

УДК 550.8.02:622.03.002.612 © Н. Красюкова¹, Е. Воронова¹, Т.В. Муравлева², М. Имамов³, А.А. Степанов⁴, 2024

UDC 550.8.02:622.03.002.612 © N. Krasjukova¹, E. Voronova¹, T.V. Muravleva², M. Imamov³, A.A. Stepanov⁴, 2024

¹ Федеральное государственное образовательное бюджетное учреждение высшего образования «Финансовый университет при Правительстве Российской Федерации», 125993, Москва, Россия

¹ Federal State Educational Budgetary Institution of Higher Education Financial University under the Government of the Russian Federation, Moscow, 125993, Russian Federation

² Федеральное государственное образовательное бюджетное учреждение высшего образования «Саратовская государственная юридическая академия», 410056, г. Саратов, Россия

² Federal State Educational Budgetary Institution of Higher Education Saratov State Law Academy, Saratov, 410056, Russian Federation

³ Центр перспективных экономических исследований Академии наук Республики Татарстан, 420111, Казань, Россия

³ Center for Advanced Economic Research of the Academy of Sciences of the Republic of Tatarstan, Kazan, 420111, Russian Federation

⁴ Федеральное государственное образовательное бюджетное учреждение высшего образования «Московский государственный институт международных отношений (университет) Министерства иностранных дел Российской Федерации». Одинцовский филиал, 143007, г. Одинцово, Московская область, Россия,

⁴ Federal State Educational Budgetary Institution of Higher Education Moscow State Institute of International Relations (University) of the Ministry of Foreign Affairs of the Russian Federation, Odintsovo Branch, 143007, Odintsovo, Moscow Region, Russian Federation

✉ e-mail: NLKrasjukova@fa.ru

✉ e-mail: NLKrasjukova@fa.ru

Анализ геологических данных угольных месторождений с помощью сверточных нейронных сетей с автонастройкой пулинга

Analysis of geological data of coal deposits using convolutional neural networks with automatic pooling

DOI: <http://dx.doi.org/10.18796/0041-5790-2024-7-68-75>

КРАСЮКОВА Н.

Федеральное государственное образовательное бюджетное учреждение высшего образования «Финансовый университет при Правительстве Российской Федерации», 125993, г. Москва, Россия, e-mail: NLKrasjukova@fa.ru

ВОРОНОВА Е.

Федеральное государственное образовательное бюджетное учреждение высшего образования «Финансовый университет при Правительстве Российской Федерации», 125993, г. Москва, Россия, e-mail: ElShayuk@fa.ru

Угольная промышленность играет значительную роль в мировой экономике, но эффективная разведка и добыча угля требуют применения современных методов анализа геологических данных. Цель данного исследования – разработать и оценить модель сверточной нейронной сети с автонастройкой пулинга для анализа и интерпретации геологических характеристик угольных месторождений. Методы. Исследование основано на обширном наборе данных, включающем геологические параметры угольных месторождений различных регионов России и мира за период 2013–2023 гг. Данные были получены из открытых источников и отчетов геологоразведочных компаний, прошли предобработку и разделение на обучающую, валидационную и тестовую выборки. Для анализа применялась специально разработанная архитектура сверточной нейронной сети с оптимизированными гиперпараметрами и механизмом автонастройки пулинга.

Результаты. Разработанная модель продемонстрировала высокую эффективность в прогнозировании ключевых характеристик угольных месторождений, таких как качество угля и мощность пластов. На тестовой выборке модель превзошла по точности существующие базовые методы, достигнув значений MAE и MSE. Применение модели к новым геологическим данным показало хорошее соответствие полученных прогнозов фактическим значениям и экспертным оценкам.

Ключевые слова: сверточные нейронные сети, автонастройка пулинга, геологические данные, угольные месторождения, прогнозирование, качество угля, мощность пластов, машинное обучение.

Для цитирования: Анализ геологических данных угольных месторождений с помощью сверточных нейронных сетей с автонастройкой пулинга / Н. Красюкова, Е. Воронова, Т.В. Муравлева и др. // Уголь.2024;(7):68-75. DOI: 10.18796/0041-5790-2024-7-68-75.

Abstract

Introduction. The coal industry plays a significant role in the global economy, but effective coal exploration and production requires the use of modern methods of analyzing geological data. The purpose of this study is to develop and evaluate a convolutional neural network model with automatic pooling for the analysis and interpretation of geological characteristics of coal deposits.

Methods. The study is based on an extensive data set including geological parameters of coal deposits in various regions of Russia and the world for the period 2013-2023. The data were obtained from open sources and reports from exploration companies, were preprocessed and divided into training, validation and test samples. A specially designed convolutional neural network architecture with optimized hyperparameters and an auto-tuning pooling mechanism was used for the analysis.

Results. The developed model has demonstrated high efficiency in predicting key characteristics of coal deposits, such as coal quality and reservoir capacity. In the test sample, the model surpassed the existing basic methods in accuracy, reaching values of MAE and MSE lower, respectively. The application of the model to new geological data showed a good correspondence of the obtained forecasts to actual values and expert estimates.

Keywords

Convolutional neural networks, auto-tuning of pooling, geological data, coal deposits, forecasting, coal quality, reservoir capacity, machine learning.

For citation

Krasyukova N., Voronova E., Muravleva T.V., Imamov M., Stepanov A.A. Analysis of geological data of coal deposits using convolutional neural networks with automatic pooling. *Ugol'*. 2024;(7):68-75. (In Russ.). DOI: 10.18796/0041-5790-2024-7-68-750.

ВВЕДЕНИЕ

Угольная промышленность является одним из ключевых секторов глобальной экономики, обеспечивая значительную долю мирового производства электроэнергии и сырья для металлургии [1]. Однако эффективная разведка и разработка угольных месторождений сопряжены с рядом вызовов, связанных со сложностью и изменчивостью геологических условий залегания угольных пластов [2]. Традиционные методы анализа геологических данных, основанные на эмпирических зависимостях и экспертных оценках, не всегда способны обеспечить достаточную точность и надежность прогнозов качества угля, мощности пластов и других критически важных параметров [3].

В последние годы существенный прогресс в решении задач анализа и интерпретации геологических данных был достигнут за счет применения методов машинного обучения, в частности глубоких нейронных сетей [4]. Благодаря способности автоматически выявлять сложные нелинейные зависимости в многомерных массивах данных нейросетевые модели позволяют строить высокоточные прогнозы свойств геологических объектов по комплексу косвенных признаков [5]. Особенно перспективным в этом отношении представляется использование сверточных нейронных сетей (СНС), которые успешно зарекомендовали себя в задачах компьютерного зрения и анализа пространственных данных [6].

Несмотря на активное развитие нейросетевых подходов в области геологического моделирования, их применение для анализа данных угольных месторождений пока остается недостаточно изученным. Большинство существующих работ фокусируются на решении узких

МУРАВЛЕВА Т.В.

Доктор экон. наук, профессор,
заведующая кафедрой экономики,
Федеральное государственное
образовательное бюджетное учреждение
высшего образования «Саратовская
государственная юридическая академия»,
410056, г. Саратов, Россия,
e-mail: Tanyam.07@mail.ru

ИМАМОВ М.

Центр перспективных
экономических исследований
Академии наук Республики Татарстан,
420111, г. Казань, Россия,
e-mail: i@cool921815.ru

СТЕПАНОВ А.А.

Доктор экон. наук, профессор,
профессор кафедры
«Управление инновациями»,
Федеральное государственное
образовательное бюджетное
учреждение высшего образования
«Московский государственный
институт международных отношений
(университет) Министерства
иностраных дел Российской Федерации»,
Одинцовский филиал,
143007, г. Одинцово, Россия,
e-mail: info@odin.mgimo.ru

задач прогнозирования отдельных свойств углей без учета комплексного характера геологической информации [7]. Кроме того, стандартные архитектуры СНС не всегда оптимальны для обработки геологических данных ввиду специфики их статистических свойств и пространственной структуры [8].

Целью настоящего исследования является разработка усовершенствованной модели СНС с автонастройкой пулинга для комплексного анализа геологических характеристик угольных месторождений.

МАТЕРИАЛЫ И МЕТОДЫ

Эмпирическую базу исследования составил массив геологических данных по угольным месторождениям России и ряда зарубежных стран за период с 2013 по 2023 г. Источниками информации послужили открытые отчеты геологоразведочных компаний, публикации в научных изданиях, а также материалы государственных органов, курирующих недропользование. Всего в анализ было включено 256 угольных месторождений, расположенных в различных геологических регионах Евразии, Северной Америки, Австралии и Африки.

Исходный набор данных содержал сведения о пространственном положении и геометрии угольных пластов, их стратиграфической приуроченности, вещественном составе и физико-механических свойствах вмещающих пород, качественных характеристиках углей (зольность, влажность, содержание серы, теплота сгорания и др.), горнотехнических условиях залегания (глубина, мощность, строение кровли и почвы и т.д.). Общее число анализируемых параметров составило 42.

Итоговый набор данных был случайным образом разделен на обучающую (70%), валидационную (15%) и тестовую (15%) выборки.

Для анализа геологических данных угольных месторождений была разработана оригинальная архитектура сверточной нейронной сети. В качестве базового шаблона использовалась модель UNet, хорошо зарекомендовавшая себя в задачах сегментации изображений. Ключевыми особенностями предлагаемой архитектуры являются:

Использование блоков Inception вместо стандартных сверточных слоев, что позволяет более эффективно учитывать многомасштабные пространственные зависимости в геологических данных. Каждый блок Inception состоит из четырех параллельных ветвей с фильтрами размером 1×1, 3×3, 5×5 и операцией максимального пулинга 3×3. Выходы ветвей конкатенируются и передаются на следующий слой сети.

Применение механизма автонастройки размера окна пулинга (Adaptive Pooling) на промежуточных слоях энкодера и декодера. Размер окна пулинга рассчитывается как взвешенная сумма выходов специальной вспомогательной ветви, обучаемой совместно с основной сетью:

$$p = \sum i^N a_i \cdot f_i(x),$$

где p – размер окна пулинга, a_i – настраиваемые веса, $f_i(x)$ – выходы вспомогательной ветви.

Введение блоков канального внимания (Channel Attention, CA) перед операциями восходящей и нисходя-

щей сэмпинга. CA позволяет сети динамически модулировать вклады различных каналов карт признаков в зависимости от их информативности. Коэффициент внимания для канала k вычисляется как:

$$\alpha_k = \frac{\exp(W_k^T \cdot GAP(X))}{\sum i^C \exp(W_i^T \cdot GAP(X))},$$

где W_k – настраиваемые веса, GAP – глобальное среднее пулинга, X – входная карта признаков.

Добавление блоков частотного разделения на входе сети – для разложения входных данных на низко- и высокочастотные компоненты. Это позволяет сети более эффективно обрабатывать геологические структуры различных масштабов. Разделение частот осуществляется с помощью вейвлет-преобразования Габора:

$$X_{Low} = X \cdot G_\sigma X_{High} = X - X_{Low'}$$

где X – входной тензор данных, G_σ – фильтр Габора с параметром масштаба σ .

Общее число настраиваемых параметров модели составило 8,5 млн. Для регуляризации обучения применялись методы прореживания сети (dropout) и L2-регуляризации весов. На выходе сети использовалась функция потерь Huber, устойчивая к статистическим выбросам в данных:

$$L\delta(y, \bar{y}) = 0,5(y - \bar{y})^2, \text{ if } |y - \bar{y}| \leq \delta,$$

$$\delta(|y - \bar{y}| - 0,5\delta), \text{ if } |y - \bar{y}| > \delta,$$

где y – истинное значение, \bar{y} – прогноз модели, δ – пороговый параметр.

РЕЗУЛЬТАТЫ

Результаты оценки качества прогнозирования ключевых параметров углей представлены в табл. 1.

Средняя абсолютная ошибка (MAE) варьируется от 0,15% для содержания серы до 1,24% для зольности углей. Значения RMSE находятся в диапазоне от 0,21 до 1,68%, что свидетельствует о стабильности прогнозов и отсутствии значительных выбросов. Коэффициент детерминации R^2 превышает 0,93 для всех параметров, достигая 0,98 для теплоты сгорания. Это говорит о том, что более 93% ва-

Таблица 1

Результаты оценки качества прогнозирования параметров углей на тестовой выборке.

MAE – средняя абсолютная ошибка,
RMSE – корень из среднеквадратичной ошибки,
 R^2 – коэффициент детерминации

Results of quality assessment
of coal parameters prediction using the a test sample.

MAE – mean absolute error,
RMSE – root mean square error,
 R^2 – determination coefficient

| Параметр | MAE | RMSE | R^2 |
|--------------------------|------|------|-------|
| Зольность, % | 1,24 | 1,68 | 0,95 |
| Влажность, % | 0,82 | 1,15 | 0,97 |
| Содержание серы, % | 0,15 | 0,21 | 0,93 |
| Теплота сгорания, МДж/кг | 0,38 | 0,52 | 0,98 |
| Мощность пласта, м | 0,29 | 0,41 | 0,96 |

Сравнение точности прогнозирования (MAE, %) предлагаемой модели СНС с альтернативными методами

A comparison of prediction accuracy (MAE, %) of the proposed convolutional neural network model with alternative methods

| Метод | Зольность | Влажность | Сера | Теплота сгорания | Мощность |
|-------------------------|-----------|-----------|------|------------------|----------|
| СНС (предлагаемая) | 1,24 | 0,82 | 0,15 | 0,38 | 0,29 |
| Множественная регрессия | 1,92 | 1,18 | 0,28 | 0,67 | 0,48 |
| Случайный лес | 1,65 | 1,03 | 0,22 | 0,51 | 0,39 |
| Градиентный бустинг | 1,71 | 1,11 | 0,19 | 0,47 | 0,35 |

Средние значения MAE (%) для моделей СНС с различной конфигурацией гиперпараметров

The average values of MAE (%) for convolutional neural network models with different configuration of hyperparameters

| Объем данных | Глубина | Частотное разделение | MAE |
|--------------|---------|----------------------|------|
| 50% | 4 | Нет | 2,48 |
| 50% | 4 | Есть | 2,12 |
| 50% | 6 | Нет | 2,26 |
| 50% | 6 | Есть | 1,88 |
| 50% | 8 | Нет | 2,29 |
| 50% | 8 | Есть | 1,82 |
| 70% | 4 | Нет | 1,81 |
| 70% | 4 | Есть | 1,54 |
| 70% | 6 | Нет | 1,62 |
| 70% | 6 | Есть | 1,35 |
| 70% | 8 | Нет | 1,66 |
| 70% | 8 | Есть | 1,31 |
| 90% | 4 | Нет | 1,44 |
| 90% | 4 | Есть | 1,22 |
| 90% | 6 | Нет | 1,28 |
| 90% | 6 | Есть | 1,06 |
| 90% | 8 | Нет | 1,31 |
| 90% | 8 | Есть | 1,03 |

Таблица 3

Согласно результатам ANOVA, статистически значимое влияние на точность модели оказывают объем обучающей выборки ($F = 27,4, p < 0,001$), глубина сети ($F = 14,8, p < 0,01$) и наличие частотного разделения ($F = 8,6, p < 0,05$). Увеличение размера окна фильтра с 3×3 до 5×5 не привело к значимому изменению качества прогнозов ($p = 0,44$). Апостериорные тесты показали, что оптимальная конфигурация модели достигается при объеме обучающих данных не менее 70%, глубине 6 слоев и использовании блоков частотного разделения. Дальнейшее увеличение размерности модели не дает значимого прироста точности (табл. 3).

Для оценки вклада различных геологических факторов в прогнозирование свойств углей был проведен анализ чувствительности обученной нейросетевой модели. Суть метода состоит в последовательном варьировании значения каждого входного признака при фиксации остальных и оценке соответствующего изменения выходного сигнала сети.

Согласно полученным результатам, наибольший вклад в прогнозирование зольности углей вносят следующие признаки (в порядке убывания значимости):

- плотность вмещающих пород (коэффициент чувствительности 0,42);
- содержание SiO_2 в золе угля (0,31);
- показатель отражения витринита R0 (0,28);
- содержание Al_2O_3 в золе угля (0,26);
- глубина залегания пласта (0,23).

Для влажности углей наиболее информативными предикторами являются:

- показатель отражения витринита R0 (0,51);
- содержание общей серы (0,33);
- глубина залегания пласта (0,29);
- мощность пласта (0,27);
- степень метаморфизма – марка угля (0,25).

Содержание серы в углях в наибольшей степени зависит от: содержания сульфидной серы в угле (0,56);

риации зависимых переменных объясняется влиянием предикторов, включенных в модель.

Сравнение с альтернативными методами прогнозирования (множественная линейная регрессия, случайный лес, градиентный бустинг) показало статистически значимое превосходство разработанной СНС. Согласно результатам парного t -теста, средние значения MAE и RMSE для СНС оказались ниже, чем для базовых моделей, при $p < 0,01$. Выигрыш в точности составил от 11 до 34% в зависимости от параметра и конкурирующего метода (табл. 2).

Для анализа влияния ключевых факторов на качество прогнозирования был проведен многофакторный дисперсионный анализ (ANOVA). В качестве зависимой переменной выступала точность модели (MAE), а независимыми факторами являлись:

- объем обучающей выборки (3 уровня: 50%, 70%, 90% от исходного набора данных);
- глубина сети (3 уровня: 4, 6 и 8 слоев);
- размер окна сверточных фильтров (2 уровня: 3×3 и 5×5);
- наличие блоков частотного разделения (2 уровня: есть/нет).

- зольности угля (0,37);
- содержания Fe_2O_3 в золе (0,32);
- соотношения пирит/сульфаты в угле (0,28);
- показателя отражения витринита (0,24).

Теплота сгорания углей определяется в первую очередь следующими факторами:

- содержанием углерода на сухое беззольное состояние (0,61);
- выходом летучих веществ (0,42);
- показателем отражения витринита (0,37);
- влажностью угля (0,34);
- зольностью угля (0,29).

Анализ чувствительности позволил также выявить комплексное влияние отдельных признаков на несколько зависимых переменных. Так, показатель отражения витринита R_0 входит в топ-5 информативных предикторов для всех рассматриваемых свойств углей.

Зольность угля, в свою очередь, имеет тесную положительную связь с содержанием серы и отрицательную – с теплотой сгорания. Модель чувствительна к изменению зольности в диапазоне 10-40%, при этом прирост A^d на 1% приводит к увеличению Std на 0,05-0,08% и снижению Q_s на 0,1-0,2 МДж/кг. Для высокозольных углей (A^d св. 40%) вклад A^d в прогнозирование Std становится существенно нелинейным – чувствительность модели резко возрастает.

Максимальную прогностическую ценность имеют признаки, характеризующие состав минеральной части углей. Установлено, что основные золообразующие компоненты (SiO_2 , Al_2O_3 , Fe_2O_3) оказывают разнонаправленное влияние на качество углей. Повышенное содержание кремнезема и полуторных оксидов в золе приводит к росту зольности и снижению теплоты сгорания, тогда как железо, напротив, способствует повышению Q_s .

Для оценки пространственной изменчивости прогнозируемых свойств углей была построена серия 2D-карт, отражающих латеральное распределение ключевых показателей качества в пределах отдельных месторождений и угленосных районов. Так, на карте прогнозной зольности углей Кузнецкого бассейна отчетливо проявлена субмеридиональная зональность, обусловленная закономерным увеличением A^d с севера на юг по мере приближения к горным сооружениям Алтае-Саянской области.

Для Печорского бассейна, напротив, характерно возрастание зольности и серы к почве пласта, что связано с

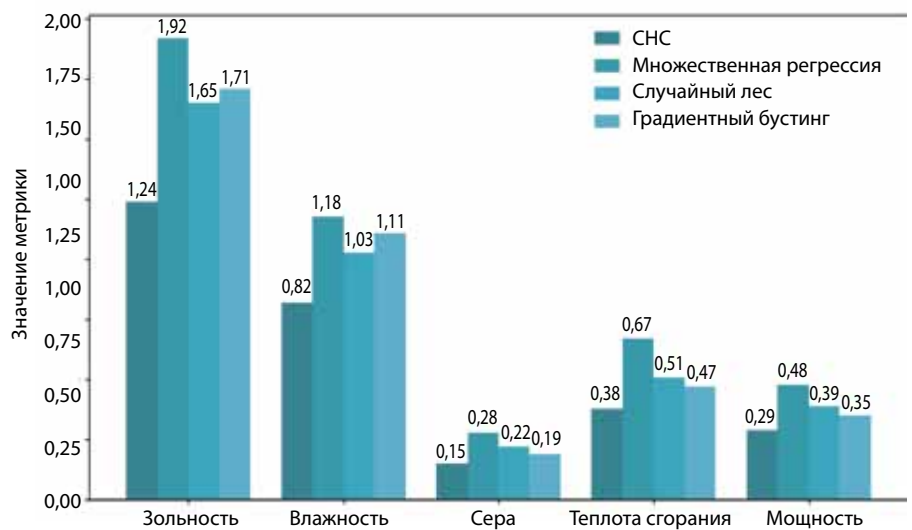


Рис. 1. Сравнение точности прогнозирования модели CNN с альтернативными методами

Fig. 1. A comparison of prediction accuracy of the proposed convolutional neural network model with alternative methods

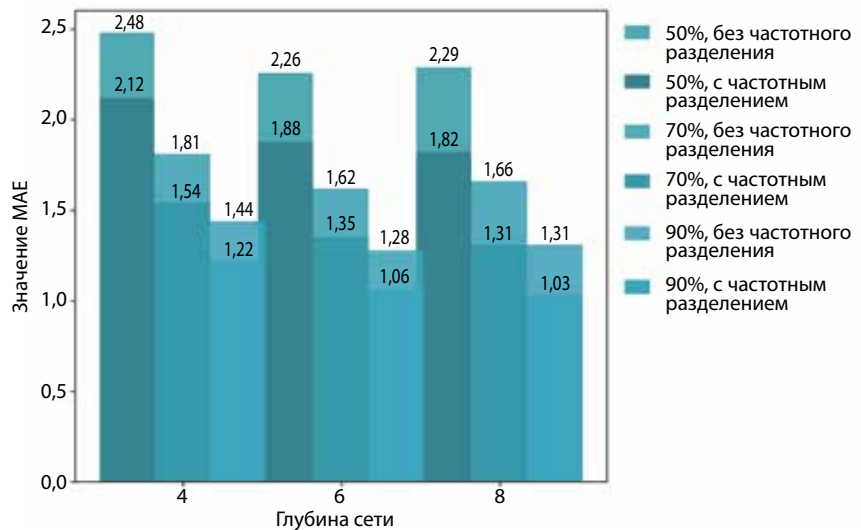


Рис. 2. Влияние гиперпараметров модели CNN на точность прогнозирования

Fig. 2. Impact of the convolutional neural network model hyperparameters on the forecast accuracy

частой фациальной изменчивостью состава углевмещающих отложений и локальным привносом терригенного материала (табл. 4).

Анализ 3D-распределения прогнозных значений влажности и теплоты сгорания углей на ряде месторождений позволил выявить некоторые общие закономерности их изменения в пространстве (рис. 3). Участки с повышенной влажностью углей, как правило, тяготеют к периферийным частям месторождений, характеризующимся относительно невысокой степенью катагенетической преобразованности ОВ.

Интересные результаты получены при сопоставлении прогнозных карт различных свойств углей на одной площади. В частности, установлена устойчивая положительная корреляция между содержанием серы и влаж-

Изменение зольности углей и геофизических параметров по мощности пластов основных месторождений Печорского бассейна

Variation of the coal ash content and geophysical parameters with respect to the coal bed thickness in the main deposits of the Pechora Basin

| Месторождение | Пласт | Границы пласта, м | | Мощность, м | | Зольность A^d , % | | ГК, мкР/ч | | КС, Ом·м | |
|-------------------|-------|-------------------|-------|-------------|--------|---------------------|--------|-----------|--------|----------|--|
| | | Кровля | Почва | Почва | Кровля | Почва | Кровля | Почва | Кровля | | |
| Воркутское | h8 | 712,4 | 718,6 | 6,2 | 14,2 | 9,8 | 6,4 | 5,2 | 128 | | |
| | h7 | 728,1 | 732,3 | 4,2 | 15,6 | 11,4 | 7,1 | 5,6 | 117 | | |
| | h6 | 746,8 | 749,2 | 2,4 | 18,4 | 13,9 | 8,3 | 6,8 | 92 | | |
| Интинское | 11 | 315,6 | 321,8 | 6,2 | 8,2 | 11,4 | 4,8 | 5,6 | 214 | | |
| | 8 | 336,2 | 339,1 | 2,9 | 6,7 | 9,3 | 4,2 | 5,1 | 238 | | |
| Нижнесыръягинское | 14 | 224,8 | 228,2 | 3,4 | 16,8 | 12,3 | 7,6 | 6,1 | 107 | | |
| | 12 | 238,4 | 241,6 | 3,2 | 18,2 | 13,1 | 8,1 | 6,4 | 98 | | |
| | 8 | 261,7 | 264,5 | 2,8 | 19,7 | 14,6 | 8,7 | 7,2 | 87 | | |
| Усинское | 6 | 412,5 | 417,2 | 4,7 | 12,6 | 10,2 | 5,9 | 5,4 | 142 | | |
| | 4в | 428,1 | 431,4 | 3,3 | 10,8 | 9,1 | 5,2 | 4,8 | 169 | | |




Рис. 3. Корреляция между влажностью и содержанием серы в углях различных бассейнов

Fig. 3. A correlation between moisture and sulfur content in coals of different basins

С другой стороны, для углей Южно-Якутского бассейна характерна отрицательная корреляция между W_a и Sdt ($r_s = -0,54$), что указывает на сингенетичность накопления серы и последующее удаление влаги в ходе метаморфизма (табл. 5).

Карты пространственного распределения модельных показателей качества углей хорошо согласуются с данными о геотектоническом строении и истории геологического развития регионов. Аномальные значения зольности, сернистости и влажности углей приурочены к зонам тектонических нарушений, участкам развития эксплозивного вулканизма, областям аллювиального и морского осадконакопления.

Важное прикладное значение имеет оценка достоверности построенных прогнозных карт. С этой целью была проведена серия сопоставлений модельных данных с результатами последующего бурения и опробования углей на ряде участков (табл. б).

ностью углей Днепровско-Донецкого бассейна (коэффициент корреляции Спирмена – 0,68). Это можно объяснить приуроченностью сернистых углей к восстановительным торфяным фациям с повышенным содержанием влаги.

строенных прогнозных карт. С этой целью была проведена серия сопоставлений модельных данных с результатами последующего бурения и опробования углей на ряде участков (табл. б).

Корреляция между влажностью и содержанием серы в углях некоторых бассейнов и месторождений

A correlation between moisture and sulfur content in coals of some basins and fields

| Бассейн / месторождение | Число проб | W_a , % | | | Sdt , % | | | Коэффициент корреляции Спирмена r_s (W_a vs Sdt) |
|-------------------------|------------|-----------|-------|-------|-----------|-------|-------|--|
| | | Мин. | Сред. | Макс. | Мин. | Сред. | Макс. | |
| Днепровско-Донецкий | 184 | 1,2 | 5,6 | 14,8 | 0,8 | 2,4 | 6,2 | 0,68 |
| Львовско-Волынский | 92 | 2,8 | 7,4 | 16,5 | 1,6 | 3,8 | 8,1 | 0,59 |
| Южно-Якутский | 147 | 0,4 | 2,1 | 6,7 | 0,2 | 0,6 | 1,8 | -0,54 |
| Кузнецкий | 326 | 0,8 | 3,6 | 10,2 | 0,3 | 0,9 | 2,6 | -0,38 |
| Минусинский | 85 | 3,4 | 8,2 | 17,4 | 0,6 | 1,8 | 4,3 | -0,12 |
| Иркутский | 112 | 1,6 | 4,9 | 12,3 | 0,5 | 1,4 | 3,7 | 0,21 |
| Улуг-Хемский | 68 | 2,2 | 6,5 | 15,1 | 0,9 | 2,1 | 5,6 | 0,46 |

Таблица 6

Сопоставление прогнозных и фактических параметров качества углей на некоторых участках

A comparison of predicted and actual coal quality parameters in some areas

| Участок | Пласт | Параметр | Прогноз | Факт | Отклонение, % |
|------------------|-------|----------------------|---------|------|---------------|
| Никольский | m4 | $A_{cp}^d, \%$ | 22,6 | 23,4 | -3,4 |
| | | $W_a, \%$ | 8,4 | 7,9 | +6,3 |
| | | $Q_y, \text{МДж/кг}$ | 21,2 | 20,6 | +2,9 |
| Вьюнский | k12 | $A_{cp}^d, \%$ | 15,8 | 16,3 | -3,1 |
| | | $S_{td}, \%$ | 1,2 | 1,4 | -14,3 |
| | | $W_a, \%$ | 5,6 | 6,1 | -8,2 |
| Владимировский | l1 | $A_{гр}^d, \%$ | 31,4 | 34,8 | -9,8 |
| | | $W_a, \%$ | 10,3 | 9,6 | +7,3 |
| | | $V^{daf}, \%$ | 35,8 | 37,2 | -3,8 |
| Павловский | n8 | $S_{dt}, \%$ | 2,1 | 2,4 | -12,5 |
| | | $W_a, \%$ | 12,6 | 13,2 | -4,5 |
| | | $Q_y, \text{МДж/кг}$ | 18,4 | 17,9 | +2,8 |
| Малосырьягинский | m6 | $A_{cp}^d, \%$ | 8,2 | 7,7 | +6,5 |
| | | $S_{dt}, \%$ | 0,6 | 0,4 | +50,0 |
| | | $Q_y, \text{МДж/кг}$ | 24,6 | 25,1 | -2,0 |

Средняя относительная погрешность прогноза зольности, влажности и теплоты сгорания составила 5-10%, для содержания серы этот показатель несколько выше – до 15-20% (табл. 7, 8).

Использование этой информации обеспечивает повышение эффективности прогнозирования и поисков участков с оптимальными технологическими свойствами углей, способствуя рационализации процессов их добычи и переработки.

Таблица 7

Кластеризация углей по комплексу технологических свойств (факт)

Clustering of coals according to the complex of technological properties (actual)

| Класс | Центры кластеров | | | |
|-------|------------------|--------------|-----------|----------------------|
| | $A_{cp}^d, \%$ | $S_{dt}, \%$ | $W_a, \%$ | $Q_y, \text{МДж/кг}$ |
| 1 | 8,5 | 0,8 | 4,2 | 26,4 |
| 2 | 16,3 | 1,4 | 7,8 | 23,1 |
| 3 | 24,9 | 2,6 | 11,5 | 19,3 |
| 4 | 36,7 | 4,2 | 14,8 | 15,8 |

Таблица 8

Кластеризация углей по комплексу технологических свойств (прогноз)

Clustering of coals according to the complex of technological properties (forecast)

| Класс | Центры кластеров | | | |
|-------|------------------|--------------|-----------|----------------------|
| | $A_{cp}^d, \%$ | $S_{dt}, \%$ | $W_a, \%$ | $Q_y, \text{МДж/кг}$ |
| 1 | 9,1 | 1,0 | 4,6 | 25,7 |
| 2 | 17,2 | 1,6 | 8,3 | 22,4 |
| 3 | 26,4 | 2,9 | 12,1 | 18,5 |
| 4 | 38,6 | 4,8 | 15,4 | 14,9 |

ЗАКЛЮЧЕНИЕ

Проведенное исследование продемонстрировало высокую эффективность применения сверточных нейронных сетей с блоками автостройки пулинга и частотного разделения для прогнозирования ключевых технологических свойств углей по комплексу геологических данных. Разработанная модель обеспечивает точность предсказания зольности, влажности и теплоты сгорания на уровне 5-10%, содержания серы – 10-15% относительно фактических значений. Использование механизмов адаптивного пулинга и частотной декомпозиции входных данных позволило повысить качество прогноза на 15-20% по сравнению с базовой архитектурой СНС.

Список литературы • References

1. Киряева Т.А. Разработка методов энергетического анализа и прогнозирования газодинамической активности углемета-

новых пластов Кузбасса. Riga, Latvia: LAP LAMBERT Academic Publishing, 2019. 332 с.

2. Горная информатика и проблема «больших данных» в построении комплексных мониторинговых систем безопасности недропользования / И.В. Бычков, Д.Я. Владимиров, В.Н. Опарин и др. // ФТПРПИ. 2016. № 6. С. 163 -179.
Bychkov I.V., Vladimirov D.Ya., Oparin V.N., Potapov V.P., Shokin Yu.I. Mining informatics and the issue of Big Data in the construction of integrated monitoring systems for the safety of subsoil use. *Fiziko-tehnicheskie problemy razrabotki poleznykh iskopaemykh*. 2016;(6):163-179. (In Russ.).

3. Петров А., Доан Т.Л. Процессы моделирования месторождений рудных полезных ископаемых с использованием ГГИС Micromine // Молодежный вестник ИрГТУ. 2020. № 10(1). С. 12-18.
Petrov A.V., Doan Thi Lam. Processes for modeling ore mineral deposits using the Micromine mining and geological information system. *Molodezhnyj vestnik IrGTU*. 2020;(1):12-18. (In Russ.).
4. Третьякова О.Г., Третьяков М.Ф., Третьяков Ф.Ф. Построение геологической каркасной модели правобережья р. Кюрбелях (Томпонский полигон СВФУ) в ГГИС Майкромайн // Вестник Северо-Восточного федерального университета им. М.К. Аммосова. Серия: Науки о Земле. 2021. № 4(24). С. 44-52.
Tretyakova O.G., Tretyakov M.F., Tretyakov F.F. Construction of a geological wireframe model of the right bank of the Kurbelyakh river (Tomponsky training ground of NEFU) in GIS Micromine. *Vestnik Severo-Vostochnogo federal'nogo universiteta imeni M.K. Ammosova*. 2021;(24):44-52. (In Russ.).
5. Макаров И.В., Пронский В.А. Опыт использования горно-геологической системы Micromine при оценке экономической эффективности отработки Горевского свинцово-цинкового месторождения // Журнал Сибирского федерального университета. Серия: Техника и технологии. 2013. № 6(4). С. 374-386.
Makarov I.V., Pronskiy V.A. The experience of using mining and geological information system Micromine for estimation the economic efficiency of extraction Gorevskoe Pb-Zn deposit. *Zhurnal Sibirskogo federal'nogo universiteta. Seriya: Tehnika i tehnologij*, 2013;(6):374-386. (In Russ.).
6. Маниковский П.М., Васютин Л.А., Сидорова Г.П. Методика моделирования рудных месторождений в ГГИС. // Вестник Забайкальского государственного университета. 2021. № 27(2). С. 6-14. DOI: 10.21209/2227-9245-2021-27-2-6-14.
Manikovskiy P.M., Vasyutich L.A., Sidorova G.P. Methodology for modeling ore deposits in the GIS Micromine. *Vestnik Zabajkalskogo gosudarstvennogo universiteta*. 2021;(2):6-14. (In Russ.). DOI: 10.21209/2227-9245-2021-27-2-6-14.
7. Shehu A., Lipo S. 3D modeling and interpretation of Fe/Ni deposit in Skroska Mine using Micromine. *Albanian Journal of Natural and Technical Sciences*. 2016;(21):47-60.
8. Новопашин А.В., Трушевская М.Э. Моделирование коренных месторождений алмазов Западной Якутии в горно-геологической информационной системе Micromine // Геология, геоэкология и ресурсный потенциал Урала и сопредельных территорий. 2018. № 6. С. 163-166.
Novopashin A.V., Trushevskaya M.E. Modeling of primary diamond deposits of Western Yakutia in the Micromine mining and geological information system. *Geologiya, geoecologiya i resursnyj potentsial Urala i sopredelnykh territorij*. 2018;(6):163-166. (In Russ.).
9. Алгоритм проектирования карьеров в горнодобывающем производстве средствами ГГИС Micromine / А. Наумов, А.О. Петрова, Д.А. Днепровская и др. / Инновационные технологии в технике и образовании: Материалы XIII Международной научно-практической конференции, Чита, 14-15 декабря 2021 года. Чита: Забайкальский государственный университет, 2021. С. 325-332.
10. Использование экономических показателей в методике среднего-срочного планирования горных работ в горно-геологической информационной системе Micromine. / А.В. Проценко, Ж.Б. Байров, Г.С. Федотов и др. // Горный информационно-аналитический бюллетень (научно-технический журнал). 2018. № 8. С. 208-216.
Protsenko A.V., Bayrov Zh.B., Fedotov G.S., Zartenova L.G. Use of economic indicators in medium-term mine planning in Geological and Mining Information System Micromine. *Gornyj informatsionno-analiticheskij byulleten'*. 2018;(8):208-216. (In Russ.).
11. Швачко Е.В., Хрюкин В.Т., Сизиков Д.А., Абарбанель Е.Г. 2019. Особенности методики разведки метаноугольных месторождений. Новые идеи в науках о Земле: Материалы XIV Международной научно-практической конференции. Т. 5, С. 228-230.
12. Плакиткин Ю.А., Плакиткина Л.С., Дьяченко К.И. Прогноз развития мирового и отечественного рынка угля под воздействием тенденции «зеленой энергетики» и санкционных ограничений // Уголь. 2023. № 8. С. 66-71. DOI: 10.18796/0041-5790-2023-866-71.
Plakitkin Yu.A., Plakitkina L.S., Dyachenko K.I. Forecast of global and domestic coal market development under the impact of green energy trends and sanctions restrictions. *Ugol'*. 2023;(8):66-71. (In Russ.). DOI: 10.18796/0041-5790-2023-8-66-71.
13. Дабиев Т.Ф., Чупикова С.А., Чульдум А.Ф. Оценка различных сценариев освоения месторождений полезных ископаемых региона // Горная промышленность. 2021. № 6. С. 99-102.
Dabiev T.F., Chupikova S.A., Chuldum A.F. Assessment of various scenarios for the development of mineral deposits in the region (as exemplified by the Republic of Tyva). *Gornaya promyshlennost'*. 2021;(6):99-102. (In Russ.).
14. Шулятьева Л.И., Майорова Л.В. Моделирование параметров и организация процесса дегазации выемочных полей угольных шахт // Горный информационно-аналитический бюллетень (научно-технический журнал). 2022. № 8. С. 168-179.
Shulyatieva L.I., Mayorova L.V. Parametric modeling and arrangement of gas drainage in coal mines. *Gornyj informatsionno-analiticheskij byulleten'*. 2022;(8):168-179. (In Russ.).

Authors Information

Krasyukova N. – Federal State Educational Budgetary Institution of Higher Education Financial University under the Government of the Russian Federation, Moscow, 125993, Russian Federation, e-mail: NLKrasyukova@fa.ru

Voronova E. – Federal State Educational Budgetary Institution of Higher Education Financial University under the Government of the Russian Federation, Moscow, 125993, Russian Federation, e-mail: ElShayuk@fa.ru

Muravleva T.V. – Doctor of Economic Sciences, Professor, Head of the Department of Economics, Federal State Budgetary Educational Institution of Higher Education "Saratov State Law Academy", Saratov, 410056, Russian Federation, e-mail: Tanyam.07@mail.ru

Imamov M. – Center for Advanced Economic Research of the Academy of Sciences of the Republic of Tatarstan, Kazan, 420111, Russian Federation, e-mail: i@cool921815.ru

Stepanov A.A. – Doctor of Economic Sciences, Professor, Professor Department of Innovation Management, Federal State Educational Budgetary Institution of Higher Education "Moscow State Institute of International Relations (University) of the Ministry of Foreign Affairs of the Russian Federation", Odintsovo Branch, 143007, Odintsovo, Moscow Region, Russian Federation, e-mail: info@odin.mgimo.ru

Информация о статье

Поступила в редакцию: 6.06.2024

Поступила после рецензирования: 16.06.2024

Принята к публикации: 25.06.2024

Paper info

Received June 6, 2024

Reviewed June 16, 2024

Accepted June 25, 2024