ГИАБ. Горный информационно-аналитический бюллетень /
MIAB. Mining Informational and Analytical Bulletin, 2023;(8):5-17
ОРИГИНАЛЬНАЯ СТАТЬЯ / ORIGINAL PAPER

УДК 550.8.053 DOI: 10.25018/0236_1493_2023_8_0_5

СОЗДАНИЕ МОДЕЛИ РАСПРЕДЕЛЕНИЯ ПОЛЕЗНОГО КОМПОНЕНТА В ЖЕЛЕЗОРУДНОМ МЕСТОРОЖДЕНИИ

А.А. Кожухов[1], Д.Р. Омельченко[1], И.А. Мельниченко[1], В.В. Ческидов[1], В.В. Мосейкин[1]

[1] НИТУ «МИСиС», Москва, Россия, e-mail: kozhuh@inbox.ru

Аннотация: Инструментарий современных горно-геологических информационных систем позволяет производить построение каркасных и блочных моделей месторождений полезных ископаемых. Однако часть этапов создания моделей остается неавтоматизированной, что определяет необходимость достаточно большого количества времени для обновления моделей при получении новой или дополнительной информации. Разработанный метод построения трехмерной модели месторождения на основе искусственных нейронных сетей позволяет осуществить построение модели месторождения и количественно оценивать распределение полезного компонента в автоматизированном режиме с применением искусственных нейронных сетей (ИНС). На примере железорудного месторождения рассмотрено построение литологической модели месторождения, на основе которой затем была построена модель распределения полезного компонента в рудных телах. Обучение ИНС производилось на основании данных, полученных на стадии геологической разведки с применением стандартных методик. Структура сети была определена эмпирически с учетом отечественного и зарубежного опыта применения нейросетевых методов для обработки геологических данных. Оценка достоверности полученных моделей осуществлялась с использованием методов кросс-валидации. Полученные результаты показывают хорошую сходимость смоделированных данных и данных контрольных выборок. Следует отметить, что развитие предлагаемого метода построения моделей месторождений полезных ископаемых может найти широкое применение на стадии поисков, а также на предварительных стадиях разведки, в условиях, когда данных о составе и строении месторождений мало, но при этом требуется оперативная их обработка.

Ключевые слова: горное дело, железорудное месторождение, геологическое обеспечение недропользования обработка данных, геоинформатика, нормирование данных, рудное тело, нейронные сети, цифровое месторождение.

Для цитирования: *Кожухов А. А., Омельченко Д. Р., Мельниченко И. А., Ческидов В. В., Мосейкин В. В.* Создание модели распределения полезного компонента в железорудном месторождении // Горный информационно-аналитический бюллетень. – 2023. – № 8. – С. 5–17. DOI: 10.25018/0236_1493_2023_8_0_5.

Modeling mineral component distribution in iron ore deposits

A.A. Kozhukhov[1], D.R. Omelchenko[1], I.A. Melnichenko[1], V.V. Cheskidov[1], V.V. Moseykin[1]

[1] National University of Science and Technology «MISiS», Moscow, Russia,
e-mail: kozhuh@inbox.ru

© А.А. Кожухов, Д.Р. Омельченко, И.А. Мельниченко, В.В. Ческидов, В.В. Мосейкин. 2023.

Abstract: The modern geological information system tools make it possible to construct frame-like and block-like models of mineral deposits. However, some modeling stages remain yet manual, which conditions much time to be spent to update the models when new or additional information arrives. The developed method of three-dimensional modeling of mineral deposits using artificial neural networks enables the automated modeling and quantitative valuation of mineral component distribution. A lithological model of an iron ore deposit was constructed and used to model mineral component distribution in ore bodies. The artificial neural network learning used the data of standard geological exploration. The network structure was determined empirically, with regard to domestic and foreign experience of using the neural networks for geological data processing. The reliability of the models was evaluated using the methods of cross-validation. The results show good agreement of the model data and test samples. The proposed method of mineral deposit modeling may find wide application at the stages of prospecting and preliminary exploration, when the data on composition and structure of a deposit are few but need prompt processing.

Key words: mining, iron ore deposit, geological feasibility study of subsoil use, data processing, geoinformation science, data rating, ore body, neural networks, digital deposit.

For citation: Kozhukhov A. A., Omelchenko D. R., Melnichenko I. A., Cheskidov V. V., Moseykin V. V. Modeling mineral component distribution in iron ore deposits. *MIAB. Mining Inf. Anal. Bull.* 2023;(8):5-17. [In Russ]. DOI: 10.25018/0236_1493_2023_8_0_5.

Введение

Существующие методы построения трехмерных моделей полезных ископаемых не позволяют динамично производить переоценку содержания полезного компонента по результатам опробования, произведенного в процессе эксплуатационной разведки. Основной проблематикой является не полностью автоматизированный процесс ввода данных, а также построения каркасных моделей [1 — 3] с использованием условного моделирования и для последующего создания блочной модели и оценки содержания полезного компонента в отдельных блоках. Все перечисленных факторы влияют на формирование технологической карты процессов и планов отработки месторождения с последующим извлечением максимальной экономической прибыли.

Исходя из этого, был разработан инструментарий на основе искусственных нейронных сетей [4 — 5], позволяющий автоматизировать такие процессы, как интерпретация полученных геологоразведочных данных в результате опробования в динамично формируемую блочную модель месторождения полезного ископаемого (ПИ), включающий в себя атрибуты литологической разности и содержания полезного компонента. Данных инструментарий обладает такими преимуществами, как возможность оценки границ литологических разностей в межскважинном пространстве, оценка качественно-количественных показателей параметров рассчитанного полезного компонента в рудном теле.

Архитектура разработанного программного обеспечения

Разработанное программное обеспечение представляет из себя web-приложение с клиент-серверной архитектурой [6]. Клиентом приложения выступает веб-браузер, код для которого написан на языке программирования typescript,

с использованием технологий html и css. Серверная часть программного обеспечения создана на технологиях Node.js. Между клиентской частью и серверами приложения располагается Nginx-сервер, который выступает в роли прокси-сервера для распределения запросов. Для хранения данных приложения используется реляционная база данных Postgres, модель которой отображена на рис. 1.

Таблицы базы данных и краткое их описание:

- deposits — таблица для хранения сущности «месторождение». В ней хранятся название месторождения и угол смещения полюса;
- deposit_borders — таблица для хранения границ месторождения, в рамках которого в дальнейшем будет строится блочная модель. Границы определяются по минимальным и максимальным координатам опробованных скважин;
- rocks — таблица для хранения всех литологических разностей месторождения, выявленных в результате опробования скважин. В процессе записи данных каждой породе присваивается определенный цвет;
- wells — таблица хранит информацию об опробованных скважинах, такую как пространственные координаты устья, наименование скважины, принадлежность к определенному месторождению и координаты окончания скважины;
- well_intervals — в процессе парсинга файла месторождения каждая скважина по данным опробования и инклино-

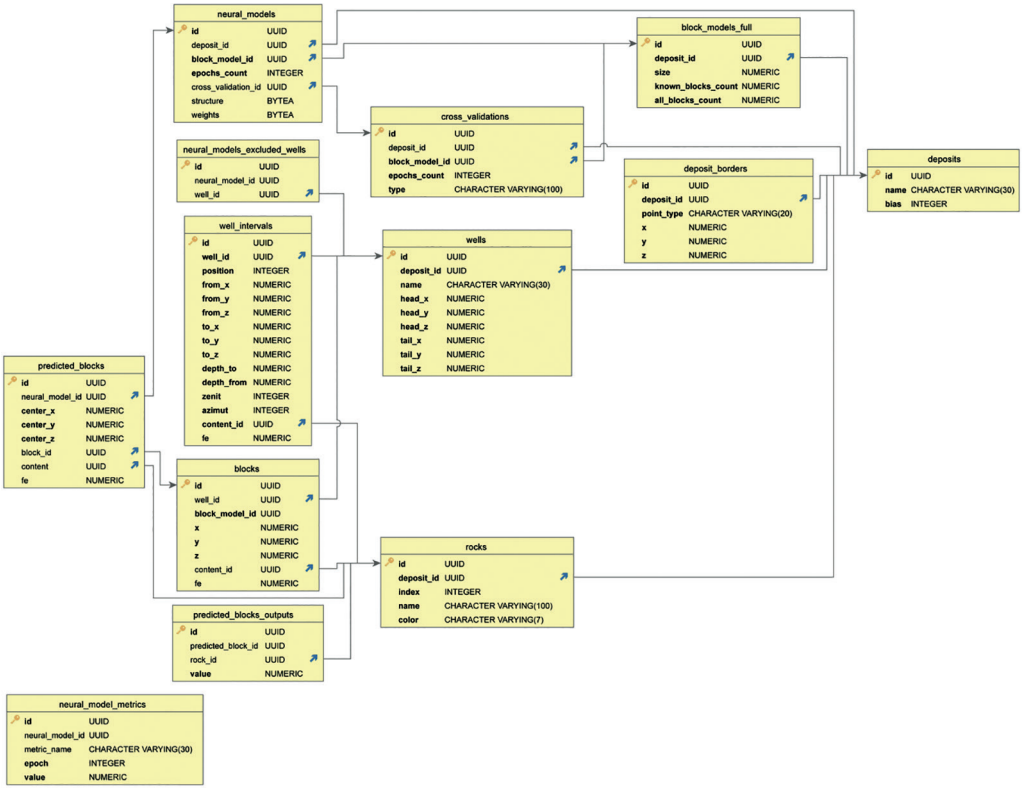

Рис. 1. Модель базы данных
Fig. 1. Database model

метрии разбивается на интервалы в виде отрезка, каждый из которых имеет свои параметры, такие как принадлежность к скважине, пространственные координаты, углы наклона, литология и опробование по полезному компоненту;

• block_model_full — кратная информация о блочной модели месторождения: размер блоков, на которые разбивается месторождение, количество блоков во всей блочной модели и количество блоков, параметры которых известны по результатам опробования;

• blocks — в этой таблице хранится информация о блоках, параметры которых известны по результатам опробования;

• neural_models — таблица хранит информацию о созданных искусственных нейронных сетях: на основе какой блочной модели она обучалась, параметры обучения, а также ее структура в виде бинарного файла и веса, полученные после процесса обучения. Также хранится информация, создавалась ли нейронная сеть в процессе кросс-валидации;

• neural_models_metrics — хранится информация о метриках, полученных в процессе обучения нейронных сетей. Каждая метрика сохраняется для каждой эпохи обучения;

• cross_validations — таблица для хранения информации по каждой кросс-валидации;

• neural_models_exluded_wells — в процессе кросс-валидации все множество блоков разбивается на тренировочную и контрольную выборки. В этой таблице хранится информация о скважине, блоки которой были исключены из обучения нейронной сети и включены в контрольную выборку;

• predicted_blocks — таблица для хранения блоков, предсказанных искусственной нейронной сетью;

• predicted_blocks_outputs — таблица для хранения значений, полученных на выходе нейронной сети в процессе предсказания.

Логика работы программного обеспечения

Весь пользовательский путь для получения модели полезного компонента месторождения показан на рис. 2.

Исходными данными для работы служат результаты опробования, на основе керновых или шламовых проб, записанные в файле формата excel. В нем хранится информация об устье скважин (северная и восточная координаты, а также абсолютная отметка), результаты инклинометрии, проведенной в скважинах, а также результаты опробования по литологии и содержанию полезного компонента. При загрузке файла в программное обеспечение происходит валидация хранящихся в нем данных на их корректную заполненность. Если приложение выявляет ошибки, которые не позволяют дальнейшее исполнение программы, пользователю необходимо исправить ошибки в ручном режиме. Если все данные корректные, на основе файла заполняются такие таблицы базы данных, как deposits, deposit_borders, rocks, wells, well_intervals. Для дальнейшей работы пользователю необходимо задать размер блока, по которому будет создаваться пустая блочная модель в границах месторождения [1, 7]. Известным в процессе опробования блокам автоматически присвоятся соответствующие параметры.

Подготовка данных для ИНС

Полученные блоки с известными параметрами будут служить исходными данными для обучения нейронной сети. Каждый блок обладает такими параметрами, как координаты в пространстве, литология и процентное содержание полезного компонента. Для корректной работы ИНС все данные нормализуются в интервале от 0 до 1 по формуле

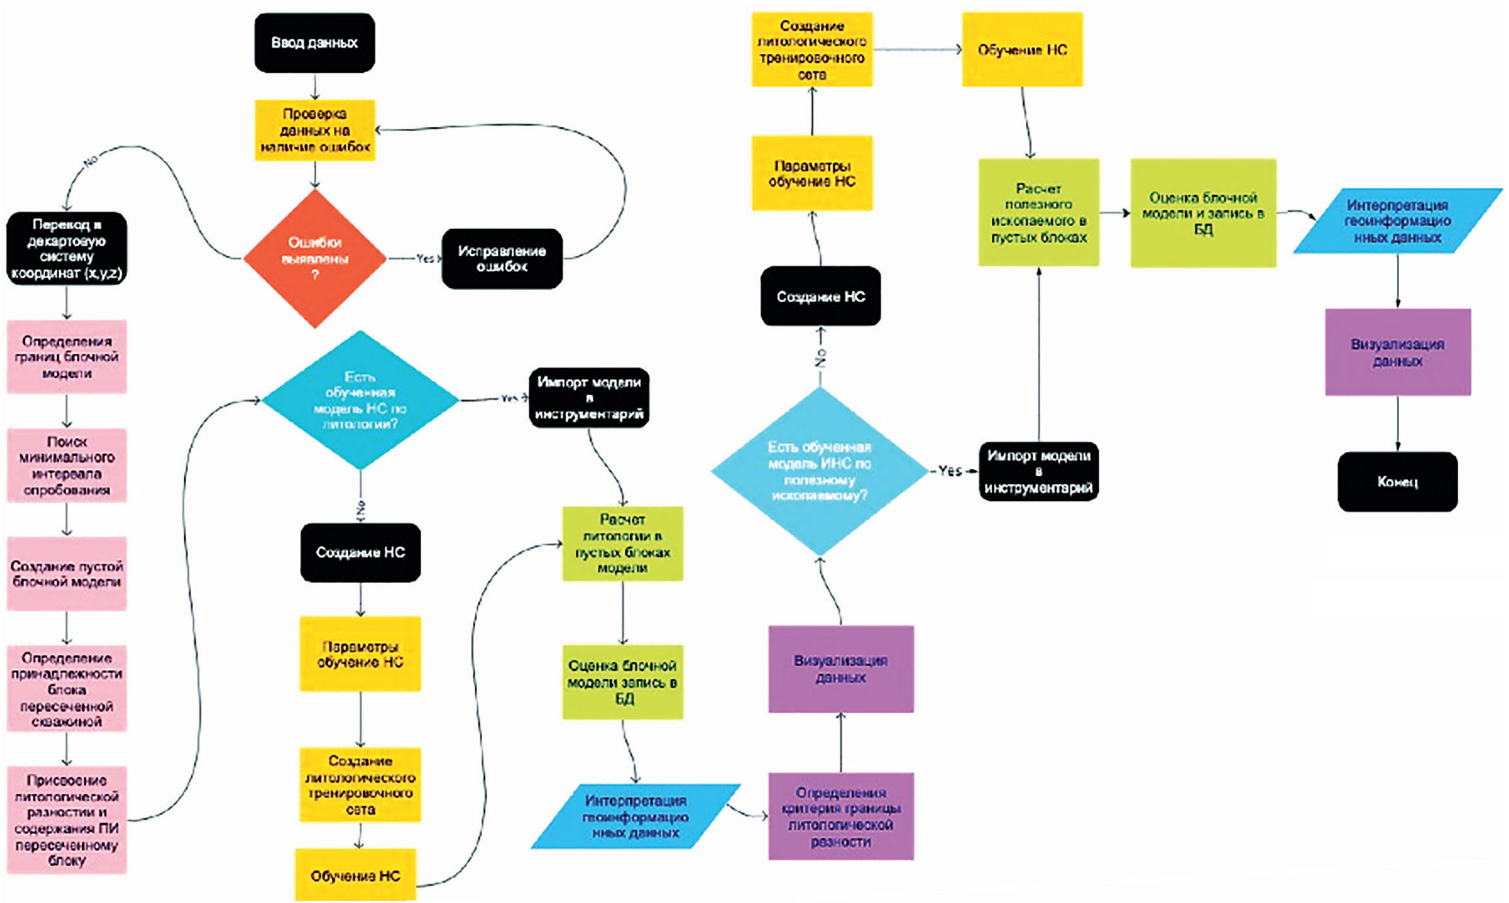

Рис. 2. Логика работы инструментария для построения и оценки блочной модели месторождения на основе нейронных сетей
Fig. 2. The logic of the tools for building and evaluating a block model of a deposit based on neural networks

$$x_{norm} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}},$$

где x_{norm} — нормализованное значение; x_{min} — минимальное значение из всей выборки; x_{max} — максимальное значение из всей выборки; x_i — значение для нормализации.

Литологическая разность, изначально представленная строковым значением, кодируется вектором длиной n, где n — количество известных литологических разностей во всем месторождении. Каждому значению вектора соответствует определенная литологическая разность, поэтому вектор имеет все нулевые значения, кроме одного, которому присваивается единица, обозначающая наличие соответствующей литологической разности.

Для последующего декодирования данных применяется следующая формула:

$$x_i = x_{\min} + x_{norm} * \left(x_{\max} - x_{\min}\right),$$

где x_{norm} — нормализованное значение; x_i — денормализованное значение; x_{min} — минимальное значение из всей выборки до нормализации; x_{max} — максимальное значение из всей выборки до нормализации.

Литологическая модель месторождения

Предварительным этапом для построения модели содержания полезного компонента является построение литологической модели месторождения. Задача определения литологической разности в блоке является классической для нейронных сетей задачей классификации [8]. Для этих целей методом подбора, с целью минимизации ошибки предсказания, была выбрана ИНС со следующей структурой: входной слой состоит из трех нейронов, на который поочередно будут подаваться координаты известных блоков, выходной слой состоит из n нейронов, где n — количество известных литологических разностей в месторождении, что позволяет кодировать строковое значение литологической разности [1, 8, 9] и четыре скрытых слоя. Первый слой имеет 64 нейрона и функцию активации гиперболический тангенс, второй и третий слои состоят из 64 нейронов без функций активации, четвертый слой имеет 32 нейрона и имеет сигмоидную функцию активации. Выбранные нами функции активации хорошо показали себя для решения задач классификации [8—10]. Обучение ИНС проходило на 1000 эпохах, так как на этом значении ви-

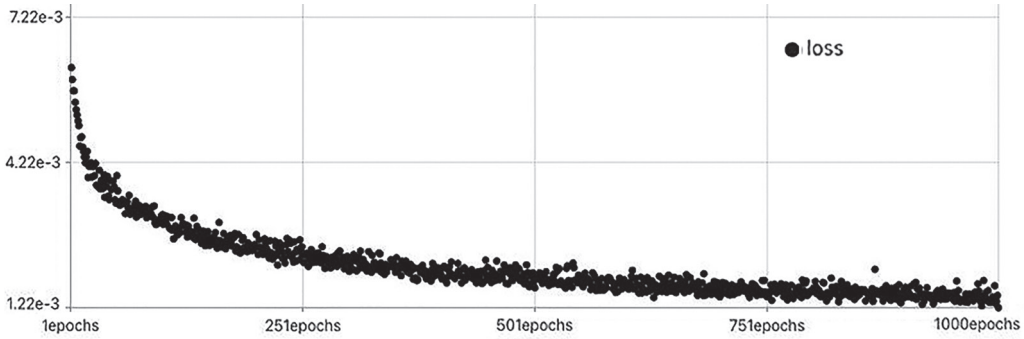

Рис. 3. Зависимость метрики потерь при обучении ИНС от количества эпох обучения: по оси x — количество эпох обучения, по оси y — значение метрики потери при обучении

Fig. 3. Dependence of the artificial neural network training loss metric on the number of training epochs, on the x-axis — the number of training epochs, on the y-axis — the value of the training loss metric

зуально видно, что метрика потерь ИНС [11 — 13] перестает уменьшаться (рис. 3).

Обученную на известных блоках ИНС можно использовать для построения блочной литологической модели месторождения. Поочередно подав на вход координаты блоков из блочной модели, на выходе мы получим вектор длиной *n*, каждому значению которого соответствует определенная порода. Максимальное из всех значений будем считать предсказанием ИНС литологии по заданному блоку.

Оценка литологической модели

Для оценки результатов ИНС используется метод кросс-валидации. Все множество известных блоков месторождения делится на тренировочный и контрольный сеты. Известные блоки из *k*–1 скважин, где *k* — общее количество скважин по месторождению, попадают в тренировочный сет, на котором обучается ИНС, а блоки, принадлежащие к оставшейся скважине — в контрольный сет. После обучения на тренировочном сете на вход ИНС подаются блоки из контрольного сета и получается предсказание ИНС. Результаты предсказания сравниваются с исходными значениями по этой скважине и считается ошибка путем нахождения процента неправильно предсказанных блоков к общему количеству изначально известных блоков в скважине.

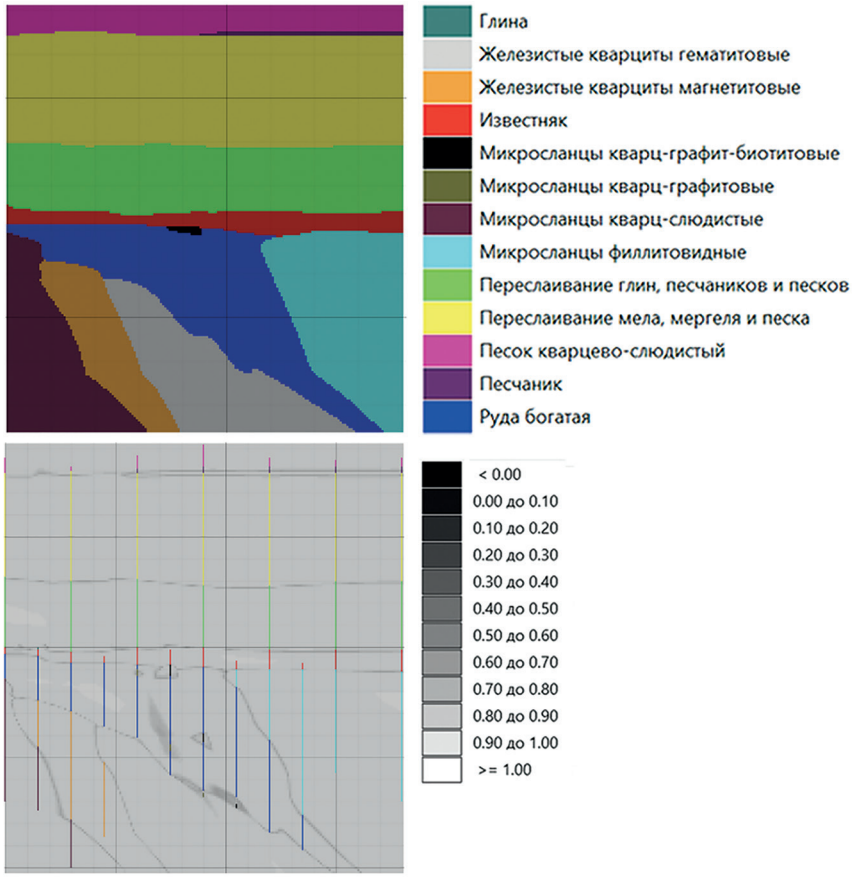

Рис. 4. Литологический разрез, полученный с помощью ИНС
Fig. 4. Lithological section obtained using artificial neural network

При повторе данной операции *k* раз получается ошибка для каждой из скважин. На рис. 4 показан один из литологических разрезов, полученный с помощью ИНС: слева отображены предсказанные литологические разности, а справа скважины, полученные в результате опробования.

Как видно из результатов, ИНС показывает хорошую сходимость между изначальными и предсказанными блоками. Сравнив каждый блок, полученный в результате кросс-валидации, с соответствующим ему изначальным блоком, высчитываем ошибку работы ИНС. Использовав данный метод оценки, средняя ошибка моделирования в межскважинном пространстве составляет 14,91%. При сравнении каркасного моделирования и разработанного инструментария трехмерного геомоделирования границ литологических разностей железорудных месторождений на основе пространственно-координированных данных было выявлено 97,65% правильно предсказанных блоков по рудному телу.

Модель содержания полезного ископаемого

Полученная на предыдущем этапе литологическая модель месторождения позволяет ИНС более точно улавливать зависимости распределения ПИ, тем самым более точно делать предсказания.

Для построения модели содержания полезного ископаемого была создана новая ИНС со следующей структурой: входной слой состоит из 3+*n* количества нейронов, где *n* — количество известных литологических разностей в месторождении. На вход подаются три координаты блока, а также к входным параметрам добавляется вектор длиной *n* с закодированной литологической разностью блока. ИНС содержит 4 скрытых слоя по 64 нейрона в каждом. На первом и последнем скрытом слое используется функция активации ReLU (Линейный выпрямитель). Данная функция активации исключает отрицательные значения при работе ИНС и допускает область значений в диапазоне [0; +∞). Выходной слой состоит из *m* нейронов,

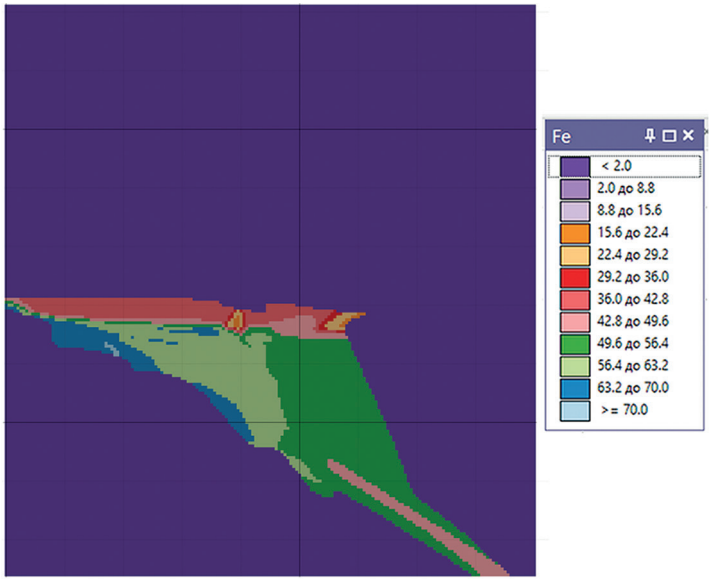

Рис. 5. Распределение ПИ в разрезе рудного тела
Fig. 5. Distribution of minerals in the section of the ore body

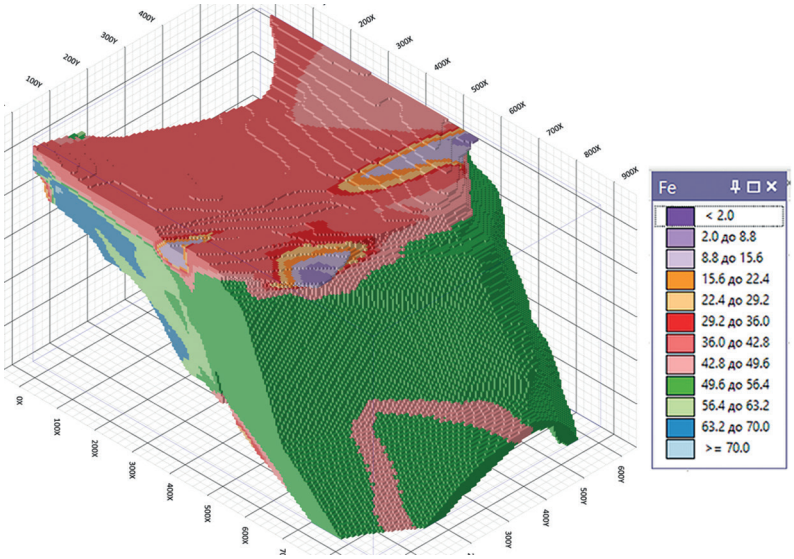

Рис. 6. Распределение ПИ в трехмерной модели рудного тела
Fig. 6. Mineral distribution in a 3D ore body model

где m — количество исследуемых полезных компонентов, в который при обучении ИНС подается содержание полезных ископаемых в блоке в нормализованном также от 0 до 1 виде. Обучение происходит на 1000 эпохах [14—18].

Для построения блочной модели полезного ископаемого блоки на вход нейронной сети подаются из литологической модели месторождения.

На рис. 5 показан один из разрезов распределения ПИ, где разными цветами обозначен интервал процентного содержания ПИ.

На рис. 6 показана трехмерная модель содержания полезного компонен-

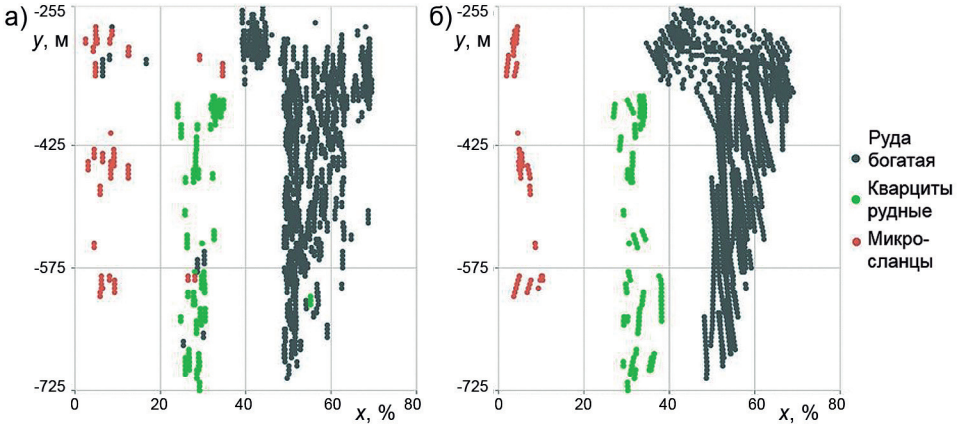

Рис. 7. Сравнение изначального и предсказанного содержания ПИ в скважинах: изначальное известное содержание (а), предсказанное ИНС (б); по оси x – процентное содержание полезного компонента, по оси y – глубина залегания
Fig. 7. Comparison of initial and predicted mineral content in wells: initial known content (a), predicted by artificial neural network (b); along x-axis – percentage of the useful component, along y-axis – depth of occurrence

та, рассчитанная с помощью обученной нейронной сети и визуализированная в горно-геологической информационной системе Micromine.

Оценка модели содержания полезного ископаемого

Оценка содержания ПИ в блоках производилась с помощью кросс-валидации, аналогично с литологической моделью. Сравнивалось содержание в блоках с известным содержанием в результате опробования с соответствующими им блоками, предсказанными ИНС [19—20]. Ошибка варьируется в диапазоне от 1% до 19,7%. Средняя ошибка по блокам составляет 9,6%. На рис. 7 представлена диаграмма распределения ПИ всех скважин в зависимости от координаты *Z*.

Заключение

В данной работе был описан инструментарий для построения блочных моделей, содержащих информацию о литологическом составе руд месторождения, а также содержании полезного компонента на основе ИНС. Результаты показывают, что обученные ИНС могут с определенной точностью делать прогнозы распределения ПИ на основе данных опробования по скважинам. Данный метод построения блочной модели может служить альтернативой традиционным методам построения моделей месторождения, особенно в тех случаях, когда требуется экспресс-построение модели с возможностью дальнейшей ее корректировки.

Ошибку, допускаемую ИНС, можно уменьшать, подбирая более подходящую архитектуру ИНС, количество слоев и нейронов в скрытых слоях, функции активации, а также добавляя новые входные параметры, которые позволят ИНС более четко прослеживать зависимости распределения литологии и ПИ.

СПИСОК ЛИТЕРАТУРЫ

1. *Мельниченко И. А.* Трехмерное геомоделирование границ литологических разностей железорудных месторождений на основе пространственно-координированных данных. Автореф. дис. ... канд. техн. наук. — М.: НИТУ «МИСиС», 2021. — 30 с.

2. *Jalloh A. B., Kyuro S., Jalloh Y., Barrie A. K.* Integrating artificial neural networks and geostatistics for optimum 3D geological block modeling in mineral reserve estimation. A case study // International Journal of Mining Science and Technology. 2016, vol. 26, no. 4, pp. 581—585. DOI: 10.1016/j.ijmst.2016.05.008.

3. *Jiateng Guo, Xulei Wang, Jiangmei Wang, Xinwei Dai, Lixin Wu, Chaoling Li, Fengdan Li, Shanjun Liu, Jessell M. W.* Three-dimensional geological modeling and spatial analysis from geotechnical borehole data using an implicit surface and marching tetrahedra algorithm // Engineering Geology. 2021, vol. 284, article 106047. DOI: 10.1016/j.enggeo.2021.106047.

4. *Melchers H., Crommelin D., Koren B., Menkovski V., Sanderse B.* Comparison of neural closure models for discretised PDEs // Computers & Mathematics with Applications. 2023, vol. 143, pp. 94—107. DOI: 10.1016/j.camwa.2023.04.030.

5. *Мельниченко И. А.*, *Кожухов А. А.*, *Омельченко Д. Р.*, *Мосейкин В. В.* Построение трехмерной модели месторождения с использованием принципов блочного моделирования и искусственных нейронных сетей // Горный информационно-аналитический бюллетень. — 2022. — № 10. — С. 5—19. DOI: 10.25018/0236_1493_2022_10_0_5.

6. *Kulawiak M., Dawidowicz A., Pacholczyk M. E.* Analysis of server-side and client-side Web-GIS data processing methods on the example of JTS and JSTS using open data from OSM and geoportal // Computers & Geosciences. 2019, vol. 129, pp. 26—37. DOI: 10.1016/j.cageo.2019.04.011.

7. *Dhont D., Monod B., Hervouët Y., Backé G., Klarica S., Choy J. E.* 3D geological modeling of the Trujillo block: Insights for crustal escape models of the Venezuelan Andes // Journal of South American Earth Sciences. 2012, vol. 39, pp. 245—251. DOI: 10.1016/j.jsames.2012.04.003.

8. *Мельниченко И. А., Кириченко Ю. В.* Пространственное районирование месторождений полезных ископаемых // Горный информационно-аналитический бюллетень. — 2021. — № 4. — С. 46—56. DOI: 10.25018/0236_1493_2021_4_0_46.

9. *Lazreg M. B., Goodwin M., Granmo O.-C.* Combining a context aware neural network with a denoising autoencoder for measuring string similarities // Computer Speech & Language. 2020, vol. 60, article 101028. DOI: 10.1016/j.csl.2019.101028.

10. *Mohammadzaheri M., Chen L., Ghaffari A., Willison J.* A combination of linear and nonlinear activation functions in neural networks for modeling a de-superheater // Simulation Modelling Practice and Theory. 2009, vol. 17, no. 2, pp. 398—407. DOI: 10.1016/j.simpat.2008.09.015.

11. *Liang Yang, Ling-Xiao Zhao, Chun-Lu Zhang, Bo Gu* Loss-efficiency model of single and variable-speed compressors using neural networks // International Journal of Refrigeration. 2009, vol. 32, no. 6, pp. 1423—1432. DOI: 10.1016/j.ijrefrig.2009.03.006.

12. *Qi Gong, Wei Kang, Fariba Fahroo* Approximation of compositional functions with ReLU neural networks // Systems & Control Letters. 2023, vol. 175, article 105508. DOI: 10.1016/j.sysconle.2023.105508.

13. *Горбатенко В. Д., Ческидов В. В., Якубов М. М.* Моделирование показателей качества поступающего на обогатительную фабрику минерального сырья при разработке Лебединского месторождения железистых кварцитов // Горный журнал. — 2022. — № 6. — С. 15—20. DOI: 10.17580/gzh.2022.06.02.

14. *Ческидов В. В., Барабанов Н. Н., Ложкин М. О., Смирнов П. А., Лагутина А. А.* Анализ закономерностей распределения соединений серы и железа на примере намывных техногенных массивов // Горный информационно-аналитический бюллетень. — 2021. — № 3. — С. 142—153. DOI: 10.25018/0236-1493-2021-3-0-142-153.

15. *Vostrikov A. V., Prokofeva E. N., Goncharenko S. N., Gribanov I. V.* Analytical modeling for the modern mining industry // Eurasian Mining. 2019, no. 2, pp. 30—35. DOI: 10.17580/em.2019.02.07.

16. *Гончаренко С. Н., Бердалиев Б. А.* Методы прогнозирования и оценки техногенного и остаточного скопления урановых руд на месторождениях, отрабатываемых способом подземного скважинного выщелачивания // Горный информационно-аналитический бюллетень. — 2018. — № 5. — С. 43—48. DOI: 10.25018/0236-1493-2018-5-0-43-48.

17. *Стадник Д. А., Стадник Н. М., Жилин А. Г., Лопушняк Е. В.* Методические основы имплицитного моделирования месторождений твердых полезных ископаемых при автоматизированном проектировании // Горный информационно-аналитический бюллетень. — 2023. — № 5-1. — С. 185—197. DOI: 10.25018/0236_1493_2023_51_0_185.

18. *Войтеховский Ю. Л., Захарова А. А., Климоченков М. Д.* Моделирование петрографических структур. Статья 2 // Вестник геонаук. — 2020. — № 12. — С. 32—35. DOI: 10.19110/geov.2020.12.3.

19. *Агафонов В. В., Зайцева Е. В., Яхеев В. В., Снигирев В. В., Гурков А. А.* Имитационное моделирование функциональных структур технологических систем угледобывающих предприятий // Уголь. — 2022. — № 2. — С. 57—60. DOI: 10.18796/0041-5790-2022-2-57-60.

20. *Войтеховский Ю. Л., Захарова В. В.* Моделирование петрографических структур // Вестник геонаук. — 2020. — № 10. — С. 38—42. DOI: 10.19110/geov.2020.10.5. ГИАБ

REFERENCES

1. Mel'nichenko I. A. *Trekhmernoe geomodelirovanie granits litologicheskikh raznostey zhelezorudnykh mestorozhdeniy na osnove prostranstvenno-koordinirovannykh dannykh* [Three-di-

mensional geomodeling of the boundaries of lithological differences of iron ore deposits based on spatially coordinated data], Candidate's thesis, Moscow, NITU «MISiS», 2021, 30 p.

2. Jalloh A. B., Kyuro S., Jalloh Y., Barrie A. K. Integrating artificial neural networks and geostatistics for optimum 3D geological block modeling in mineral reserve estimation. A case study. *International Journal of Mining Science and Technology*. 2016, vol. 26, no. 4, pp. 581—585. DOI: 10.1016/j.ijmst.2016.05.008.

3. Jiateng Guo, Xulei Wang, Jiangmei Wang, Xinwei Dai, Lixin Wu, Chaoling Li, Fengdan Li, Shanjun Liu, Jessell M. W. Three-dimensional geological modeling and spatial analysis from geotechnical borehole data using an implicit surface and marching tetrahedra algorithm. *Engineering Geology*. 2021, vol. 284, article 106047. DOI: 10.1016/j.enggeo.2021.106047.

4. Melchers H., Crommelin D., Koren B., Menkovski V., Sanderse B. Comparison of neural closure models for discretised PDEs. *Computers & Mathematics with Applications*. 2023, vol. 143, pp. 94—107. DOI: 10.1016/j.camwa.2023.04.030.

5. Melnichenko I. A., Kozhukhov A. A., Omelchenko D. R., Moseykin V. V. 3D mineral deposit modeling using concepts of blockmodeling and artificial neural networks. *MIAB. Mining Inf. Anal. Bull.* 2022, no. 10, pp. 5—19. [In Russ]. DOI: 10.25018/0236_1493_2022_10_0_5.

6. Kulawiak M., Dawidowicz A., Pacholczyk M. E. Analysis of server-side and client-side Web-GIS data processing methods on the example of JTS and JSTS using open data from OSM and geoportal. *Computers & Geosciences*. 2019, vol. 129, pp. 26—37. DOI: 10.1016/j.cageo.2019.04.011.

7. Dhont D., Monod B., Hervouët Y., Backé G., Klarica S., Choy J. E. 3D geological modeling of the Trujillo block: Insights for crustal escape models of the Venezuelan Andes. *Journal of South American Earth Sciences*. 2012, vol. 39, pp. 245—251. DOI: 10.1016/j.jsames.2012.04.003.

8. Melnichenko I A., Kirichenko Yu V. Spatial zoning of mineral deposits. *MIAB. Mining Inf. Anal. Bull.* 2021, no. 4, pp. 46—56. [In Russ]. DOI: 10.25018/0236_1493_2021_4_0_46.

9. Lazreg M. B., Goodwin M., Granmo O.-C. Combining a context aware neural network with a denoising autoencoder for measuring string similarities. *Computer Speech & Language*. 2020, vol. 60, article 101028. DOI: 10.1016/j.csl.2019.101028.

10. Mohammadzaheri M., Chen L., Ghaffari A., Willison J. A combination of linear and nonlinear activation functions in neural networks for modeling a de-superheater. *Simulation Modelling Practice and Theory*. 2009, vol. 17, no. 2, pp. 398—407. DOI: 10.1016/j.simpat.2008.09.015.

11. Liang Yang, Ling-Xiao Zhao, Chun-Lu Zhang, Bo Gu Loss-efficiency model of single and variable-speed compressors using neural networks. *International Journal of Refrigeration*. 2009, vol. 32, no. 6, pp. 1423—1432. DOI: 10.1016/j.ijrefrig.2009.03.006.

12. Qi Gong, Wei Kang, Fariba Fahroo Approximation of compositional functions with ReLU neural networks. *Systems & Control Letters*. 2023, vol. 175, article 105508. DOI: 10.1016/j.sysconle.2023.105508.

13. Gorbatenko V. D., Cheskidov V. V., Yakubov M. M. Modeling quality of concentration factory feedstock in ferruginous quartzite mining at the Lebedinskoe deposit. *Gornyi Zhurnal*. 2022, no. 6, pp. 15—20. [In Russ]. DOI: 10.17580/gzh.2022.06.02.

14. Cheskidov V. V., Barabanov N. N., Lozhkin M. O., Smirnov P. A., Lagutina A. A. Distribution of iron and sulfur compounds: A case study of hydraulic waste fills. *MIAB. Mining Inf. Anal. Bull.* 2021, no. 3, pp. 142—153. [In Russ]. DOI: 10.25018/0236-1493-2021-3-0-142-153.

15. Vostrikov A. V., Prokofeva E. N., Goncharenko S. N., Gribanov I. V. Analytical modeling for the modern mining industry. *Eurasian Mining*. 2019, no. 2, pp. 30—35. DOI: 10.17580/em.2019.02.07.

16. Goncharenko S. N., Berdaliev B. A. Methods to predict and estimate residual and technological concentrations of uranium ore in in-situ leaching mining. *MIAB. Mining Inf. Anal. Bull.* 2018, no. 5, pp. 43—48. [In Russ]. DOI: 10.25018/0236-1493-2018-5-0-43-48.

17. Stadnik D. A., Stadnik N. M., Zhilin A. G., Lopushnyak E. V. Methodological framework for implicit modeling of solid mineral deposits in automated design. *MIAB. Mining Inf. Anal. Bull.* 2023, no. 5-1, pp. 185—197. [In Russ]. DOI: 10.25018/0236_1493_2023_51_0_185.

18. Voitekhovsky Yu. L., Zakharova A. A., Klimochenkov M. D. Modeling of petrographic structures. Article 2. *Vestnik of Geosciences*. 2020, no. 12, pp. 32 — 35. [In Russ]. DOI: 10.19110/geov.2020.12.3.

19. Agafonov V. V., Zaitseva E. V., Yakheev V. V., Snigirev V. V., Gurkov A. A. Simulation modeling of functional structures of technological systems of mining enterprises. *Ugol'*. 2022, no. 2, pp. 57 — 60. [In Russ]. DOI: 10.18796/0041-5790-2022-2-57-60.

20. Voitekhovsky Yu. L., Zakharova V. V. Modeling of petrographic structures. *Vestnik of Geosciences*. 2020, no. 10, pp. 38 — 42. [In Russ]. DOI: 10.19110/geov.2020.10.5.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Кожухов Артем Александрович[1] — аспирант,
e-mail: kozhuh@inbox.ru,
ORCID ID: 0000-0002-9137-6315,
Омельченко Денис Русланович[1] — аспирант,
e-mail: omelched@gmail.com,
ORCID ID: 0000-0001-5419-4881,
Мельниченко Илья Ашотович[1] — канд. техн. наук,
ассистент кафедры, e-mail: kors-ilay@mail.ru,
ORCID ID: 0000-0002-0205-6425,
Ческидов Василий Владимирович[1] — канд. техн. наук,
доцент, заместитель директора Горного института,
e-mail vcheskidov@misis.ru,
Мосейкин Владимир Васильевич[1] — д-р техн. наук,
профессор, e-mail: moseykin@inbox.ru,
ORCID ID: 0000-0002-2286-1480,
[1] НИТУ «МИСиС».
Для контактов: Кожухов А.А., e-mail: kozhuh@inbox.ru.

INFORMATION ABOUT THE AUTHORS

A.A. Kozhukhov[1], Graduate Student,
e-mail: kozhuh@inbox.ru,
ORCID ID: 0000-0002-9137-6315,
D.R. Omelchenko[1], Graduate Student,
e-mail: omelched@gmail.com,
ORCID ID: 0000-0001-5419-4881,
I.A. Melnichenko[1], Cand. Sci. (Eng.),
Assistant of Chair, e-mail: kors-ilay@mail.ru,
ORCID ID: 0000-0002-0205-6425,
V.V. Cheskidov[1], Cand. Sci. (Eng.),
Assistant Professor,
e-mail vcheskidov@misis.ru,
Vice-director, College of Mining,
V.V. Moseykin[1], Dr. Sci. (Eng.), Professor,
e-mail: moseykin@inbox.ru,
[1] National University of Science and Technology «MISiS»,
119049, Moscow, Russia.
Corresponding author: A.A. Kozhukhov, e-mail: kozhuh@inbox.ru.

Получена редакцией 05.05.2023; получена после рецензии 07.06.2023; принята к печати 10.07.2023.
Received by the editors 05.05.2023; received after the review 07.06.2023; accepted for printing 10.07.2023.