ГИАБ. Горный информационно-аналитический бюллетень /
MIAB. Mining Informational and Analytical Bulletin, 2021;(4):46-56
ОРИГИНАЛЬНАЯ СТАТЬЯ / ORIGINAL PAPER

УДК 550.8.053 DOI: 10.25018/0236_1493_2021_4_0_46

ПРОСТРАНСТВЕННОЕ РАЙОНИРОВАНИЕ МЕСТОРОЖДЕНИЙ ПОЛЕЗНЫХ ИСКОПАЕМЫХ

И.А. Мельниченко[1], Ю.В. Кириченко[1]

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

Аннотация: Оконтуривание рудных интервалов и построение рудных тел, как и создание литологических моделей месторождений полезных ископаемых, до сих пор остается одним из неавтоматизированных процессов, требующего непосредственного участия геолога. Цифровизация всех отраслей производства диктует условия, при которых количество операций с высокой долей человеческого участия постепенно сводится к необходимому и достаточному минимуму. Одним из процессов, автоматизация которого позволит минимизировать количество ручного труда при оконтуривании, является выделение литологических разностей, геологических тел и инженерно-геологических элементов. Предлагается метод определения границ литологических разностей, основанный на нейросетевых технологиях, для построения трехмерных моделей рудных тел (угольных пластов) и вмещающих пород с целью повышения качества геологического обеспечения, проектирования и планирования горных работ. Данный метод позволяет не только повысить качество, но и значительно ускорить обработку геологической информации, получаемой при опробовании массивов горных пород, на всех стадиях комплексного освоения различных участков недр. Разработанный метод построения трехмерных литологических моделей участков недр с использованием функциональных возможностей нейронных сетей позволяет осуществлять процесс моделирования в значительно более короткие сроки с сохранением требуемой точности и достоверности результатов.

Ключевые слова: добыча полезных ископаемых, геологическое обеспечение недропользования, статистика, обработка данных, эксплуатационная разведка, бурение скважин, нормирование данных, рудное тело, нейронные сети, 3D моделирование, цифровое месторождение.

Для цитирования: *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.

Spatial zoning of mineral deposits

I.A. Melnichenko[1], Yu.V. Kirichenko[1]

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

Abstract: Delineation of ore-bearing intervals, construction of ore bodies and lithological modeling of mineral deposits yet remain the uncomputerized processes which need direct participation of geologists. Industrial digitalization dictates minimization of operations which require high-level human control. One of the processes automation of which can help minimize manual work in delineation is detection of lithological varieties, geological bodies and geotechnical

© И.А. Мельниченко, Ю.В. Кириченко. 2021.

elements. The method proposed to delineate lithological varieties is based on neural network technologies for three-dimensional modeling of ore bodies (coal seams) and enclosing rocks in order to improve the quality of geological supervision, planning and design of mines. This method can refine and greatly accelerate processing of geological data from rock mass assaying at all stages of integrated subsoil use. The developed method of three-dimensional modeling of rock mass lithology using functional capabilities of neural networks enables modeling at shorter notice at the required accuracy and reliability of the results.

Key words: mineral mining, geological supervision of subsoil use, statistics, data processing, operational exploration, drilling, data standartization, ore body, neural networks, 3D modeling, digital deposit.

For citation: Melnichenko I.A., Kirichenko Yu.V. Spatial zoning of mineral deposits. *MIAB. Mining Inf. Anal. Bull.* 2021;(4):46-56. [In Russ]. DOI: 10.25018/0236_1493_2021_4_0_46.

Введение

Одной из наиболее сложных и трудоемких задач при геологоразведочных работах является оконтуривание тел полезных ископаемых для их комплексного использования. Применение компьютерных технологий в геологии позволяет отойти от традиционных методов сбора и обработки информации, решать проблему интерпретации больших массивов данных, исключить субъективность интерпретации результатов исследований, что в конечном итоге способствует комплексному использованию полезных ископаемых и всех вмещающих пород в контурах месторождения. Это отвечает основным требованиям рационального природопользования.

В настоящее время в геологии существует ряд актуальных задач, одной из которых является построение цифровых инженерно-геологических и литологических моделей [1]. Несмотря на то, что в своей работе инженер-геолог не может обойтись без использования CAD и ГГИС (горно-геологических информационных систем), большинство процессов не автоматизировано, и инженер вынужден выполнять значительный объем ручной работы. В задаче исследования модели инженерно-геологических элементов такими неавтоматизированными процессами являются расчет, оконтуривание, создание каркасной и блочной моделей [2], подсчет объемов полезного ископаемого. В условиях цифровизации горного производства возникла необходимость разработки новых методов обработки геологической информации с целью создания инженерно-геологических моделей, отвечающих современным требованиям точности, полноты и достоверности [3].

Существующие методы построения трехмерных цифровых моделей в основном базируются на принципах каркасного и блочного моделирования [2, 4], при этом создание последующих включает этап формирования первых. Следует отметить, что при проектировании новых добывающих предприятий и эксплуатации разрабатываемых участков недр возникает необходимость создания модели не только рудной толщи, но и вмещающих пород, а также техногенных массивов с целью прогнозирования их состояния, в том числе повышения точности оценки устойчивости уступов и бортов карьеров, ярусов отвалов, а также дамб намывных горнотехнических сооружений [3, 5]. Развитие цифровых технологий и методов обработки геологической информации создает предпосылки для разработки детализированных моделей

породных массивов, которые позволят осуществлять оперативный прогноз изменения их состояния в процессе освоения месторождения.

При помощи технологии распознавания образов, основанной на методе классификации и идентификации инженерно-геологических элементов, стало возможным построить трехмерную инженерно-геологическую модель, где основой интерпретации результата является не субъективный характер модели, а математический аппарат [6]. Особое внимание необходимо уделить технологическим и бизнес-процессам в горном производстве, направленным на обеспечение максимальной безопасности и получение экономической выгоды [7]. Это позволит оперативно дополнять и вносить изменения в цифровую модель, которую в дальнейшем возможно будет предсказать при помощи обученных искусственных нейронных сетей для более точного определения литологических разностей [8–10].

В отличие от уже известных способов моделирования месторождений, математический аппарат искусственных нейронных сетей позволяет произвести более качественную оценку трехмерной модели месторождения, что способствует переходу на качественно новый уровень обработки результатов инженерно-геологических изысканий и минимизировать объем ручного труда инженера-геолога, занимающегося просмотром и обработкой огромных массивов однотипной геологической информации [8, 9].

Разработанный метод построения трехмерных блочных литологических моделей с использованием нейросетевых методов позволяет не только повысить оперативность обработки геологической информации и качество ее интерпретации, но и более комплексно подойти к освоению месторождения [1, 11, 12].

При разработке данного метода были решены следующие задачи:

- осуществлен анализ распространенных методов построения моделей массивов горных пород;
- произведена оценка применимости блочного моделирования и нейронных сетей для построения литологических моделей;
- спроектирована нейронная сеть на основе перцептронов для определения границ литологических разностей на основе информации, полученной на стадиях изучения участка недр;
- обоснован метод обучения, нормирования данных, функций активации и других параметров нейронной сети для решения задач построения бескаркасных трехмерных литологических моделей;
- произведен анализ скорости обучения нейронной сети;
- определены необходимые и достаточные условия, позволяющие оценивать элемент блочной модели в качестве достоверно определенного;
- проведено моделирование нескольких участков недр на основе разработанного инструментария;
- оценена область применимости спроектированной нейронной сети для геологических тел различных форм залегания;
- рассмотрены перспективы разработок для применения на различных этапах освоения месторождений полезных ископаемых в соответствии с требованиями рационального природопользования.

Вышеизложенные задачи представлены в виде блок схемы, приведенной на рис. 1.

Ниже приведены результаты пространственного районирования месторождения полезных ископаемых одного из железорудных месторождений, проведенного по разработанной методике

определения границ литологических разностей с использованием принципов блочного моделирования [2] и искусственных нейронных сетей [10, 13]. Районирование производилось в следующей последовательности.

Результаты

Обучение и предсказание были выполнены при помощи cross-validation — эмпирической оценки обобщающей способности алгоритма, обучаемого по прецедентам. Фиксируем обучающие мно-

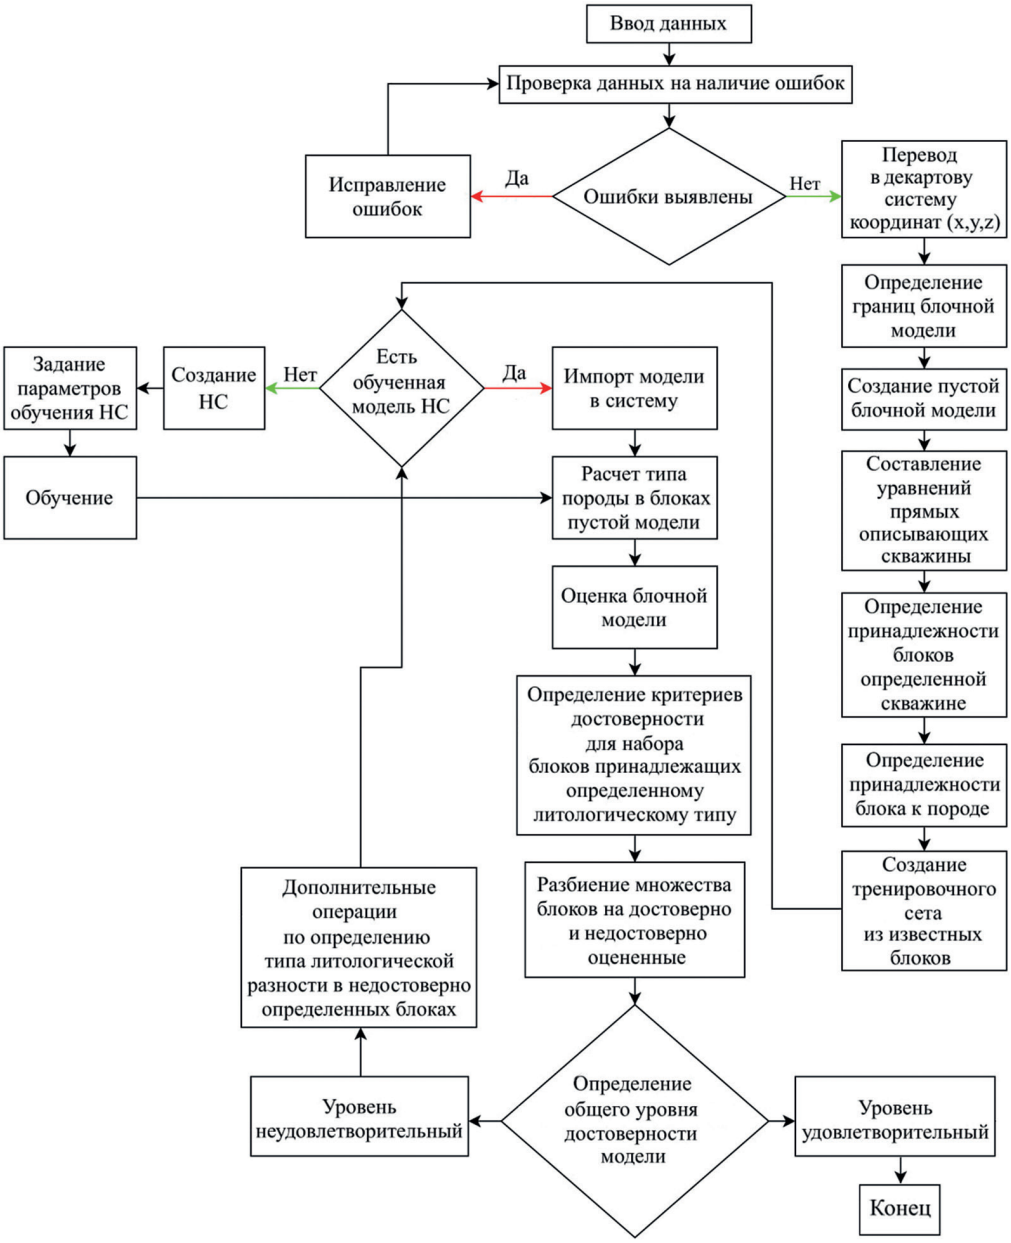

Рис. 1. Блок-схема разработанного метода
Fig. 1. Block-diagram of the developed method

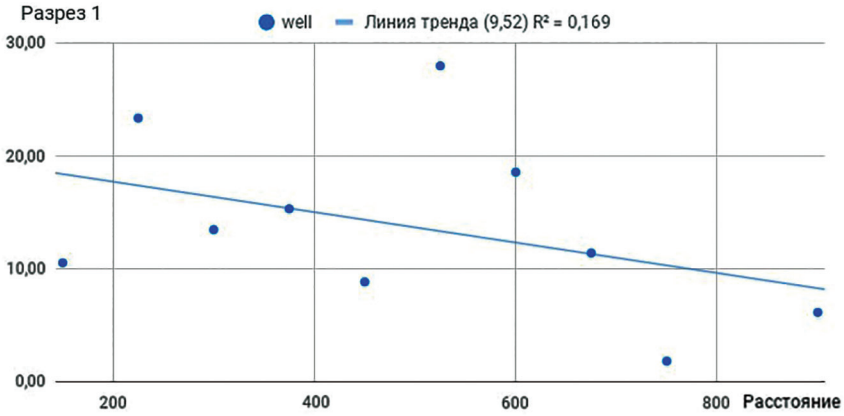

Рис. 2. Распределение ошибки по разрезу 1
Fig. 2. Distribution of errors in section 1

жества с разбиением на исходную выборку и предсказанную. Основываясь на данных (координаты блока, порода, выходной нейрон), полученных в результате предсказания блочной скважины, проведен ряд аналитических преобразований.

- Сумма всех известных блоков — 37 970;
- Сумма всех верно предсказанных блоков — 33 112;
- Общая ошибка — 12,8%.

На основании полученных данных по предсказанным блокам построим график распределения общий ошибки для разреза 1 (рис. 2).

По такому же алгоритму производится оценка распределения ошибки по другим разведочным разрезам (линиям). Полученные данные позволяют провести пространственное районирование месторождения полезных ископаемых по всему разведочному полю (в пределах разведочной сети), представленному на рис. 3.

Для каждой породы необходимо рассчитать доверительный интервал исходя из данных, полученных в результате

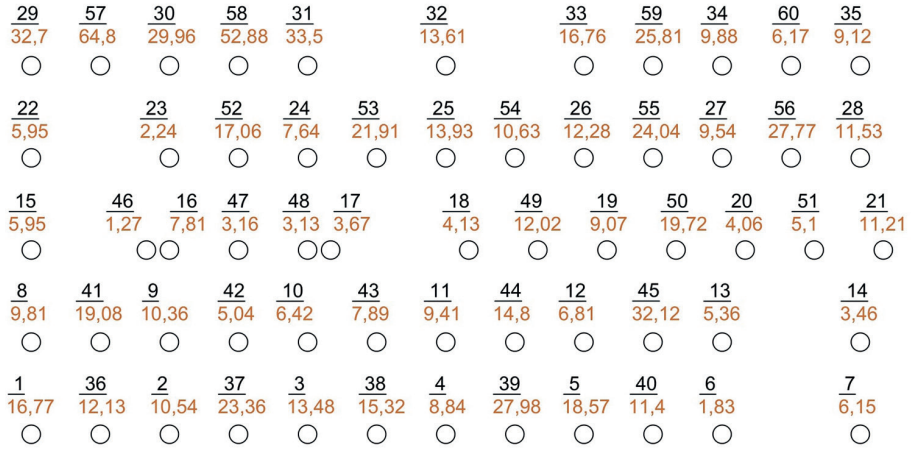

Рис. 3. Распределение ошибки по разведочному полю
Fig. 3. Distribution of errors in exploration field

обучения. Первым делом рассчитываем среднее значение по выборке для каждой породы. Пусть $X_1 \ldots X_n$ — выборка. Среднее значение выборки оценивается по формуле:

$$M = \frac{\sum_{i=1}^{n} X_i}{n}. \qquad (1)$$

Среднеквадратичное отклонение популяции:

$$\sigma = \sqrt{D[X]}, \qquad (2)$$

где $D[X]$ — дисперсия или мера разброса случайной величины, т.е. ее отклонение от математического ожидания.

При расчете доверительного интервала задаем вероятность попадания результатов обучения нейронной сети в заданные границы прогноза. Для этого задаем значения 3σ. Т.о. есть вероятность попадания очередного фактического значения в доверительный интервал; она составляет 99,7%, или 3000 к 1 (существует 0,3% вероятности выхода за границы).

$$3\sigma = M \pm 3\sigma, \qquad (3)$$

$$-3\sigma < \bar{X} < +3\sigma, \qquad (4)$$

где $\bar{X}$ — количество блоков, удовлетворяющих условию.

$$B = \frac{\pm 3\sigma}{(\pm 3\sigma + \pm 3\sigma)} \cdot 100, \qquad (5)$$

где B — процент блоков, удовлетворяющих условию.

Рассчитываем математическое ожидание верно предсказанных блоков для руды богатой исходя из глубины.

Среднее значение выборки по руде богатой исходя из глубины будет:

M = 0,9678461489.

Среднеквадратичное отклонение популяции для руды богатой составит:

σ = 0,0806650654.

Отсюда доверительный интервал для руды богатой:

3σ = M – 3σ = 0,7258509527;

3σ = M + 3σ = 1,209841345.

Количество блоков, удовлетворяющее доверительному интервалу для руды богатой, составит:

$$\bar{X} = 5311 > -3\sigma.$$

Следовательно количество блоков, неудовлетворяющее доверительному интервалу для руды богатой, составит:

$$\bar{X} = 186 < -3\sigma.$$

Определяем процент блоков, удовлетворяющих условию:

$$B = \frac{5311}{(5311 + 186)} \cdot 100 = 96,61633618\%.$$

Количество блоков, неудовлетворяющее доверительному интервалу для руды богатой, составит:

$$\bar{X} = 0 > +3\sigma.$$

Следовательно количество блоков, удовлетворяющее доверительному интервалу для руды богатой, составит:

$$\bar{X} = 5497 < +3\sigma.$$

Определяем процент блоков, неудовлетворяющих условию:

$$B = \frac{0}{(0 + 5497)} \cdot 100 = 0\%.$$

Результаты расчетов позволяют графически оценить распределение выхода нейронной сети верно предсказанных блоков в пространстве (рис. 4).

Аналогично рассчитывается математическое ожидание неправильно предсказанных блоков для руды богатой исходя из глубины.

Среднее значение выборки по руде богатой исходя из глубины:

M = 0,9007325409.

Среднеквадратичное отклонение популяции для руды богатой:

σ = 0,1347944782.

Доверительный интервал для руды богатой:

3σ = M – 3σ = 0,4963491064;

3σ = M + 3σ = 1,305115975.

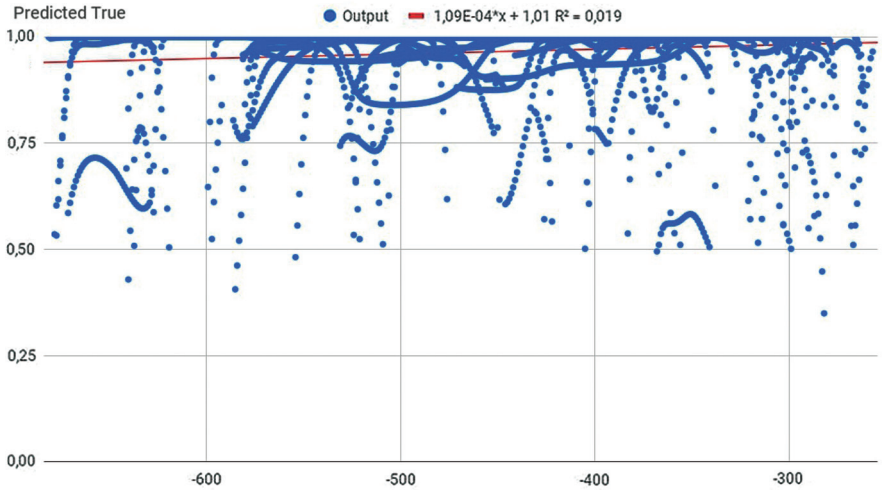

Рис. 4. Распределение выхода нейронной сети верно предсказанных блоков по руде богатой исходя из глубины

Fig. 4. Distribution of neural network output on correctly predicted blocks of rich ore on the basis of depth value

Количество блоков, удовлетворяющее доверительному интервалу для руды богатой:

$$\bar{X} = 1155 > -3\sigma .$$

Количество блоков, неудовлетворяющее доверительному интервалу для руды богатой:

$$\bar{X} = 7 < -3\sigma .$$

Процент блоков, удовлетворяющих условию:

$$B = \frac{1155}{(1155+7)} \cdot 100 = 99,39759036\% .$$

Количество блоков, неудовлетворяющее доверительному интервалу для руды богатой:

$$\bar{X} = 0 > +3\sigma .$$

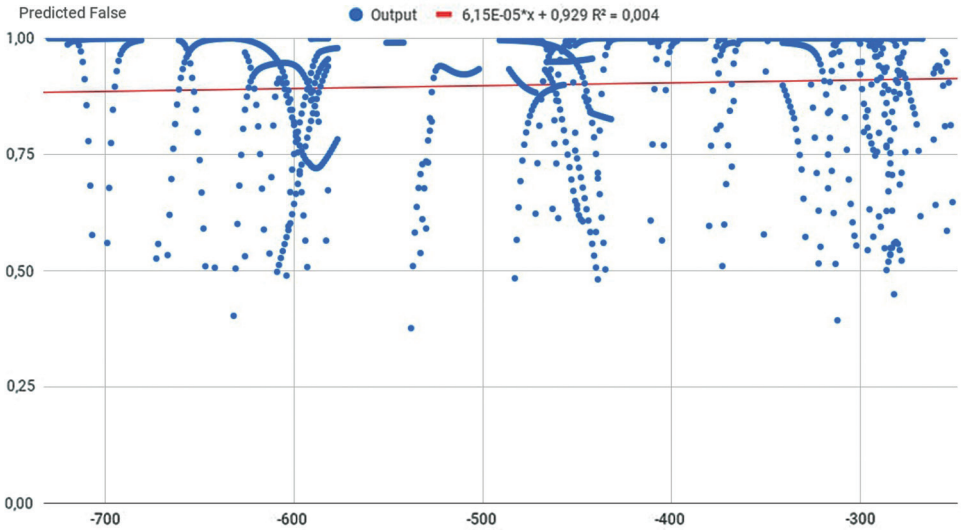

Рис. 5. Распределение выхода нейронной сети неправильно предсказанных блоков по руде богатой исходя из глубины

Fig. 5. Distribution of neural network output on incorrectly predicted blocks of rich ore on the basis of depth value

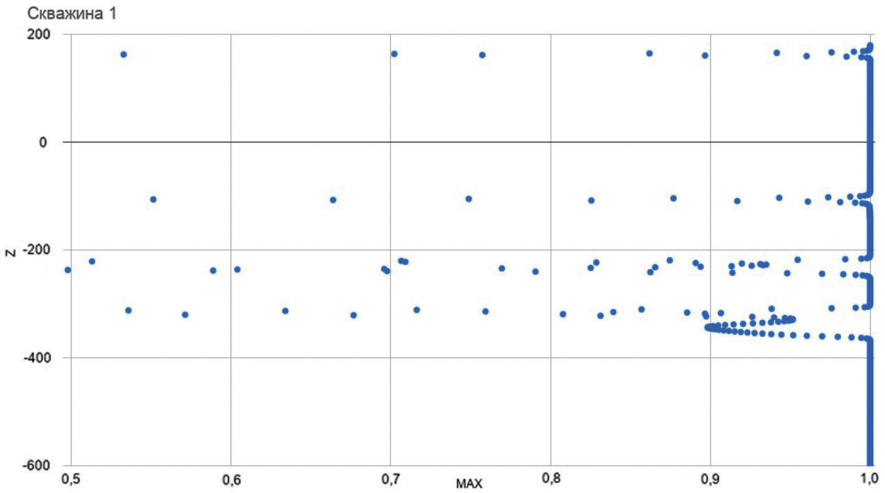

Рис. 6. Распределение вероятности в зависимости от расстояния
Fig. 6. Probability distribution versus distance

Количество блоков, удовлетворяющее доверительному интервалу для руды богатой:

$$\bar{X} = 1162 < +3\sigma .$$

Процент блоков, не удовлетворяющих условию:

$$B = \frac{0}{(0+1162)} \cdot 100 = 0\% .$$

Результаты расчетов позволяют графически оценить распределение выхода нейронной сети неправильно предсказанных блоков в пространстве (рис. 5).

По данным выходного вектора искусственной нейронной сети строим графики по скважинам для определения границы между литологическими разностями (рис. 6). Этот график позволяет

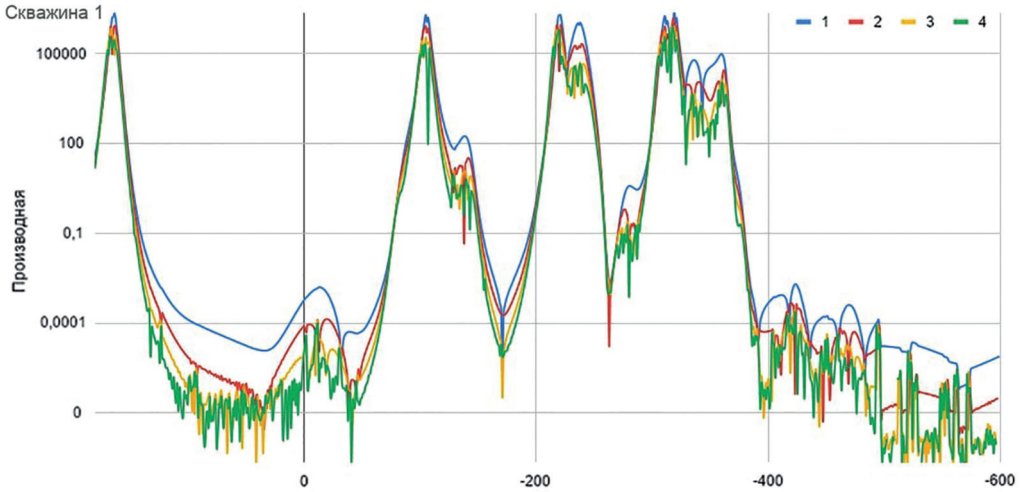

Рис. 7. Распределение производной в зависимости от расстояния: синий – первая производная; красный – вторая производная; желтый – третья производная; зеленый – четвертая производная
Fig. 7. Distribution of derivative versus distance: blue — the first derivative; red — the second derivative; yellow — the third derivative; green — the fourth derivative

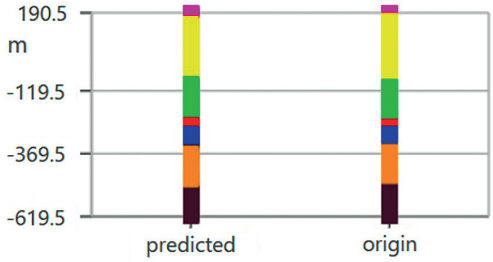

Рис. 8. Скважина 1: predicted (предсказанные данные), origin (исходные данные)
Fig. 8. Borehole 1: predicted data; origin data

определить примерную границу смены литологических разностей на основе имеющихся представлений о том, что вектор выходного слоя искусственной нейронной сети при смене литологических разностей стремится к 0.

Для получения более точной границы смены литологических разностей на основе выходного вектора необходимо взять производную для каждого значения. По нормированным данным строится график (рис. 7). Пик на графике предоставляет возможность провести более ярко выраженную границу смены литологических разностей.

Достоверность данных, получаемых по разработанной методике определения границ литологических разностей с использованием принципов блочного моделирования и искусственных нейронных сетей, можно оценить на примере литологической колонки одной из скважин (рис. 8).

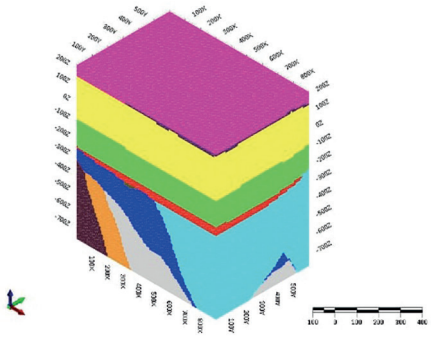

Рис. 9. Блочная трехмерная модель, предсказанная искусственной нейронной сетью
Fig. 9. 3D block model predicted by artificial neural network

С использованием этой методики построена трехмерная блочная модель, отображающая пространственное районирование месторождений полезных ископаемых по заданным параметрам инженерно-геологических элементов.

Выводы

- в качестве необходимого критерия достоверности определения вида литологической разности в рассматриваемом элементе блочной модели необходимо принять величину, равную отношению максимального значения, полученного в выходном векторе нейронной сети, к сумме всех значений, при этом граничное значение предлагаемого критерия устанавливается в зависимости от требуемого уровня достоверности и закономерности изменения величины критерия внутри предположительно выделенной однородной по составу части массива пород;
- максимальная сходимость построенной литологической модели будет наблюдаться при условии выбора параметров блока на основании поиска минимума функции достоверности полученных результатов от размера элементарной единицы модели; данная зависимость имеет выраженный параболический характер и должна быть построена на основании методов cross-validation;
- использование принципов блочного моделирования месторождений полезных ископаемых и методов распознавания образов на основе нейронных сетей позволяет определить границы литологических разностей или других задаваемых параметров исключая этап построения каркасов и автоматизировать всю цепочку операций от загрузки первичных геологических данных до построения литологической модели породного массива.

СПИСОК ЛИТЕРАТУРЫ

1. *Mahmoodi O., Smith R. S., Tinkham D. K.* Supervised classification of down-hole physical properties measurements using neural network to predict the lithology // Journal of Applied Geophysics. 2016. Vol. 124. Pp. 17–26. DOI: 10.1016/j.jappgeo.2015.11.006.

2. *Сорокина А. С., Загибалов А. В.* Практическое применение программного обеспечения Mineframe при построении блочной модели и подсчете запасов золоторудных месторождений // Горный информационно-аналитический бюллетень. — 2018. — СВ 27. — С. 65–72. DOI: 10.25018/0236-1493-2018-6-27-65-72.

3. *Громов Е. В., Торопов Д. А.* Повышение точности подсчета запасов с применением 3D моделирования (на примере месторождения «Партомчорр») // Горный информационно-аналитический бюллетень. — 2017. — СВ 23. — С. 158–166. DOI: 10.25018/0236-1493-2017-10-23-158-166.

4. *Лихман А. А.* Геологическая блочная модель как главный актив горнодобывающего предприятия // Недропользование XXI век. — 2020. — № 4 (87). — С. 170–175.

5. *Аленичев В. М., Аленичев М. В.* Повышение достоверности геоинформационного обеспечения при отработке техногенных месторождений // Горный информационно-аналитический бюллетень. — 2019. — № 11. — С. 172–179. DOI: 10.25018/0236-1493-2019-11-0-172-179.

6. *Щенкова Е. С.* Использование статистического и геостатистического аппарата при блочном моделировании (на примере золоторудного месторождения жильного типа) / Геология в развивающемся мире: сборник научных статей. — Пермь, 2019. — С. 517 — 520.

7. *Чеклар М., Рыбар П., Михок Я., Энгел Я.* Экономическая оценка месторождений полезных ископаемых на примерах блочных моделей открытых горных работ // Экономика и управление инновациями. — 2018. — № 1. — С. 46–59. DOI: 10.26730/2587-5574-2018-1-46-58.

8. *Ripley B. D.* Pattern recognition and neural networks. Cambridge University Press, 2014. 403 p.

9. *Wang K., Zhang L.* Predicting formation lithology from log data by using a neural network // Petroleum Science. 2008. Vol. 5. no 3. Pp. 242–246. DOI: 10.1007/s12182-008-0038-9.

10. *Wood D. A.* Lithofacies and stratigraphy prediction methodology exploiting an optimized nearest-neighbour algorithm to mine well-log data // Marine and Petroleum Geology. 2019. Vol. 110. Pp. 347–367. DOI: 10.1016/j.marpetgeo.2019.07.026.

11. *Sahoo S., Jha M. K.* Pattern recognition in lithology classification: modeling using neural networks, self-organizing maps and genetic algorithms // Hydrogeology Journal. 2017. Vol. 25. No 2. Pp. 311–330. DOI: 10.1007/s10040-016-1478-8.

12. *Gu Y., Bao Z., Song X., Patil S., Ling K.* Complex lithology prediction using probabilistic neural network improved by continuous restricted Boltzmann machine and particle swarm optimization // Journal of Petroleum Science and Engineering. 2019. Vol. 149. Pp. 966–978. DOI: 10.1016/j.petrol.2019.05.032.

13. *Воронин А. Ю.* Геологическое районирование с позиции распознавания образов // Геоинформатика. — 2008. — № 1. — С. 13–18. ГИАБ

REFERENCES

1. Mahmoodi O., Smith R. S., Tinkham D. K. Supervised classification of down-hole physical properties measurements using neural network to predict the lithology. *Journal of Applied Geophysics.* 2016. Vol. 124. Pp. 17–26. DOI: 10.1016/j.jappgeo.2015.11.006.

2. Sorokina A. S., Zagibalov A. V. Practical application of Mineframe software in building a block model and calculating reserves of gold ore deposits. *MIAB. Mining Inf. Anal. Bull.* 2018. Special edition 27, pp. 65–72. [In Russ]. DOI: 10.25018/0236-1493-2018-6-27-65-72.

3. Gromov E. V., Toropov D. A. Improving the accuracy of reserves calculation using 3D modeling (on the example of the Partomchorr field). *MIAB. Mining Inf. Anal. Bull.* 2017. Special edition 23, pp. 158–166. [In Russ]. DOI: 10.25018/0236-1493-2017-10-23-158-166.

4. Likhman A. A.Geological block model as the main asset of a mining enterprise. *Nedropolzovanie XXI vek*. 2020, no 4 (87), pp. 170–175. [In Russ].

5. Alenichev V. M., Alenichev M. V. Increasing validity of geoinformation support in mining waste management. *MIAB. Mining Inf. Anal. Bull.* 2019, no 11, pp. 172–179. DOI: 10.25018/0236-1493-2019-11-0-172-179.

6. Shchenkova E. S.Use of statistical and geostatistical apparatus in block modeling (on the example of a vein-type gold ore deposit). *Geologiya v razvivayushchemsya mire*: sbornik nauchnykh statey [Geology in the developing world, Collection of scientific articles], Perm, 2019, pp. 517–520. [In Russ].

7. Cheklar M., Rybar P., Mihok J., Engel J. Economic assessment of mineral deposits on the examples of block models of open pit mining. *Economics and Innovation Management*. 2018, no 1, pp. 46–59. [In Russ]. DOI: 10.26730/2587-5574-2018-1-46-58.

8. Ripley B. D. *Pattern recognition and neural networks*. Cambridge University Press, 2014. 403 p.

9. Wang K., Zhang L. Predicting formation lithology from log data by using a neural network. *Petroleum Science*. 2008. Vol. 5. no 3. Pp. 242–246. DOI: 10.1007/s12182-008-0038-9.

10. Wood D.A. Lithofacies and stratigraphy prediction methodology exploiting an optimized nearest-neighbour algorithm to mine well-log data. *Marine and Petroleum Geology*. 2019. Vol. 110. Pp. 347–367. DOI: 10.1016/j.marpetgeo.2019.07.026.

11. Sahoo S., Jha M. K. Pattern recognition in lithology classification: modeling using neural networks, self-organizing maps and genetic algorithms. *Hydrogeology Journal*. 2017. Vol. 25. No 2. Pp. 311–330. DOI: 10.1007/s10040-016-1478-8.

12. Gu Y., Bao Z., Song X., Patil S., Ling K. Complex lithology prediction using probabilistic neural network improved by continuous restricted Boltzmann machine and particle swarm optimization. *Journal of Petroleum Science and Engineering*. 2019. Vol. 149. Pp. 966–978. DOI: 10.1016/j.petrol.2019.05.032.

13. Voronin A. Yu. Geological regionalization from the position of pattern recognition. *Geoinformatika*. 2008, no 1, pp. 13–18. [In Russ].

ИНФОРМАЦИЯ ОБ АВТОРАХ

Мельниченко Илья Ашотович[1] — аспирант,
e-mail: kors-ilay@mail.ru,
Кириченко Юрий Васильевич[1] — д-р техн. наук, профессор,
[1] НИТУ «МИСиС».
Для контактов: Мельниченко И.А., e-mail: kors-ilay@mail.ru.

INFORMATION ABOUT THE AUTHORS

I.A. Melnichenko[1], Graduate Student,
e-mail: kors-ilay@mail.ru,
Yu.V. Kirichenko[1], Dr. Sci. (Eng.), Professor,
[1] National University of Science and Technology «MISiS»,
119049, Moscow, Russia.
Corresponding author: I.A. Melnichenko, e-mail: kors-ilay@mail.ru.

Получена редакцией 03.12.2020; получена после рецензии 15.01.2021; принята к печати 10.03.2021.
Received by the editors 03.12.2020; received after the review 15.01.2021; accepted for printing 10.03.2021.