

## КРАТКОСРОЧНОЕ ПРОГНОЗИРОВАНИЕ ЭЛЕКТРОПОТРЕБЛЕНИЯ ОБОГАТИТЕЛЬНОЙ ФАБРИКИ

А.Д. Моргоева<sup>1</sup>, И.Д. Моргоев<sup>1</sup>, Р.В. Ключев<sup>2</sup>, В.Н. Хетагуров<sup>1</sup>, О.А. Гаврина<sup>1</sup>

<sup>1</sup> Северо-Кавказский горно-металлургический институт  
(государственный технологический университет), Владикавказ, РСО-Алания, Россия,  
e-mail: m.angelika-m@yandex.ru

<sup>2</sup> Московский политехнический университет, Москва, Россия

**Аннотация:** Представлены результаты прогнозирования электропотребления обогатительной фабрики. В связи с энергоемкостью технологического процесса на рассматриваемой обогатительной фабрике необходимо совершенствование системы управления электропотреблением. Одним из методов повышения эффективности принятия решений в процессе управления электропотреблением является планирование. Однако для обеспечения результативности планирования необходим учет и детальный анализ производственных факторов. Прогнозирование же электропотребления позволяет на системном уровне управлять электропотреблением предприятия при оперативном учете данных о протекании технологического процесса. Поэтому актуальным направлением исследований является адаптация существующих и разработка новых методов прогнозирования электропотребления. Рассмотрены современные методы интеллектуального анализа данных. По фактическим данным о суточном электропотреблении за 2021 г. было построено несколько моделей машинного обучения и проведено сравнение их точности. В моделях были учтены как погодные, так и технологические факторы. Наилучшие результаты прогноза были получены с помощью модели, основанной на алгоритме «случайного леса» Random Forest. Погрешность прогноза на неделю вперед составила менее 5% по величине средней абсолютной процентной ошибки, что позволяет считать полученный результат точным.

**Ключевые слова:** энергосбережение, обогатительная фабрика, промышленность, случайный лес, градиентный бустинг, электропотребление, прогнозирование, машинное обучение.

**Для цитирования:** Моргоева А. Д., Моргоев И. Д., Ключев Р. В., Хетагуров В. Н., Гаврина О. А. Краткосрочное прогнозирование электропотребления обогатительной фабрики // Горный информационно-аналитический бюллетень. – 2023. – № 5-1. – С. 157–169. DOI: 10.25018/0236\_1493\_2023\_51\_0\_157.

### Short-term prediction of energy consumption at concentration factory

A.D. Morgoeva<sup>1</sup>, I.D. Morgoev<sup>1</sup>, R.V. Klyuev<sup>2</sup>, V.N. Khetagurov<sup>1</sup>, O.A. Gavrina<sup>1</sup>

<sup>1</sup> North Caucasian Institute of Mining and Metallurgy  
(State Technological University), Vladikavkaz, Russia, e-mail: m.angelika-m@yandex.ru

<sup>2</sup> Moscow Polytechnic University, Moscow, Russia

---

**Abstract:** The article describes prediction of energy consumption at a concentration factory. In view of the energy intensity of the process flow at the test concentration factory, its power delivery system needs an improvement. One of the methods of making decisions on power delivery more effective is planning. The effectiveness of planning requires inclusion and comprehensive analysis of all production factors. The energy consumption forecast enables a systemic control of power intake at the factory, with the real-time inclusion of all data on a production process. For this reason, it seems to be scientifically relevant to develop and adapt energy consumption prediction techniques. The scope of this study also embraces the modern methods of the intelligent analysis of data. Using the actual data on daily energy consumption in 2021, a number of the machine learning models are constructed and their accuracy is compared. The best prediction is provided by the model using the Random Forest algorithm. The error of the forecast for a week ahead is less than 5% MAPE, which allows considering the obtained result as an accurate outcome.

**Key words:** energy saving, concentration factory, industry, Random Forest, gradient boosting, energy consumption, prediction, machine learning.

**For citation:** 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;(5-1):157-169. [In Russ]. DOI: 10.25018/0236\_1493\_2023\_51\_0\_157.

---

## Введение

Совершенствование ресурсосберегающих подходов является важным аспектом развития промышленного производства. Функционирование оптового рынка электроэнергии и мощности (ОРЭМ) позволяет предприятиям переходить на экономически выгодные условия приобретения электроэнергии. К таковым относятся рынок на сутки вперед, балансирующий рынок, двусторонние договоры и др. Основным условием, необходимым для участия в ОРЭМ, является наличие достоверного прогноза потребления электроэнергии и мощности на сутки и более вперед.

Предприятия горной отрасли являются, как правило, крупными потребителями электроэнергии, при этом временной ряд их электропотребления является случайной величиной, на которую оказывает влияние множества горно-геологических и технологических факторов [1, 2],

а также климатических условий и т.п. Поэтому совершенствование энергосберегающих подходов является особенно актуальным направлением исследований в условиях необходимости поддержания конкурентоспособности горнодобывающей промышленности [3]. Подтверждением этому является наличие значительного числа научных работ по развитию энергосберегающих подходов в электрообеспечении горных предприятий.

Так, в работе [4] приведены результаты прогнозирования электропотребления горно-металлургического завода с помощью гибридной модели, представляющей собой модель искусственной нейронной сети с применением сингулярного спектрального анализа для разложения исходного ряда электропотребления на аддитивные составляющие. Описанный в [4] подход позволил повысить точность прогнозной модели по сравнению с применением других моделей.

В исследовании [5] представлены результаты реализации проекта системы мониторинга и прогнозирования пиковых нагрузок электроэнергии для горнодобывающей промышленности. В процессе внедрения данного проекта были достигнуты следующие результаты: проведено исследование потребления электроэнергии на выбранном объекте (карьер Бен-Герир, Марокко) с помощью средств машинного обучения; создано несколько моделей прогнозирования спроса на электроэнергию на основе ретроспективных данных (модель искусственной нейронной сети, модель временного ряда нейро-нечеткого вывода, модель регрессии опорных векторов SVM и квантильная регрессия Fast Forest), среди которых наилучшие результаты прогноза получены с помощью модели квантильной регрессии Fast Forest (FFQR) [5, 6].

В работе [7] описана необходимость использования технологических факторов при среднесрочном (на месяц вперед) прогнозировании электропотребления для небольшого промышленного предприятия. Важность учета метеорологических факторов при прогнозировании электропотребления описана в [8, 9].

Как следует из результатов литературных обзоров [10, 11], несмотря на большое число подходов к прогнозированию электропотребления, можно констатировать отсутствие универсальных методов, подходящих для каждой предметной области и для любого периода упреждения прогноза. Поэтому необходимость адаптации существующих или разработки новых методов прогнозирования с учетом специфики предметной области (технологического процесса) побуждает исследователей производить научный поиск новых подходов.

В этой связи было принято решение провести исследование — краткосрочное прогнозирование потребления электроэнергии для обогатительной фабрики.

Таким образом, целью исследования является повышение эффективности использования электроэнергии на обогатительной фабрике. В качестве критерия эффективности использования электроэнергии на обогатительной фабрике рассматривается энергетическая составляющая затрат в себестоимости продукции, определяемая по (1).

$$\varepsilon(t) = \frac{Z_{\varepsilon}(t)}{T \cdot B(t)} \rightarrow \min, \quad (1)$$

где  $Z_{\varepsilon}(T)$  — энергетическая составляющая затрат в себестоимости продукции за время  $t$ , руб.;  $B(T)$  — выпуск продукции за время  $t$ , ед. продукции;  $t$  — рассматриваемый интервал времени, сутки.

Научное обоснование и расчет этого показателя базируются на решении ряда важных задач, одной из которой является разработка прогностических моделей электропотребления обогатительной фабрики на недельный период упреждения.

Для осуществления поставленной цели были определены и выполнены следующие задачи:

- сбор ретроспективных данных об электропотреблении;
- предобработка исходных данных;
- построение моделей машинного обучения;
- оценка погрешности полученных с помощью разработанных моделей прогнозов.

В процессе выполнения исследования были получены как прикладные результаты, так и теоретические.

### **Технологический процесс обогатительной фабрики**

Обогатительная фабрика входит в состав горно-обогатительного комбината (ГОК), является самым мощным потребителем электроэнергии ГОК. На фабрике осуществляется технологический процесс по переработке руды и получению вольфрамового и молибденового

концентратов следующим образом. Добытая на карьере и руднике руда транспортируется к дробильному корпусу фабрики. Здесь она подвергается среднему и мелкому дроблению в замкнутом цикле с грохочением. Крупное дробление осуществляется на руднике в щековых дробилках. Измельчение руды происходит в шаровых мельницах в одну стадию в замкнутом цикле со спиральными классификаторами. Слив классификаторов поступает на основную молибденовую флотацию, где выделяется грубый сульфидный молибденовый концентрат. Затем концентрат подвергается доводке. Часть флотационного концентрата для удаления вредных примесей обрабатывается в цехе выщелачивания соляной кислотой, а другая часть направляется на гидрометаллургический завод в виде вольфрамо-молибденового продукта [12]. При обработке концентрата соляной кислотой часть вольфрама и окисленного молибдена переходит в раствор, из которого молибден и вольфрам осаждаются с помощью извести.

Таким образом, технологический процесс обогатительной фабрики можно охарактеризовать как сложный и ресурсоемкий. Для описания использования электроэнергии при осуществлении технологического процесса приведем краткую характеристику электроснабжения обогатительной фабрики.

### **Краткая характеристика электроснабжения обогатительной фабрики**

Подстанция, питающая обогатительную фабрику, укомплектована двумя открытыми распределительными устройствами напряжением 110 кВ и 35 кВ соответственно.

Значительную долю общей электрической нагрузки фабрики составляют высоковольтные двигатели. Для привода шаровых мельниц применяются синхронные двигатели. Привод дробилок осуществляется асинхронными двигателями двух типов. Номинальные параметры двигателей приведены в табл. 1.

Режим работы всех электроприемников длительный, фактическая загрузка высоковольтных двигателей составляет 60 – 70% от номинальной. Технологическое оборудование предприятия энергоемкое и устаревшее, выпуск продукции неравномерный в течение года.

По степени бесперебойности электроснабжения обогатительная фабрика относится к потребителю первой категории, так как имеются приемники, прекращение работы которых вызывает длительное расстройство технологического процесса. Поэтому использование накопителей электроэнергии как источников электрической энергии в часы пиковой нагрузки может быть экономически целесообразным решением [13]. При этом

Таблица 1

#### **Номинальные параметры высоковольтных двигателей Номинальные параметры высоковольтных двигателей**

Назначение	Вид высоковольтных двигателей	Напряжение, кВ	Максимальная мощность, кВт	Сила тока, А	Частота вращения, об/мин
Привод шаровых мельниц	синхронные двигатели	6	420	70	250
Привод дробилок	асинхронные двигатели первого типа	6	198	33	490
	асинхронные двигатели второго типа	6	287	44,5	490

накопление электроэнергии предполагается в часы минимальной нагрузки на электросеть и по минимальному тарифу. По оценкам экспертов исследовательской компании BloombergNEF (BNEF), к концу 2030 г. емкость систем накопления энергии (СНЭ) возрастет до 358 ГВт/1028 ГВт·ч, что в 21 раз превышает показатель, зафиксированный в 2020 г. (17 ГВт/34 ГВт·ч). Ожидается, что в период с 2021 по 2030 гг. суммарная емкость систем накопления энергии в мире возрастет на 345 ГВт, что сопоставимо с мощностью нынешней энергосистемы Японии [14].

В качестве накопителей в крупных системах электроснабжения могут использоваться гидроаккумулирующие электростанции. Их можно рассматривать в качестве СНЭ для обогатительной фабрики. Однако для инвестиций в такой проект и дальнейшее функционирование подобной схемы режимного регулирования нагрузки необходим точный прогноз электропотребления на сутки вперед для определения оптимальной емкости накопителей электроэнергии.

Таким образом, обогатительная фабрика является энергоемким предприятием горной промышленности. Одним из возможных путей снижения затрат на электропотребление является участие в программах оптового рынка электроэнергии и мощности. Прогнозирование электропотребления позволяет проводить обоснованное планирование затрат на электроэнергию [15, 16]. Кроме того, наличие достоверного прогноза дает возможность принимать более обоснованные решения по управлению режимами работы электрооборудования [17, 18], формировать стратегию сокращения величины максимальной мощности в часы пиковых нагрузок [19, 20], переходить на более выгодные тарифы электропотребления [21], открывает возможность внедрения промышленных накопителей электриче-

ской энергии [22] и многое другое [23, 24].

### **Методика выполнения исследования**

Исследования проводились по роботанной методике, предусматривающей алгоритм расчета, реализованный в интерактивной платформе Jupyter Notebook на языке программирования Python. Были использованы библиотеки Numpy и Pandas (для вычислений и манипуляций с данными), Matplotlib (для визуализации данных), Scikit-learn, XGBoost и Cat Boost (для предобработки данных и загрузки экземпляров моделей регрессии).

В качестве исходных данных были взяты: фактические суточные данные потребления электроэнергии за 2021 г., метеорологические данные (среднесуточные значения температуры и скорости ветра) из открытых источников информации, а также данные технологического процесса. К данным, характеризующим технологический процесс, были отнесены данные по выработке продукции в цехах дробильного и флотационного комплексов, а также цеха по обезвоживанию, фильтрации и сушке сырья.

На первом этапе исследования был проведен анализ исходного набора данных (дата-сета). На рис. 1 приведен график потребления электроэнергии за 2021 г. на обогатительной фабрике.

Была произведена предобработка исходных данных. Она заключалась в нахождении пропусков в данных и заполнении их с помощью процедуры интерполяции. Для прогнозирования в качестве входных моделей были использованы следующие признаки: температура наружного воздуха ( $T$ ), скорость ветра ( $W$ ), данные выработки продукции дробильного комплекса (Des\_1), данные выработки продукции флотационного комплекса (Des\_2), данные выработки продукции цеха по обезвоживанию, фильтрации и




Рис. 1. График потребления электроэнергии обогатительной фабрикой за 2021 г.

Fig. 1. Graph of electricity power consumption at the enrichment plant in 2021

сушке сырья (Des\_3). Целевой переменной ( $y$ ) явилось суточное электропотребление. Все значения являются средними за сутки.

Для обучения и тестирования моделей набор данных длиной  $n$  был разделен следующим образом. Набор данных длиной  $n - 7$  значений был разделен на обучающую и тестовую выборки в соотношении 80:20, а последние 7 значений были зарезервированы для валидации — прогнозирования электропотребления на неделю вперед.

Затем для приведения всех признаков к одинаковому масштабу была проведена минимаксная нормализация признаков по (2) с помощью функции MinMax Scaler библиотеки SkLearn.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}. \quad (2)$$

В качестве алгоритмов, с помощью которых были построены модели машинного обучения, были взяты следующие:  $k$ -ближайших соседей KNeighborsRegressor (KNN), дерево решений DecisionTreeRegressor (DTR), случайный лес RandomForestRegressor (RFR), экстремальный градиентный бустинг XGBRegressor, градиентный бустинг CatBoostRegressor. Подбор параметров моделей (кроме XGBoost) происходил с помощью инструмента перекрестной проверки GridSearchSV, реализованного в модуле model\_selec-

tion библиотеки SkLearn. Для этого была задана так называемая «сетка параметров» или параметр param\_grid, представляющий собой массив значений параметров, перебор которых необходимо выполнить. Затем в параметре estimator была указана соответствующая модель, а в параметре cv было указано количество разбиений кросс-валидации, которое было определено экспериментально перебором значений. В качестве метрики ошибки для оценки погрешности в процессе подбора параметров для каждой модели (scoring) была указана отрицательная средняя абсолютная ошибка (neg\_mae), вычисляемая по (3) и представляющая собой инвертированное значение средней абсолютной ошибки (mean absolute error).

$$neg\_mae(y, \hat{y}) = -\frac{1}{n} \sum_{i=0}^{n-1} |y_i - \hat{y}_i|, \quad (3)$$

где  $y_i$  — это фактическое значение для  $i$ -го наблюдения;  $\hat{y}_i$  — прогнозируемое значение для  $i$ -го наблюдения;  $n$  — количество наблюдений.

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-neigh-



bors — 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, в котором 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, например, среднеквадратичная ошибка (MSE), вычисляемая по (4).

$$MSE(y, \hat{y}) = -\frac{1}{n} \sum_{i=0}^{n-1} (y_i - \hat{y}_i)^2, \quad (4)$$

где  $y_i$  — это фактическое значение для  $i$ -го наблюдения;  $\hat{y}_i$  — прогнозируемое значение для  $i$ -го наблюдения;  $n$  — количество наблюдений.

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 улучшило результаты прогнозирования), и сделать 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, L2-регуляризацию и др. возможности. Основными параметрами модели являются: iterations — количество итераций, loss\_function — функция потерь, скорость обучения learning\_rate, 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.

Таблица 2

**Оценка качества прогностических моделей**  
**Оценка качества прогностических моделей**

Модель	Метрики качества прогноза				
	обучающий дата-сет		тестовый дата-сет		тестирование на 7 дней
	MAPE, %	R <sup>2</sup>	MAPE, %	R <sup>2</sup>	MAPE, %
к-ближайших соседей K Neighbors Regressor	18,63	0,21	16,72	-0,37	15,79
Дерево решений Decision Tree Regressor	0	1	12,45	0,49	9,13
Случайный лес Random Forest Regressor	7,59	0,84	6,43	0,79	4,09
Экстремальный градиентный бустинг XGBRegressor	1,11	0,99	10,82	0,23	6,34
Градиентный бустинг CatBoostRegressor	5,81	0,93	8,52	0,65	7,82

В качестве метрик качества прогнозов были выбраны средняя абсолютная ошибка в процентах (MAPE), вычисляемая по (5) и коэффициент детерминации (R<sup>2</sup>), рассчитываемый по (6).

$$MAPE(y, \hat{y}) = \frac{1}{n} \sum_{i=0}^{n-1} \frac{|y_i - \hat{y}_i|}{y_i} \cdot 100\%, \quad (5)$$

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (6)$$

где  $y_i$  — это фактическое значение для  $i$ -го наблюдения;  $\hat{y}_i$  — прогнозируемое значение для  $i$ -го наблюдения;  $n$  — количество наблюдений.

Как показали результаты исследований, точность моделей к-ближайших соседей и деревьев решений оказалась неудовлетворительной. В табл. 2 приведены значения метрик качества прогнозных моделей для обучающей и тестовой выборки. Как можно заметить, наибольшее значение коэффициента детерминации (R<sup>2</sup> = 0,79) у модели случайного леса.




Рис. 2. Фактические и тестовые значения электропотребления для обогатительной фабрики за неделю  
 Fig. 2. Actual and forecast values of electricity consumption for the enrichment plant for a week



Также у данной модели наблюдается наименьшее переобучение. Для того чтобы оценить погрешность моделей на недельном интервале, было проведено тестирование указанных моделей. Значения ошибок для недельного тестирования указаны в последнем столбце в табл. 2

На рис. 2. приведены графики фактических значений электропотребления и полученных разными моделями на неделю вперед для обогатительной фабрики.

Таким образом, погрешность прогноза, полученного с помощью модели машинного обучения, основанной на алгоритме RFR, составляет менее 6,43% на тестовой выборке при коэффициенте детерминации  $R^2$ , равном 0,79. Это позволяет рекомендовать ее применение при прогнозировании электропотребления обогатительной фабрики.

### **Выводы**

В настоящем исследовании было проведено прогнозирование электропотребления обогатительной фабрики. Были построены модели машинного обучения с использованием универсальных алгоритмов регрессии. Наилучшие показатели прогнозирования были достигну-

ты с помощью модели регрессии, основанной на алгоритме случайного леса Random Forest. Погрешность при тестировании модели на недельном временном интервале составила 4,09%, что позволяет считать прогноз достаточно точным.

Таким образом, полученные результаты прогнозирования могут быть использованы при разработке системы поддержки принятия решений по управлению электропотреблением обогатительной фабрики. Для обобщения результатов исследования для других предприятий, в том числе горной промышленности, необходимо проведение дополнительных исследований.

Поэтому перспективой дальнейших исследований является учет большего количества факторов технологического процесса, повышение точности прогнозных моделей, а также увеличение горизонта прогнозирования.

Также в дальнейших исследованиях будет определен критерий эффективности использования электроэнергии на обогатительной фабрике, в качестве которого рассматривается энергетическая составляющая затрат в себестоимости продукции.

### **СПИСОК ЛИТЕРАТУРЫ**

1. Кубрин С. С., Решетняк С. Н., Загоршменный И. М., Карпенко С. М. Имитационное моделирование режимов работы оборудования комплексно-механизированного забоя угольной шахты // Устойчивое развитие горных территорий. — 2022. — Т. 14. — № 2. — С. 286 — 294. DOI: 10.21177/1998-4502-2022-14-2-286-294.

2. Баловцев С. В. Аэрологические риски высших рангов в угольных шахтах // Горные науки и технологии. — 2022. — Т. 7. — № 4. — С. 310 — 319. DOI: 10.17073/2500-0632-2022-08-18.

3. Петров В. Л., Кузнецов Н. М., Морозов И. Н. Управление спросом на электроэнергию в горнопромышленном секторе на основе интеллектуальных электроэнергетических систем // Горный информационно-аналитический бюллетень. — 2022. — № 2. — С. 169 — 180. DOI: 10.25018/0236\_1493\_2022\_2\_0\_169.

4. Вялкова С. А., Моргоева А. Д., Гаврина О. А. Разработка гибридной модели прогнозирования потребления электрической энергии для горно-металлургического предприятия //

Устойчивое развитие горных территорий. — 2022. — Т. 14. — № 3. — С. 486–493. DOI: 10.21177/1998-4502-2022-14-3-486-493.

5. *Laayati O., Bouzi M., Chebak A.* Smart energy management system: design of a monitoring and peak load forecasting system for an experimental open-pit mine // *Applied System Innovation*. 2022, vol. 5, no. 1, article 18. DOI: 10.3390/asi5010018.

6. *Klyuev R. V., Morgoev I. D., Morgoeva A. D., Gavrina O. A., Martyushev N. V., Efremenkov E. A., Mengxu Q.* Methods of forecasting electric energy consumption: A literature review // *Energies*. 2022, vol. 15, no. 23, article 8919. DOI: 10.3390/en15238919.

7. *Моргоева А. Д., Моргоев И. Д., Ключев Р. В., Гаврина О. А.* Прогнозирование потребления электрической энергии промышленным предприятием с помощью методов машинного обучения // *Известия Томского политехнического университета. Инжиниринг георесурсов*. — 2022. — Т. 333. — № 7. — С. 115–125. DOI: 10.18799/24131830/2022/7/3527.

8. *Shklyarskiy J. E., Batueva D. E.* The influence of external climatic factors on the accuracy of the forecast of energy consumption // *E3S Web of Conferences*. 2019, vol. 140, article 04014. DOI: 10.1051/e3sconf/201914004014.

9. *Rollert K. E.* The underlying factors in the uptake of electricity demand response: The case of Poland // *Utilities Policy*. 2018, vol. 54, pp. 11–21. DOI: 10.1016/j.jup.2018.07.002.

10. *Biel K., Glock C.* Systematic literature review of decision support models for energy-efficient production planning // *Computers & Industrial Engineering*. 2016, vol. 101, pp. 243–259. DOI: 10.1016/j.cie.2016.08.021.

11. *Lago J., Marcjasz G., De Schutter B., Weron R.* Forecasting day-ahead electricity prices. A review of state-of-the-art algorithms, best practices and an open-access benchmark // *Applied Energy*. 2021, vol. 293, article 116983. DOI: 10.1016/j.apenergy.2021.116983.

12. *Кондратьев Ю. И., Соколова О. А., Камбаров Д. А., Мирошников А. С.* Электрохимическое выщелачивание полиметаллической руды под действием несимметричных импульсов тока и добавкой поверхностно-активного вещества // *Устойчивое развитие горных территорий*. — 2022. — Т. 14. — № 1. — С. 20–26. DOI: 10.21177/1998-4502-2022-14-1-20-26.

13. *Senchilo N. D., Ustinov D. A.* Method for determining the optimal capacity of energy storage systems with a long-term forecast of power consumption // *Energies*. 2021. vol. 14, no. 21, article 7098. DOI: 10.3390/en14217098.

14. *Новикова А.* Накопитель энергии: технологии и тренды // *Рынок электротехники*. — 2022. — № 4(68). — С. 6–25.

15. *Ibrahim B., Rabelo L.* A deep learning approach for peak load forecasting: A case study on Panama // *Energies*. 2021, vol. 14, no. 11, article 3039. DOI: 10.3390/en14113039.


16. *Wang Y., Zhang N., Chen X.* A short-term residential load forecasting model based on LSTM recurrent neural network considering weather features // *Energies*. 2021, vol. 14, no. 10, article 2737. DOI: 10.3390/en14102737.

17. *Dorado R. F., Suarez J. D., del Real Torres A.* Short-term load forecasting using encoder-decoder WaveNet: Application to the french grid // *Energies*. 2021, vol. 14, no. 9, article 2524. DOI: 10.3390/en14092524.

18. *Xie Y., Yang Y., Wu L.* Power consumption forecast of three major industries in China based on fractional grey model // *Axioms*. 2022, vol. 11, no. 8, article 407. DOI: 10.3390/axioms11080407.

19. *Khan S., Aslam S., Mustafa I., Aslam S.* Short-term electricity price forecasting by employing ensemble empirical mode decomposition and extreme learning machine // *Forecasting*. 2021, vol. 3, no. 3, pp. 460–477. DOI: 10.3390/forecast3030028.

20. *Abu-Salih B., Wongthongtham P., Morrison G., Coutinho K., Al-Okaily M., Huneiti A.* Short-term renewable energy consumption and generation forecasting. A case study of Western Australia // *Heliyon*. 2022, vol. 8, no. 3, article e09152. DOI: 10.1016/j.heliyon.2022.e09152.

21. Szul T., Nečka K., Lis S. Application of the takagi-sugeno fuzzy modeling to forecast energy efficiency in real buildings undergoing thermal improvement // *Energies*. 2021, vol. 14, no. 7, article 1920. DOI: 10.3390/en14071920.
22. Ramos D., Khorram M., Faria P., Vale Z. Load forecasting in an office building with different data structure and learning parameters // *Forecasting*. 2021, vol. 3, no. 1, pp. 242 – 255. DOI: 10.3390/forecast3010015.
23. Oprea S.-V., Pirjan A., Caruțașu G., Petroșanu D.-M., Bara A., Stanica J.-L., Coculescu C. Developing a Mixed neural network approach to forecast the residential electricity consumption based on sensor recorded data // *Sensors*. 2018, vol. 18, no. 5, article 1443. DOI: 10.3390/s18051443.
24. Frikha M., Taouil K., Fakhfakh A., Derbel F. Limitation of deep-learning algorithm for prediction of power consumption // *Engineering Proceedings*. 2022, vol. 18, no. 1, article 26. DOI: 10.3390/engproc2022018026. 

## REFERENCES

1. Kubrin S. S., Reshetnyak S. N., Zakorshmeny I. M., Karpenko S. M. Simulation modeling of equipment operating modes of complex mechanized coal mine face. *Sustainable Development of Mountain Territories*. 2022, vol. 14, no. 2, pp. 286 – 294. [In Russ]. DOI: 10.21177/1998-4502-2022-14-2-286-294.
2. Balovtsev S. V. Higher rank aerological risks in coal mines. *Mining Science and Technology (Russia)*. 2022, vol. 7, no. 4, pp. 310 – 319. [In Russ]. DOI: 10.17073/2500-0632-2022-08-18.
3. Petrov V. L., Kuznetsov N. M., Morozov I. N. Electric energy demand management in mining industry using smart power grids. *MIAB. Mining Inf. Anal. Bull.* 2022, no. 2, pp. 169 – 180. [In Russ]. DOI: 10.25018/0236\_1493\_2022\_2\_0\_169.
4. Vyalkova S. A., Morgoeva A. D., Gavrina O. A. Development of a hybrid model for predicting the consumption of electrical energy for a mining and metallurgical enterprise. *Sustainable Development of Mountain Territories*. 2022, vol. 14, no. 3, pp. 486 – 493. [In Russ]. DOI: 10.21177/1998-4502-2022-14-3-486-493.
5. Laayati O., Bouzi M., Chebak A. Smart energy management system: design of a monitoring and peak load forecasting system for an experimental open-pit mine. *Applied System Innovation*. 2022, vol. 5, no. 1, article 18. DOI: 10.3390/asi5010018.
6. Klyuev R. V., Morgoev I. D., Morgoeva A. D., Gavrina O. A., Martyushev N. V., Efremenkov E. A., Mengxu Q. Methods of forecasting electric energy consumption: A literature review. *Energies*. 2022, vol. 15, no. 23, article 8919. DOI: 10.3390/en15238919.
7. Morgoeva A. D., Morgoev I. D., Klyuev R. V., Gavrina O. A. Forecasting of electric energy consumption by an industrial enterprise using machine learning methods. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*. 2022, vol. 333, no. 7, pp. 115 – 125. [In Russ]. DOI: 10.18799/24131830/2022/7/3527.
8. Shklyarskiy J. E., Batueva D. E. The influence of external climatic factors on the accuracy of the forecast of energy consumption. *E3S Web of Conferences*. 2019, vol. 140, article 04014. DOI: 10.1051/e3sconf/201914004014.
9. Rollert K. E. The underlying factors in the uptake of electricity demand response: The case of Poland. *Utilities Policy*. 2018, vol. 54, pp. 11 – 21. DOI: 10.1016/j.jup.2018.07.002.
10. Biel K., Glock C. Systematic literature review of decision support models for energy-efficient production planning. *Computers & Industrial Engineering*. 2016, vol. 101, pp. 243 – 259. DOI: 10.1016/j.cie.2016.08.021.
11. Lago J., Marcjasz G., De Schutter B., Weron R. Forecasting day-ahead electricity prices. A review of state-of-the-art algorithms, best practices and an open-access benchmark. *Applied Energy*. 2021, vol. 293, article 116983. DOI: 10.1016/j.apenergy.2021.116983.
12. Kondratiev Yu. I., Sokolova O. A., Kambolov D. A., Miroshnikov A. S. Electrochemical leaching of polymetallic ore under the action of asymmetric current pulses and the addition of a

surfactant. *Sustainable Development of Mountain Territories*. 2022, vol. 14, no. 1, pp. 20–26. [In Russ]. DOI: 10.21177/1998-4502-2022-14-1-20-26.

13. Senchilo N. D., Ustinov D. A. Method for determining the optimal capacity of energy storage systems with a long-term forecast of power consumption. *Energies*. 2021. vol. 14, no. 21, article 7098. DOI: 10.3390/en14217098.

14. Novikova A. Energy storage: technologies and trends. *Rynek elektrotechniki*. 2022, no. 4(68), pp. 6–25. [In Russ].

15. Ibrahim B., Rabelo L. A deep learning approach for peak load forecasting: A case study on Panama. *Energies*. 2021, vol. 14, no. 11, article 3039. DOI: 10.3390/en14113039.

16. Wang Y., Zhang N., Chen X. A short-term residential load forecasting model based on LSTM recurrent neural network considering weather features. *Energies*. 2021, vol. 14, no. 10, article 2737. DOI: 10.3390/en14102737.

17. Dorado R. F., Suarez J. D., del Real Torres A. Short-term load forecasting using encoder-decoder WaveNet: Application to the french grid. *Energies*. 2021, vol. 14, no. 9, article 2524. DOI: 10.3390/en14092524.

18. Xie Y., Yang Y., Wu L. Power consumption forecast of three major industries in China based on fractional grey model. *Axioms*. 2022, vol. 11, no. 8, article 407. DOI: 10.3390/axioms11080407.

19. Khan S., Aslam S., Mustafa I., Aslam S. Short-term electricity price forecasting by employing ensemble empirical mode decomposition and extreme learning machine. *Forecasting*. 2021, vol. 3, no. 3, pp. 460–477. DOI: 10.3390/forecast3030028.

20. Abu-Salih B., Wongthongtham P., Morrison G., Coutinho K., Al-Okaily M., Huneiti A. Short-term renewable energy consumption and generation forecasting. A case study of Western Australia. *Heliyon*. 2022, vol. 8, no. 3, article e09152. DOI: 10.1016/j.heliyon.2022.e09152.

21. Szul T., Nečka K., Lis S. Application of the takagi-sugeno fuzzy modeling to forecast energy efficiency in real buildings undergoing thermal improvement. *Energies*. 2021, vol. 14, no. 7, article 1920. DOI: 10.3390/en14071920.

22. Ramos D., Khorram M., Faria P., Vale Z. Load forecasting in an office building with different data structure and learning parameters. *Forecasting*. 2021, vol. 3, no. 1, pp. 242–255. DOI: 10.3390/forecast3010015.

23. Oprea S.-V., Pirjan A., Caruțașu G., Petroșanu D.-M., Bara A., Stanica J.-L., Coculescu C. Developing a Mixed neural network approach to forecast the residential electricity consumption based on sensor recorded data. *Sensors*. 2018, vol. 18, no. 5, article 1443. DOI: 10.3390/s18051443.

24. Frikha M., Taouil K., Fakhfakh A., Derbel F. Limitation of deep-learning algorithm for prediction of power consumption. *Engineering Proceedings*. 2022, vol. 18, no. 1, article 26. DOI: 10.3390/engproc2022018026.

## ИНФОРМАЦИЯ ОБ АВТОРАХ

Моргоева Анжелика Джабраиловна<sup>1</sup> — аспирант,

e-mail: m.angelika-m@yandex.ru,

ORCID ID: 0000-0003-2949-1993,

Моргоев Ирбек Джабраилович<sup>2</sup> — аспирант,

e-mail: m.irbek@yandex.ru,

ORCID ID: 0000-0003-4390-5662,

Клюев Роман Владимирович — д-р техн. наук,

доцент, профессор,

e-mail: kluev-roman@rambler.ru,

Московский политехнический университет,

ORCID ID: 0000-0003-3777-7203,

*Хетагуров Валерий Николаевич*<sup>1</sup> — д-р техн. наук,  
профессор, e-mail: hetag@mail.ru,  
ORCID ID: 0000-0002-2151-9309,  
*Гаврина Оксана Александровна*<sup>1</sup> — канд. техн. наук,  
доцент, e-mail: Gavrina-Oksana@yandex.ru,  
ORCID ID: 0000-0002-9712-9075,  
<sup>1</sup> Северо-Кавказский горно-металлургический институт  
(государственный технологический университет).  
**Для контактов:** Моргоева А.Д., e-mail: m.angelika-m@yandex.ru.

#### INFORMATION ABOUT THE AUTHORS

*A.D. Morgoeva*<sup>1</sup>, Graduate Student,  
e-mail: m.angelika-m@yandex.ru,  
ORCID ID: 0000-0003-2949-1993,

*I.D. Morgoev*<sup>1</sup>, Graduate Student,  
e-mail: m.irbek@yandex.ru,  
ORCID ID: 0000-0003-4390-5662,

*R.V. Klyuev*, Dr. Sci. (Eng.),  
Assistant Professor, Professor,  
Moscow Polytechnic University,  
107023, Moscow, Russia,  
e-mail: kluev-roman@rambler.ru,  
ORCID ID: 0000-0003-3777-7203,

*V.N. Khetagurov*<sup>1</sup>, Dr. Sci. (Eng.),  
Professor, e-mail: hetag@mail.ru,  
ORCID ID: 0000-0002-2151-9309,

*O.A. Gavrina*<sup>1</sup>, Cand. Sci. (Eng.),  
Assistant Professor,  
e-mail: Gavrina-Oksana@yandex.ru,  
ORCID ID: 0000-0002-9712-9075,

<sup>1</sup> North Caucasian Institute of Mining  
and Metallurgy (State Technological University),  
362021, Vladikavkaz, Russia.

**Corresponding author:** A.D. Morgoeva, e-mail: m.angelika-m@yandex.ru.

Получена редакцией 16.02.2023; получена после рецензии 13.03.2023; принята к печати 10.04.2023.  
Received by the editors 16.02.2023; received after the review 13.03.2023; accepted for printing 10.04.2023.

