

ПОСТРОЕНИЕ ТРЕХМЕРНОЙ МОДЕЛИ МЕСТОРОЖДЕНИЯ С ИСПОЛЬЗОВАНИЕМ ПРИНЦИПОВ БЛОЧНОГО МОДЕЛИРОВАНИЯ И ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

И.А. Мельниченко¹, А.А. Кожухов¹, Д.Р. Омельченко¹, В.В. Мосейкин¹

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

Аннотация: При развитии цифровых технологий и методов обработки геологической информации создаются предпосылки для разработки детализированных объемных моделей породных массивов. При помощи технологии распознавания образов, основанной на методе классификации и идентификации инженерно-геологических элементов, станет возможно построение трехмерной инженерно-геологической модели, где основой интерпретации результата является не субъективный характер модели, а математический аппарат. Разработанный метод позволяет осуществить оперативное построение трехмерной литологической модели, исключая этап построения каркасов, который на сегодняшний день требует больших временных затрат. Применение результатов исследования позволяет построить литологические модели, которые могут быть уточнены в автоматическом режиме при появлении дополнительных геологических данных. Это позволит оперативно управлять геологоразведочными работами, осуществлять планирование отработки месторождения с целью достижения требуемых значений качественных характеристик полезного ископаемого. Разработка нового метода построения трехмерных моделей месторождений полезных ископаемых при помощи искусственных нейронных сетей позволит не только повысить качество моделирования и интерпретации геологических данных, но и значительно ускорить обработку геологической информации, получаемой в результате геологоразведочных работ на всех этапах разработки месторождения и формирования техногенных массивов с сохранением требуемой точности и достоверности результатов. В результате создания блочной геологической модели месторождения полезного ископаемого при помощи искусственной нейронной сети появляется возможность оценивать модель математическими методами не только в двумерном пространстве, но и произвести пространственное районирование месторождения полезных ископаемых для более детального анализа.

Ключевые слова: горное дело, геологическое обеспечение недропользования, статистика, обработка данных, эксплуатационная разведка, геоинформатика, нормирование данных, рудное тело, нейронные сети, 3D моделирование, цифровое месторождение.

Для цитирования: 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.

3D mineral deposit modeling using concepts of blockmodeling and artificial neural networks

I.A. Melnichenko¹, A.A. Kozhukhov¹, D.R. Omelchenko¹, V.V. Moseykin¹

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

Abstract: Digital technologies and geological information processing techniques create a framework for the comprehensive 3D modeling. The image identification technology using the method of identification and classification of engineering geological elements can enable 2D engineering geological modeling with the interpretation basis represented not by the subjective model but by the mathematical apparatus. The developed method allows the real-time 3D lithology modeling with elimination of the frameworking stage which takes much time today. The research findings make it possible to build lithological models adjustable automatically upon updating of geological data. This allows the real-time exploration activity control and mining operation planning toward the target quality characteristics of mineral production. The new method of 3D mineral deposit modeling using artificial neural networks improves the quality of the modeling and geological data interpretation, as well as greatly accelerates processing of the information provided by exploration at all stages of mining and manmade deposit formation at the required accuracy and reliability. The constructed geological block model of a mineral deposit using artificial neural network enables the model assessment using mathematical methods not only in a two-dimensional space but also the special zoning of the deposit for the more comprehensive analysis.

Key words: mining, geological support of subsoil use, statistics, data processing, operational exploration, geoinformation science, data normalization, ore body, neural networks, 3D modeling, digital mineral deposit.

For citation: 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;(10):5-19. [In Russ]. DOI: 10.25018/0236_1493_2022_10_0_5.

Введение

При подготовке данных к построению трехмерной модели массивов горных пород и отложений с использованием искусственных нейронных сетей нами был использован традиционный комплекс исследований, включающий [1]:

- анализ и обобщение опыта построения объемных геологических моделей, а также инструментария нейронных сетей для решения задачи распознавания образов в геологии и других смежных областях [1];

- методы геометрического моделирования формы и пространственного по-

ложения геологических тел в пространстве [1];

- принципы блочного моделирования месторождений полезных ископаемых [1];

- математические и геостатистические методы обработки, интерпретации и преобразования геологической информации, получаемой на различных стадиях освоения участков недр [1];

- методы кросс-валидации для определения достоверности результатов моделирования [1].

Для построения трехмерной литологической модели необходимо иметь ряд

данных, приведенных в отчете о геологоразведочных работах, отображающих положение устья скважины в пространстве, ее глубину, результаты инклинометрических измерений при их наличии, а также информацию о распределении литологических разностей вдоль оси выработки (рис. 1, см. Приложение, с. 18 и рис. 2) [1].

Основные положения для разработки метода

Для обучения искусственной нейронной сети необходимо подготовить данные, полученные в результате геологоразведочных работ, для корректного представления результатов опробования в трехмерном пространстве [1–3]. Это достигается переводом в декартову систему координат, где для каждого интервала опробования справедливы выражения:

$$r = Start_i - End_i \quad (1)$$

$$x_i = r \cdot (\sin\beta + 90) \cdot (\cos\alpha + offset - 90) \quad (2)$$

$$y_i = r \cdot (\sin\beta + 90) \cdot (\sin\alpha + offset + 90) \quad (3)$$

$$z_i = -r \cdot (\cos\beta + 90) \quad (4)$$

где i – номер породы; r – интервал опробования; α – азимут скважины; β – ось (уклон, наклон) скважины относи-

тельно вертикали; $offset$ – смещения для различных систем отсчета; $Start_i$ – расстояние от начала скважины до i -го образца; End_i – расстояние до конца скважины по i -му образцу.

По полученным декартовым координатам (формулы (1)–(4)) удаленности интервала опробования от устья скважины находим абсолютные координаты в декартовой системе координат, просуммировав декартовы координаты и координаты устья скважины.

$$x_a = x + x_i, \quad (5)$$

$$y_a = y + y_i, \quad (6)$$

$$z_a = z + z_i, \quad (7)$$

где x, y, z – координаты устья скважины.

По координате устья скважины и конечному интервалу скважины составляем уравнения прямой, описывающие скважину по классической формуле (уравнение прямой, проходящей через две точки) [1].

Зафиксируем в трехмерном пространстве прямоугольную систему координат $Oxyz$, и зададим две несовпадающие точки $M_1(x_1, y_1, z_1)$ и $M_2(x_2, y_2, z_2)$, через которые проходит прямая M_1M_2 . Отсюда получим уравнения этой прямой.

Известно, что канонические уравнения прямой в пространстве имеет вид:

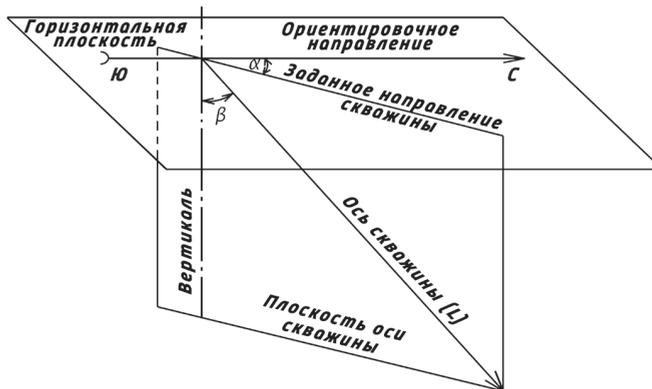


Рис. 2. Ориентация скважины в трехмерном пространстве

Fig. 2. Orientation of borehole in 3D space

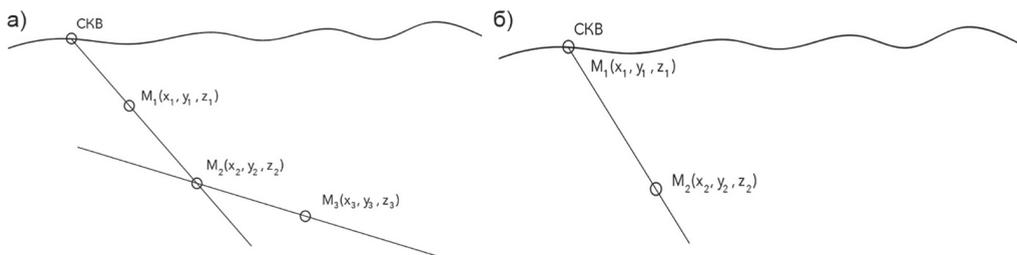


Рис. 3. Прямая, проходящая через две заданные точки в пространстве
 Fig. 3. Straight line passing through two assigned points in space

$$\frac{x - x_1}{a_x} = \frac{y - y_1}{a_y} = \frac{z - z_1}{a_z} \quad (8)$$

и параметрические уравнения прямой в пространстве имеют вид:

$$\begin{cases} x = x_1 + a_x \cdot \lambda \\ y = y_1 + a_y \cdot \lambda \\ z = z_1 + a_z \cdot \lambda \end{cases} \quad (9)$$

Далее задаем в прямоугольной системе координат $Oxyz$ прямую линию, которая проходит через точки с координатами (x_1, y_1, z_1) и имеет направляющий вектор (рис. 3):

$$\vec{a} = (a_x, a_y, a_z). \quad (10)$$

Следовательно, направляющим вектором прямой является вектор:

$$\overline{M_1M_2} = (x_2 - x_1, y_2 - y_1, z_2 - z_1). \quad (11)$$

Так как прямая проходит через точку $M_1(x_1, y_1, z_1)$ и $M_2(x_2, y_2, z_2)$, то канонические уравнения этой прямой имеют вид:

$$\frac{x - x_1}{x_2 - x_1} = \frac{y - y_1}{y_2 - y_1} = \frac{z - z_1}{z_2 - z_1} \quad (12)$$

или

$$\frac{x - x_2}{x_2 - x_1} = \frac{y - y_2}{y_2 - y_1} = \frac{z - z_2}{z_2 - z_1}. \quad (13)$$

Параметрические уравнения имеют вид:

$$\begin{cases} x = x_1 + (x_2 - x_1) \cdot \lambda \\ y = y_1 + (y_2 - y_1) \cdot \lambda \\ z = z_1 + (z_2 - z_1) \cdot \lambda \end{cases} \quad (14)$$

или

$$\begin{cases} x = x_2 + (x_2 - x_1) \cdot \lambda \\ y = y_2 + (y_2 - y_1) \cdot \lambda \\ z = z_2 + (z_2 - z_1) \cdot \lambda \end{cases} \quad (15)$$

Применительно к рассматриваемой задаче представляем скважину прямой с известными координатами. На рис. 4 (см. Приложение, с. 18) зафиксировано визуальное представление участка месторождения железистых кварцитов, цветом указаны горные породы, пройденные выработки на соответствующих глубинах [4–6].

Полученные прямые (скважины), проходящие через две и более заданные точки, принадлежащие данной прямой в пространстве, необходимо ограничить границами блочной модели. Для создания границ блочной модели надо найти минимальные и максимальные значения x, y, z из числа известных точек для каждой скважины [1, 7–9].

Формула нахождения минимальных и максимальных x, y и z запишется в виде:

$$\begin{cases} f(x) \Rightarrow M \forall x_b \in [min, max] \\ f(y) \Rightarrow M \forall y_b \in [min, max] \\ f(z) \Rightarrow M \forall z_b \in [min, max] \end{cases} \quad (16)$$

где M – блочная модель; $x_b, y_b, z_b \in [min, max]$ – минимальная и максимальная точки границы блочной модели.

Минимальные и максимальные значения $x_b, y_b, z_b \in [min, max]$ из всех из-

вестных точек будут ограничивать построение блочной модели.

Расстояние от точки шага опробования по искомой скважине $M_1(x_1, y_1, z_1)$ и $M_2(x_2, y_2, z_2)$ до минимальной $x_b, y_b, z_b \in \in [min]$ можно выразить:

$$\begin{cases} size.x_b = point.x - min.x_b \\ size.y_b = point.y - min.y_b \\ size.z_b = point.z - min.z_b \end{cases} \quad (17)$$

Имея расстояние от минимальной границы блочной модели, вычисляем количество блоков в данном интервале согласно заданному размеру блока. Формула начала отсчета первого блока в пустой блочной модели принимает вид:

$$\begin{cases} number.min.x_b = \frac{point.x - min.x_b}{size.block} \\ number.min.y_b = \frac{point.y - min.y_b}{size.block} \\ number.min.z_b = \frac{point.z - min.z_b}{size.block} \end{cases} \quad (18)$$

где $point.x$ — точка начала отсчета шага по скважине; $min.x_b$ — граница месторождения; $size.block$ — размер пустого блока.

Полученное значение в формуле (18) необходимо округлить в меньшую сторону по модулю для получения целого числа, в которое попала точка шага опробования по искомой скважине $M_1(x_1, y_1, z_1)$ и $M_2(x_2, y_2, z_2)$:

$$\begin{cases} number.min.x_b \\ number.min.y_b \\ number.min.z_b \end{cases} \rightarrow \begin{cases} number.block.x_b \\ number.block.y_b \\ number.block.z_b \end{cases} \quad (19)$$

На основе целых блоков необходимо найти координаты центра блока, в который попала точка шага опробования по искомой скважине $M_1(x_1, y_1, z_1)$ и $M_2(x_2, y_2, z_2)$ (рис. 5). Формула расчета координаты пустого блока в рамках заданных границ имеет вид:

$$\begin{cases} x_c = min.x_c + number.block.x_c + \\ + size.block + \frac{size.block}{2} \\ y_c = min.y_c + number.block.y_c + \\ + size.block + \frac{size.block}{2} \\ z_c = min.z_c + number.block.z_c + \\ + size.block + \frac{size.block}{2} \end{cases} \quad (20)$$

где $number.min.x_b$ — целое количество пустых блоков от границы до точки шага; $min.x_b$ — граница месторождения; $size.block$ — размер пустого блока.

Пустым блоком, которые пересекли скважины, необходимо присвоить параметры, соответствующие данному интервалу опробования пересекающей скважины. Также необходимо обратить внимание на случай, когда точка пересечения будет находиться на границе двух пло-

4 целых блока+block_size/2 даст нам координаты блока

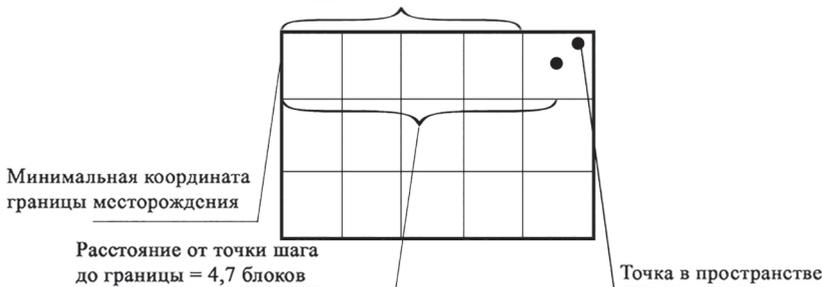


Рис. 5. Схема присваивания интервала опробования (породы) пустому блоку
Fig. 5. Scheme of assignment of sampling interval (rock) in empty block

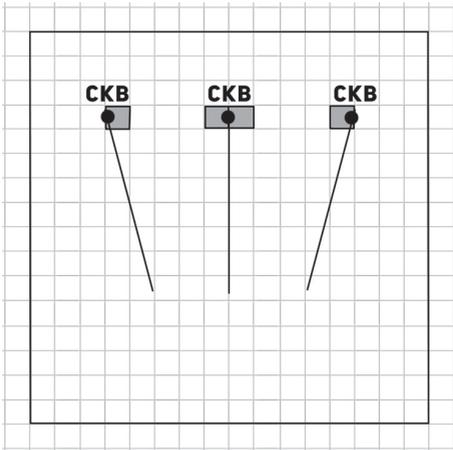


Рис. 6. Схема присваивания интервала опробования (породы) на границе двух пустых блоков
 Fig. 6. Scheme of assignment of sampling interval (rock) at interface of two empty blocks

скостей (рис. 6). В данном случае принимаем, что оба блока принадлежат скважине.

Известным пересеченным пустым блокам необходимо присвоить известные параметры, такие, как порода.

$$x_c, y_c, z_c \in M_1(x_1, y_1, z_1). \quad (21)$$

Полученные пустые блоки и блоки с известными параметрами считаем подготовленным обучающим множеством, необходимым для обучения искусственной нейронной сети, где на входе будут подаваться x, y, z , а на выходе будет получено значение породы, соответствующее данным координатам для корректировки весов [1].

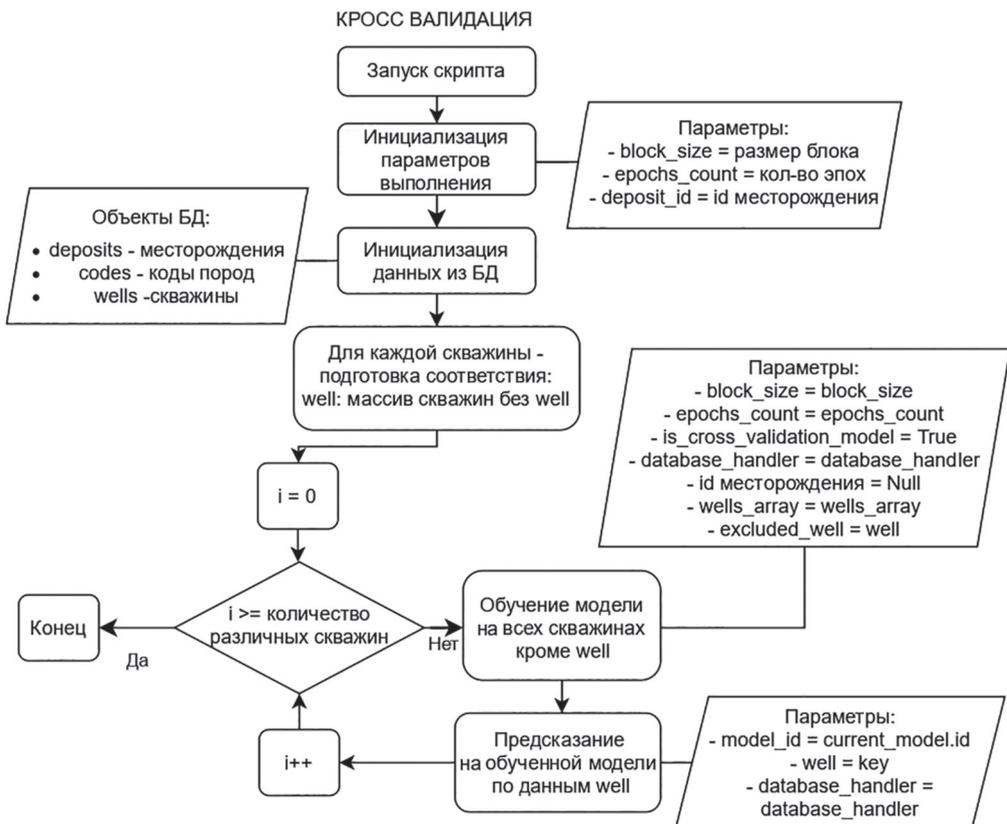


Рис. 7. Блок-схема кросс-валидации при обучении нейронной сети
 Fig. 7. Cross-validation flowchart in neural network learning

Принципы работы нейронной сети и полученные результаты

Для того чтобы алгоритм работал на независимом наборе данных, в процессе обучения используется метод кросс-валидации (рис. 7). Для этого все месторождение было разбито на k частей, затем на $k-1$ частях было произведено обучение модели, а оставшаяся часть была использована для тестирования. Значение переменной k целесообразно принять равным количеству скважин, пробуренных при разведке конкретного месторождения [1, 10, 11].

Получив данные по всем скважинам из базы данных, из $k-1$ скважин создается тренировочный сет. Также создается новая нейронная сеть, которая использует полученный тренировочный сет для обучения. Данная операция проводится k раз, в итоге мы получаем k обученных

нейронных сетей, каждая из которых также хранит информацию о скважине, не участвовавшей в обучении сети [1, 12, 13].

Для каждой скважины рассчитываем ошибку, основываясь на данных по известным блокам и предсказанным по формуле (22), и строим карту относительной погрешности, представленную на рис. 8 [14–16]. Формула расчета относительной погрешности по искомой скважине имеет вид:

$$error.number.well = \frac{falsePredicted.block}{all.number.block} \cdot 100, \quad (22)$$

где $error.number.well$ – относительная погрешность по искомой скважине; $falsePredicted.block$ – неверно предсказанные блоки по искомой скважине; $all.number.block$ – все блоки по искомой скважине.

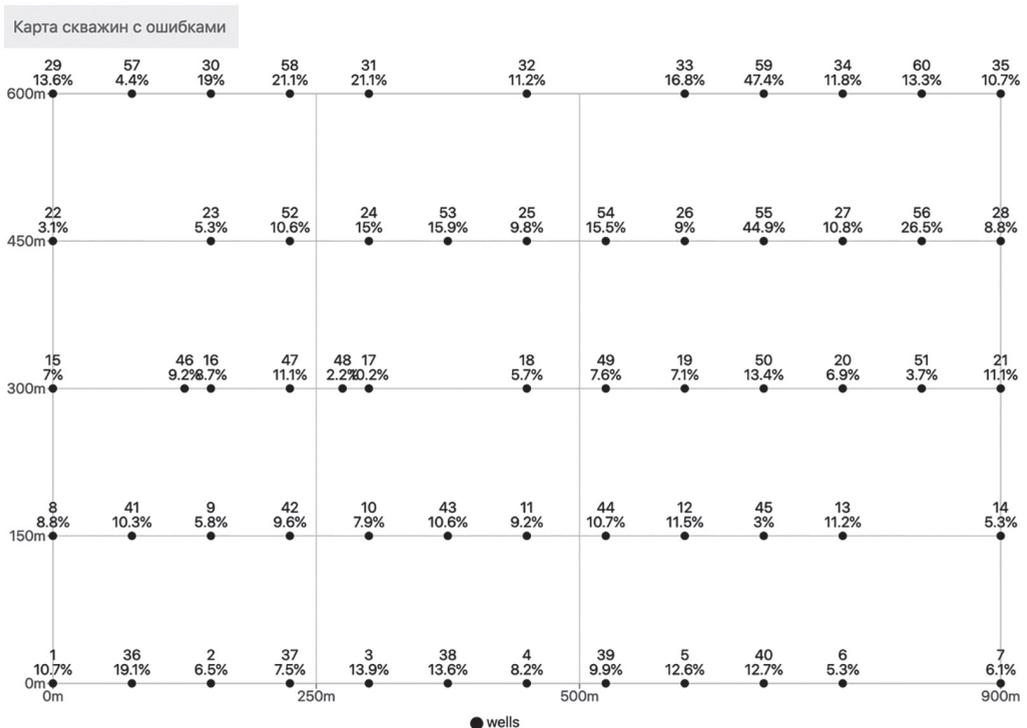


Рис. 8. Карта скважин с относительной погрешностью

Fig. 8. Map of boreholes with relative error

Предсказанные блоки в искомой скважине имеют помимо координат блока и породы вектор выходного слоя искусственной нейронной сети. Нормируем данный вектор и строим график распределения вероятности в зависимости от глубины скважины (рис. 9, см. Приложение, с. 19) [17–19]. Соотношение, полученное путем деления наибольше-

го выхода нейронной сети к сумме всех выходов нейронной сети, будем называть вероятностью предсказания данной породы в этом блоке.

Расположим на графике искомую (оригинальную) скважину с правой стороны и предсказанную с левой стороны графика. На основе знания о том, что вероятность стремится к 0, мы можем

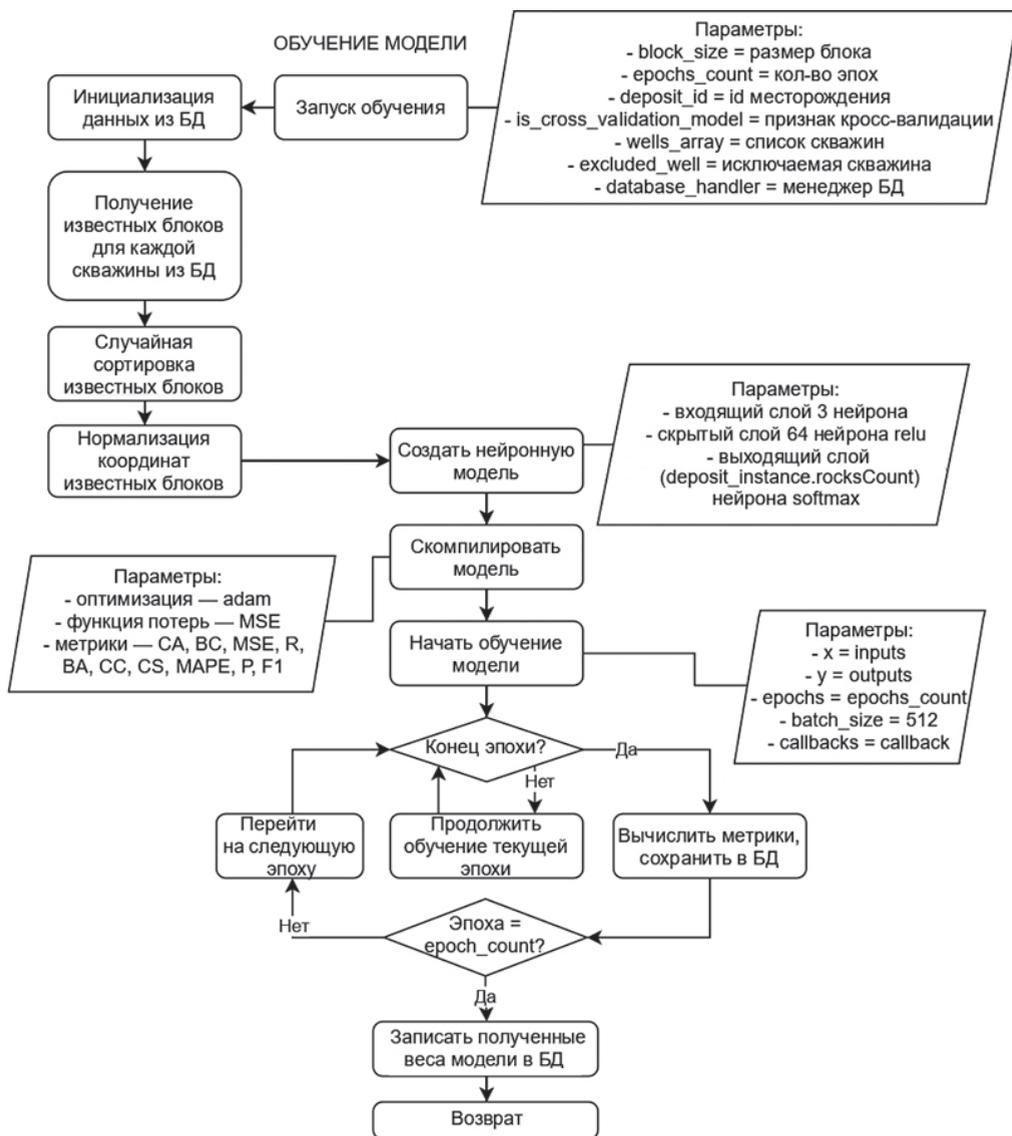


Рис. 10. Блок-схема обучения на данных геологоразведочных работ
Fig. 10. Flowchart of learning using geological exploration data

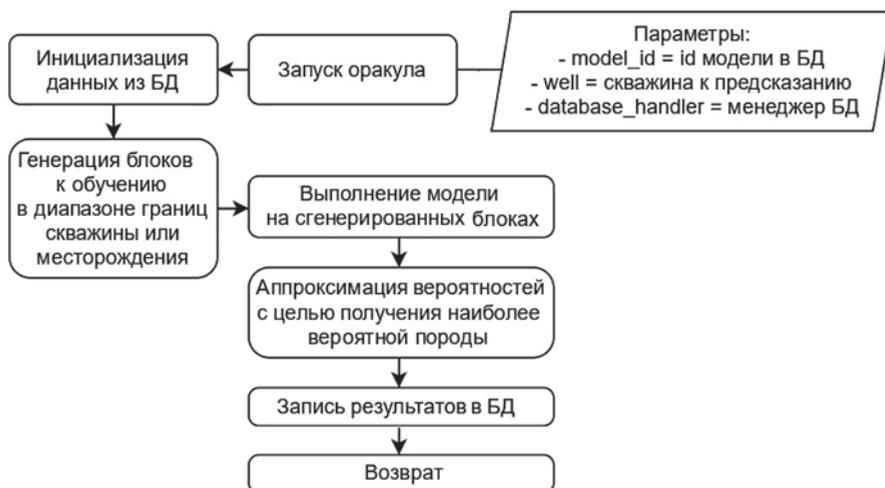


Рис. 11. Блок-схема предсказания месторождения полезного ископаемого или кросс-валидация
 Fig. 11. Flowchart of mineral occurrence prediction or cross-validation

определить литологическую изменчивость.

Полученные блоки служат тренировочным сетом для обучения нейронной сети. На каждой итерации обучения на вход нейронной сети подаются параметры блока — его координаты. Выход нейронной сети представлен слоем из нейронов, количество которых обусловлено количеством разновидностей пород во всем месторождении, и каждый из которых отвечает за вероятность наличия породы в блоке. Диапазон значений на нейронах выходящего слоя $[0,1]$, где 1 — наличие породы, 0 — отсутствие. С целью удобства представления данных выходящего слоя для конечного пользователя, значение нейрона с максимальным значением на выходящем слое округляется до 1, а значения оставшихся нейронов — до 0 [1, 20, 21].

Каждое обучение характеризуется такими параметрами, как структура нейронной сети (количество слоев и нейронов в каждом слое, функции активации), количеством эпох обучения, быстротой обучения. В процессе обучения собираются метрики, необходимые для дальнейшего анализа (рис. 10) [1, 22, 23].

Перед этапом предсказания блочной модели в базе данных мы имеем обученную нейронную сеть (рис. 11). Для предсказания месторождения полезного ископаемого нам необходимо сформировать все блоки, которые формируют данное месторождение. Нормализованные координаты каждого из сформированных блоков подаются на вход нейронной сети. На выходе ожидается массив из чисел, каждое из которых отвечает за вероятность наличия определенной породы в этом блоке. Породу, соответствующую нейрону с наибольшим из этих значений, мы считаем породой предсказанного блока [1, 24].

На основе полученных данных была построена трехмерная литологическая модель месторождения полезных ископаемых, представленная на рис. 12 см. Приложение, с. 19.

Аналогичным способом можно построить блочные трехмерные модели для любых массивов горных пород или отложений — хвостохранилищ, отвалов, шламоохранилищ и т.д.

Подобная модель является примером объемного районирования по заданным параметрам.

Выводы

Разработанный метод позволяет осуществлять оперативное построение трехмерной литологической модели месторождения полезного ископаемого, исключая этап построения каркасов, который на сегодняшний день требует больших временных затрат.

Применение результатов исследования позволяет построить литологические модели, которые могут быть уточнены в полностью автоматическом режиме при появлении дополнительных геологиче-

ских данных в результате эксплуатационной разведки месторождения полезных ископаемых. Это позволит осуществлять оперативное управление геологоразведочными работами, планирование отработки месторождения с целью достижения требуемых значений качественных характеристик рудного сырья с учетом данных, полученных при эксплуатационной разведке.

Метод позволяет строить модели техногенных массивов, задаваясь, например, наличием полезного компонентов.

СПИСОК ЛИТЕРАТУРЫ

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

2. 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.

3. 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.

4. 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.

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

6. 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.

7. 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.

8. 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.

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. Войтеховский Ю. Л., Захарова А. А. Петрографические структуры и равновесия Харди-Вайнберга // Записки Горного института. — 2020. — Т. 242. — С. 133–138. DOI: 10.31897/PMI.2020.2.133.

11. 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.

12. Абрамян Г. О., Абрамян А. Г. О свойствах бинарных функций переходных вероятностей (в приложении к геометрии недр) // Маркшейдерский вестник. — 2019. — № 3(130). — С. 57 — 60.

13. 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.

14. 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.

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

16. Asfahani Jamal, Ghani B. Abdul Ghani Self organizing map neural networks approach for lithologic interpretation of nuclear and electrical well logs in basaltic environment, Southern Syria // Applied Radiation and Isotopes. 2018, vol. 137, pp. 50 — 55. DOI: 10.1016/j.apradiso.2018.03.008.

17. Junxi Chen, Jorge Pisonero, Sha Chen, Xu Wang, Qingwen Fan, Yixiang Duan Convolutional neural network as a novel classification approach for laser-induced breakdown spectroscopy applications in lithological recognition // Spectrochimica Acta. Part B: Atomic Spectroscopy. 2020, vol. 166, article 105801. DOI: 10.1016/j.sab.2020.105801.

18. Valentin M. B., Bom C. R., Coelho J. M., Correia M. D., M.P. de Albuquerque, M.P. de Albuquerque, Fari E. L. A deep residual convolutional neural network for automatic lithological facies identification in Brazilian pre-salt oilfield wellbore image logs // Journal of Petroleum Science and Engineering. 2019, vol. 179, pp. 474 — 503. DOI: 10.1016/j.petrol.2019.04.030.

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

20. 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.

21. Ameer O.-Zaimeche, Zeddouri A., Heddam S., Kechiched R. Lithofacies prediction in non-cored wells from the Sif Fatima oil field (Berkine basin, southern Algeria). A comparative study of multilayer perceptron neural network and cluster analysis-based approaches // Journal of African Earth Sciences. 2020, vol. 166, article 103826. DOI: 10.1016/j.jafrearsci.2020.103826.

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

23. Imamverdiyev Y., Sukhostat L. Lithological facies classification using deep convolutional neural network // Journal of Petroleum Science and Engineering. 2019, vol. 174, pp. 216 — 228. DOI: 10.1016/j.petrol.2018.11.023.

24. Yufeng Gu, Zhidong Bao, Xinmin Song, Shirish Patil, Kegang Ling 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. 179, pp. 966 — 978. DOI: 10.1016/j.petrol.2019.05.032. **PLAS**

REFERENCES

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

3. Sorokina A. S., Zagibalov A. V. Practical application of the Mineframe software in building a block model and calculating the reserves of gold 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.

4. 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.

5. 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].

6. 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. [In Russ]. DOI: 10.25018/0236-1493-2019-11-0-172-179.

7. Shchenkova E. S. Use of statistical and geostatistical apparatus in block modeling (on the example of a vein-type gold deposit). *Geologiya v razvivayushchetsya mire: sbornik nauchnykh statey* [Geology in the Developing World: a collection of scientific articles], Perm', 2019, pp. 517 – 520.

8. Cheklar M., Rybar P., Mihok Ya., Engel Ya. Economic evaluation of mineral deposits on 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.

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. Voitekhovskiy Yu. L., Zakharova A. A. Petrographic structures and Hardy-Weinberg equilibria. *Journal of Mining Institute.* 2020, vol. 242, pp. 133 – 138. [In Russ]. DOI: 10.31897/PMI.2020.2.133.

11. 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.

12. Abramyan G. O., Abramyan A. G. On the properties of binary functions of transition probabilities (in application to the geometry of the subsoil). *Mine Surveying Bulletin.* 2019, no. 3(130), pp. 57 – 60. [In Russ].

13. 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.

14. 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.

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

16. Asfahani Jamal, Ghani B. Abdul Ghani Self organizing map neural networks approach for lithologic interpretation of nuclear and electrical well logs in basaltic environment, Southern Syria. *Applied Radiation and Isotopes.* 2018, vol. 137, pp. 50 – 55. DOI: 10.1016/j.apradiso.2018.03.008.

17. Junxi Chen, Jorge Pisonero, Sha Chen, Xu Wang, Qingwen Fan, Yixiang Duan Convolutional neural network as a novel classification approach for laser-induced breakdown spectroscopy applications in lithological recognition. *Spectrochimica Acta. Part B: Atomic Spectroscopy.* 2020, vol. 166, article 105801. DOI: 10.1016/j.sab.2020.105801.

18. Valentin M. B., Bom C. R., Coelho J. M., Correia M. D., M.P. de Albuquerque, M.P. de Albuquerque, Fari E. L. A deep residual convolutional neural network for automatic lithological facies identification in Brazilian pre-salt oilfield wellbore image logs. *Journal of Petroleum Science and Engineering.* 2019, vol. 179, pp. 474 – 503. DOI: 10.1016/j.petrol.2019.04.030.

19. Voitekhovskiy Yu. L., Zakharova A. A., Klimochkov 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.

20. 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.

21. Ameer O.-Zaimeche, Zeddouri A., Heddam S., Kechiched R. Lithofacies prediction in non-cored wells from the Sif Fatima oil field (Berkine basin, southern Algeria). A comparative study of multilayer perceptron neural network and cluster analysis-based approaches. *Journal of African Earth Sciences*. 2020, vol. 166, article 103826. DOI: 10.1016/j.jafrearsci.2020.103826.

22. Voitekhevsky 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.

23. Imamverdiyev Y., Sukhostat L. Lithological facies classification using deep convolutional neural network. *Journal of Petroleum Science and Engineering*. 2019, vol. 174, pp. 216 – 228. DOI: 10.1016/j.petrol.2018.11.023.

24. Yufeng Gu, Zhidong Bao, Xinmin Song, Shirish Patil, Kegang Ling 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. 179, pp. 966 – 978. DOI: 10.1016/j.petrol.2019.05.032.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Мельниченко Илья Ашотович¹ – канд. техн. наук,

ассистент кафедры, e-mail: kors-ilya@mail.ru,

ORCID ID: 0000-0002-0205-6425,

Кожухов Артем Александрович¹ – аспирант,

e-mail: kozhuh@inbox.ru,

ORCID ID: 0000-0002-9137-6315,

Омельченко Денис Русланович¹ – магистр,

e-mail: omelched@gmail.com,

ORCID ID: 0000-0001-5419-4881,

Мосейкин Владимир Васильевич¹ – д-р техн. наук,

профессор, e-mail: moseykin@inbox.ru,

ORCID ID: 0000-0002-2286-1480,

¹ НИТУ «МИСиС».

Для контактов: Мельниченко И.А., e-mail: kors-ilya@mail.ru.

INFORMATION ABOUT THE AUTHORS

I.A. Melnichenko¹, Cand. Sci. (Eng.),

Assistant of Chair, e-mail: kors-ilya@mail.ru,

ORCID ID: 0000-0002-0205-6425,

A.A. Kozhukhov¹, Graduate Student,

e-mail: kozhuh@inbox.ru,

ORCID ID: 0000-0002-9137-6315,

D.R. Omelchenko¹, Magister, e-mail: omelched@gmail.com,

ORCID ID: 0000-0001-5419-4881,

V.V. Moseykin¹, Dr. Sci. (Eng.), Professor,

e-mail: moseykin@inbox.ru,

ORCID ID: 0000-0002-2286-1480,

¹ National University of Science and Technology «MISiS»,

119049, Moscow, Russia.

Corresponding author: I.A. Melnichenko, e-mail: kors-ilya@mail.ru.

Получена редакцией 10.02.2022; получена после рецензии 11.05.2022; принята к печати 10.09.2022.

Received by the editors 10.02.2022; received after the review 11.05.2022; accepted for printing 10.09.2022.

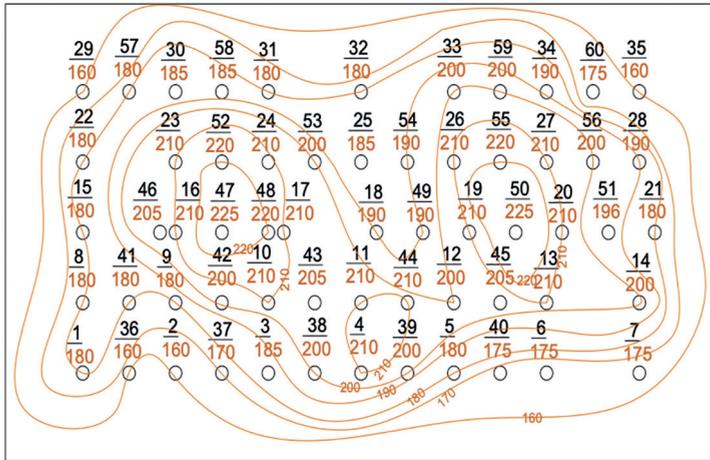


Рис. 1. План поверхности участка месторождения железистых кварцитов
 Fig. 1. Surface plan of ferruginous quartzite deposit site

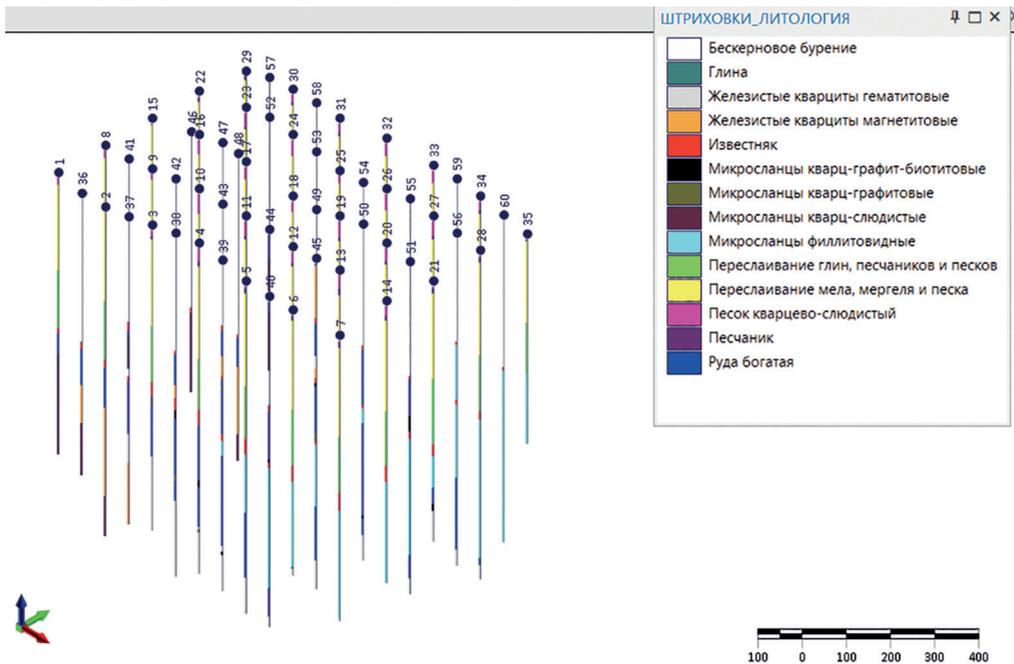


Рис. 4. Трехмерное отображение скважин с литологией
 Fig. 4. 3D image of boreholes and lithology

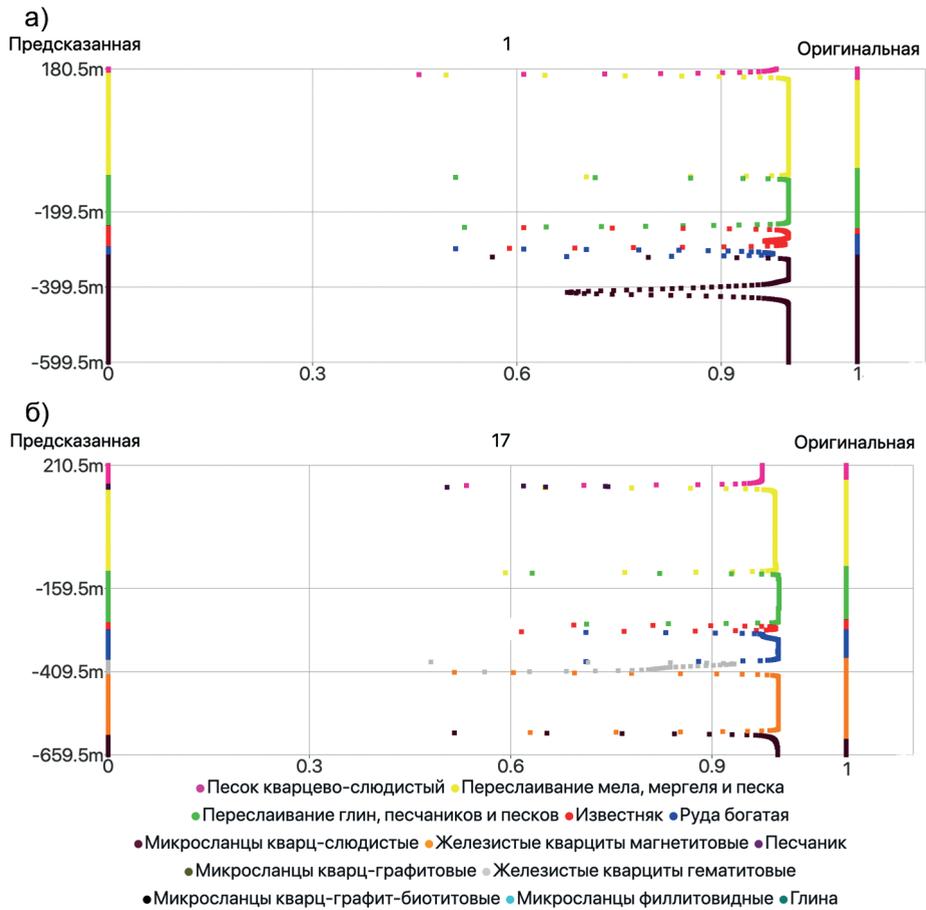


Рис. 9. Распределение вероятности в зависимости от глубины литологических разностей
 Fig. 9. Probability distribution versus depth of lithological types

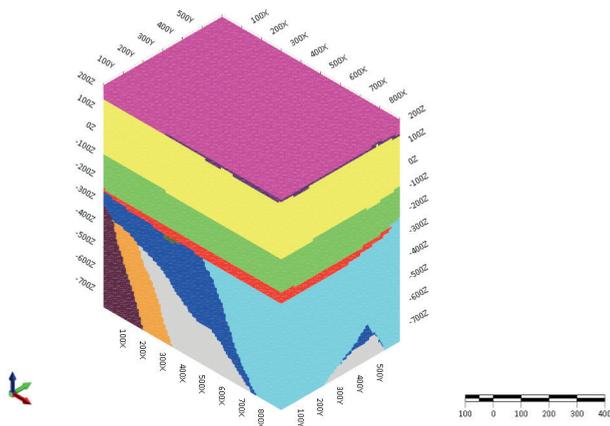


Рис. 12. Блочная трехмерная модель, предсказанная искусственной нейронной сетью
 Fig. 12. 3D block model predicted by artificial neural network