ГИАБ. Горный информационно-аналитический бюллетень /
MIAB. Mining Informational and Analytical Bulletin, 2025;(1-1):178-192
ОРИГИНАЛЬНАЯ СТАТЬЯ / ORIGINAL PAPER

УДК 550.8.05 + 004.94 DOI: 10.25018/0236_1493_2025_11_0_178

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ДЛЯ ПРОГНОЗНОГО КАРТИРОВАНИЯ ЭНДОГЕННЫХ МЕСТОРОЖДЕНИЙ ЗОЛОТА

А.Х.М. Нкрума[1], Т.С. Силина[2], Р.А. Файзрахманов[1]

[1] Пермский национальный исследовательский политехнический университет, Пермь, Россия
[2] Уральский государственный горный университет, Екатеринбург, Россия,
e-mail: tamarasil @mail.ru

Аннотация: Рассмотрен вопрос разработки нейронной сети для моделирования неоднородного распределения минерализации на этапе разведки и освоения золоторудных месторождений. В многочисленных работах по реализации и использованию искусственных нейронных сетей предлагаются методы и модели, адаптированные для стадии регионального (мелкомасштабного) картирования с целью прогноза и оценки больших площадей с высокой степенью минерализации. Эти модели и методы, описанные в литературных источниках, не подходят для прогнозного картирования новых перспективных локальных зон с целью расширения зон эксплуатируемого месторождения, потому что определение классов уровней перспективности полезных ископаемых зависит не только от пространственных параметров (географического положения) целей, но и от других параметров, таких, как значения интенсивности минерализации (например, геохимического содержания минерала) в каждой точке цели, порогового значения минерализации и др. В процессе исследования выполнен анализ существующих методов прогнозного картирования перспективности полезных ископаемых. Сформулирована задача реализации архитектуры нейронной сети. Использовались следующие методы исследования: моделирование неоднородного распределения минерализации с использованием пространственной автокорреляции (зависимый параметр); выбор факторов, влияющих на неоднородность минерализации (независимые параметры); реализация архитектуры нейронной сети. Представлены результаты работы нейросетевой модели на экспериментальном этапе для прогнозного картирования перспективности полезных ископаемых на золоторудном комплексе «Агбау», расположенном в биримских образованиях палеопротерозойского возраста в Западной Африке.

Ключевые слова: искусственная нейронная сеть, прогнозное картирование перспективных месторождений полезных ископаемых, факторы, влияющие на минерализацию, критерий подтверждения минерализации, мелкомасштабное и крупномасштабное картирование, индекс Морана, реализация архитектуры нейронной сети.

Для цитирования: *Нкрума А. Х. М., Силина Т. С., Файзрахманов Р. А.* Нейросетевая модель для прогнозного картирования эндогенных месторождений золота // Горный информационно-аналитический бюллетень. – 2025. – № 1-1. – С. 178–192. DOI: 10.25018/0236_1493_2025_11_0_178.

© А.Х.М. Нкрума, Т.С. Силина, Р.А. Файзрахманов. 2025.

Neural network model for predictive mapping of endogenous gold deposits

A.H.M. Nkrumah[1], T.S. Silina[2], R.A. Faizrakhmanov[1]

[1] Perm National Research Polytechnic University, Perm, Russia
[2] Ural State Mining University, Ekaterinburg, Russia, e-mail: tamarasil @mail.ru

Abstract: The scientific article is devoted to the development of a neural network for modeling the heterogeneous distribution of mineralization in the gold ore complex at the stage of exploration and development of the deposit. In numerous works on the implementation and use of artificial neural networks, methods and models adapted for the stage of regional (small-scale) mapping are proposed in order to predict and evaluate large areas with a high degree of mineralization. These models and methods described in the literature on this topic are not suitable for predictive mapping of new promising local zones in order to expand the exploited field, in the sense that the definition of classes of mineral prospectivity levels depends not only on the spatial parameters (geographical location) of the targets, but also on other parameters, such as the values of mineralization intensity (e.g., geochemical content of the mineral) at each point of the target, the threshold value of mineralization, etc. An analysis of existing methods for predictive mapping of mineral prospects was carried out. The task of implementing a neural network architecture is formulated. The following research methods were used in the work: modeling the heterogeneous distribution of mineralization using spatial autocorrelation. (dependent parameter); factors influencing the heterogeneity of mineralization (independent parameters) were identified and selected; a neural network (ANN) architecture has been implemented. The article presents the results of the neural network model at the experimental stage for predictive mapping of mineral prospects at the Agbau gold complex, located in the Birimians formations of Paleoproterozoic age in West Africa.

Key words: artificial neural network, predictive mapping of mineral prospectivity, factors affecting mineralization, criterion for confirming mineralization, small-scale and large-scale mapping, Moran's index, implementation of neural network architecture.

For citation: Nkrumah A. H. M., Silina T.S., Faizrakhmanov R.A. Neural network model for predictive mapping of endogenous gold deposits. *MIAB. Mining Inf. Anal. Bull.* 2025;(1-1): 178-192. [In Russ]. DOI: 10.25018/0236_1493_2025_11_0_178.

Введение

На сегодняшний день наблюдается повсеместный переход к новым технологическим решениям на этапах изучения горной среды, изыскания способов и средств осуществления геотехнологических процессов, управления и контроля за процессами добычи полезных ископаемых [1 – 2].

Текущей тенденцией для решения проблем при разведке или эксплуатации природных ресурсов является использование алгоритмов машинного или глубокого обучения при картировании перспективных территорий.

С учетом выбранных литотипов авторам удалось определить плотность и раскрытость трещин с помощью алгоритмов машинного обучения, на основе которых рассчитывалась проницаемость трещин в объеме залежи с погрешностью не более 5% [3]. В исследовании К.Н. Майорова, М.Т. Калашниковой [4] авторами используются такие алгорит-

мы, как нейронная сеть, случайный лес, градиентный метод и линейная регрессия. Анализ больших данных с помощью алгоритмов глубокого обучения в горнодобывающем секторе дополнительно обеспечивает эффективную и безопасную добычу твердых полезных ископаемых на основе развития методов прогнозного анализа [5].

Прогнозное картирование перспективности месторождений полезных ископаемых определяется как многоэтапный процесс, направленный на выявление участков с высоким потенциалом и высокой вероятностью обнаружения новых зон локализации полезных ископаемых искомого типа, а также выявление перспективных участков на этапе эксплуатационной разведки месторождений [6 — 8].

Широко применяемое при мелкомасштабной съемке прогнозное картирование перспективности полезных ископаемых позволяет выявлять закономерности между географическим положением известных месторождений полезных ископаемых (целей) и геологическими факторами, обусловившими их образование (признаками). Таким образом, в зависимости от наличия (географического положения) или отсутствия целей устанавливаются два класса уровней перспективности полезных ископаемых, которые соответствуют перспективному и неперспективному классу для изучаемой территории. Однако моделирование перспективности полезных ископаемых на основе бинарной классификации не подходит для выявления новых перспективных участков в процессе расширения эксплуатируемого месторождения в том смысле, что в масштабах месторождения определение классов уровней перспективности полезных ископаемых зависит не только от пространственных параметров (географического положения) целей, но и от других параметров, таких как значения интенсивности минерализации (например, геохимической минерализации) в каждой точке цели, порогового значения минерализации и других физических и геохимических параметров.

Целью работы является разработка архитектуры нейронной сети (ANN) для крупномасштабного прогнозного картирования перспективности локальных зон полезных ископаемых на месторождении.

В отличие от методики на основе бинарной классификации, в данной статье предлагается архитектура многоклассовой нейронной сети для прогнозного картирования перспективности полезных ископаемых в масштабе месторождения.

Для реализации поставленной цели необходимо выполнить следующие задачи:

- проанализировать существующие методы прогнозного картирования перспективности полезных ископаемых;
- сформулировать задачи реализации архитектуры нейронной сети для крупномасштабного прогнозного картирования перспективности полезных ископаемых на основе геолого-геофизических данных;
- разработать архитектуру нейронной сети на основе открытых и фондовых данных геолого-геофизических работ, выполненных на участке;
- провести эксперименты по прогнозному картированию перспективности на примере золотого комплекса «Агбау» (Западная Африка, Кот-д'Ивуар).

Анализ существующих методов прогнозного картирования перспективности полезных ископаемых

В отличие от картографирования, основанного на знаниях, картирование перспективности полезных ископаемых на основе данных хорошо подходит для обнаружения новых объектов разведки в

умеренно разведанных районах [9, 10]. Однако в процессе реализации модели очень часто возникают стохастические и системные неопределенности, исходящие от различных источников. Неопределенности являются результатом неэффективных, недостаточных и неточных данных разведки, чувствительности моделей и неправильного применения методик привязки геопространственных объектов к известным месторождениям полезных ископаемых.

Существующая литература по этому вопросу предлагает четыре основных условия для борьбы с неопределенностями [11]:

- Известные минерализованные объекты на участке должны иметь метку 1, а неминерализованные объекты — метку 0.
- Количество минерализованных целей (метка 1) должно быть равно количеству неминерализованных целей (метка 0).
- Минерализованные объекты (метка 1) должны быть полностью отделены от неминерализованных объектов (метка 0).
- Неминерализованные цели (метка 0) должны выбираться случайным образом, в отличие от минерализованных целей, которые имеют кластерное распределение. Вышеуказанная методология широко используется для прогнозного картирования минерально-ресурсного потенциала в региональном масштабе. Например, Давиран, Гезельбаш использовали эту методологию для создания прогнозных карт минерального потенциала в провинция Голестан (Иран) [11], Ригол-Санчес предлагает модель нейронной сети (ANN — Artificial Neural Network) для распознавания областей с высоким потенциалом золота в Испании [12]. В этих исследованиях созданные алгоритмы машинного обучения направлены на разделение участка исследования на перспективную (метка 1) и неперспективную (метка 0) области, однако эта архитектура не позволяет выполнять крупномасштабное прогнозное картографирование.

Связано это со следующими причинами: объемы разведки для расширения уже эксплуатируемого месторождения проводятся в небольших масштабах; если рассматривать минерализованную зону в мелком масштабе (метка 1), то в крупном масштабе минерализация уже не будет равномерной по всей зоне; для определения классов уровня перспективности при расширении эксплуатации месторождения полезных ископаемых помимо пространственного характера целей минерализации необходимо учитывать дополнительные параметры, такие, как значения содержания полезных ископаемых в каждой цели, пороговое значение минерализации и т.д.

Таким образом, возникла задача крупномасштабного прогнозного картирования перспектив минеральных ресурсов. Для решения этой проблемы был учтен существующий метод и адаптирован к архитектуре нейронной сети.

Постановка задачи реализации архитектуры нейронной сети

Рассмотрим нейронную сеть, состоящую из e нейронов на входном слое, c скрытых слоев, каждый из которых содержит число p нейронов (p может варьироваться от одного скрытого слоя к другому) и s нейронов на выходном слое ($e, c, p, s \in N$). Эта нейронная сеть имеет две функции активации: одну для скрытых слоев и другую для выходного слоя (не исключено, что эти две функции активации одинаковы).

Задача заключается в следующем. В зависимости от эндогенного или экзогенного типа месторождения, которое необходимо исследовать с целью прогноза локальных участков необходимо:

• смоделировать неоднородное распределение показателя минерализации (количества нейронов на выходном слое);

• определить наиболее важные факторы, влияющие на минерализацию (количество нейронов входного слоя);

• определить параметры количества скрытых слоев, нейронов на скрытый слой и функции активации для улучшения производительности модели.

Методы

Разработка архитектуры нейронной сети на основе доступных данных геологической разведки для определения количества нейронов на выходном слое сети

Пространственная автокорреляция измеряет направление линейной связи между элементами переменной (в нашем случае показатели минерализации) и степень интенсивности пространственного паттерна переменной с самой собой, но для определенной окрестности. В исследованиях [13, 14] использовали расчет глобального индекса Морана для моделирования пространственного распределения явлений:

$$I = \frac{N}{\sum_{i=1}^{N}\sum_{j=1}^{N} w_{ij}} \cdot \frac{\sum_{i=1}^{N}\sum_{j=1}^{N} w_{ij}(Z_i - \overline{Z})(Z_j - \overline{Z})}{\sum_{i=1}^{N}(Z_i - \overline{Z})^2}, \quad (1)$$

где I — индекс Морана (от –1 до 1); N — общее количество точек показателей минерализации; Z_i — значение показателя минерализации в точке отбора i в пространстве; $\overline{Z}$ — среднее значение показателя минерализации для N точек отбора проб; Z_j — значение показателя минерализации в точке отбора j в пространстве; w_{ij} — влияние между значениями показателя минерализации в точках отбора i и j в пространстве.

Индекс Морана — это статистический показатель, позволяющий сгруппировать переменную исследования (показатель минерализации) в кластер, а именно: кластер high-high (значения переменной Z_i выше среднего, в близкой к ним окрестности Z_j); кластер low-low (значения переменной Z_i ниже среднего, в окрестности Z_j, которая их напоминает); кластер high-low (значения переменной Z_i выше среднего в окрестности Z_j, которая на них не похожа); кластер low-high (значения переменной Z_i ниже среднего в окрестности Z_j, которая на них не похожа) и кластер random (пара (Z_i, Z_j) статистически незначима — точки, подтверждающие гипотезу о случайности) [13—15].

На рис. 1 изображено неоднородное распределение минерализации в виде классов:

• класс 1. «Минерализованная зона», которая соответствует кластеру high-high;

• класс 2. «Ореол минерализации», соответствует кластеру high-low;

• класс 3. «Низкая минерализованная зона», которая соответствует кластеру low-low;

• класс 4: «Выбросы», соответствует кластеру low-high.

В ходе исследования возникла необходимость определить и ввести пятый класс, который называется «статистически незначимый», соответствует кластеру «random». К этому классу относятся показатели минерализации, у которых вероятность, связанная с индексом Морана (локальным индексом), при нулевой гипотезе (случайном распределении) превышает 5%. Вероятность показателей минерализации при нулевой гипотезе определяется из математического ожидания $E(I_n) = -1/(N - 1)$ (при $I_n = Z_i \cdot w_{ij} \cdot Z_j$: локальный индекс Морана в точке n) и дисперсией $V(I_n) = E(I_n^2) - E^2(I_n)$ [13] в каждой точке показателя минерализации.

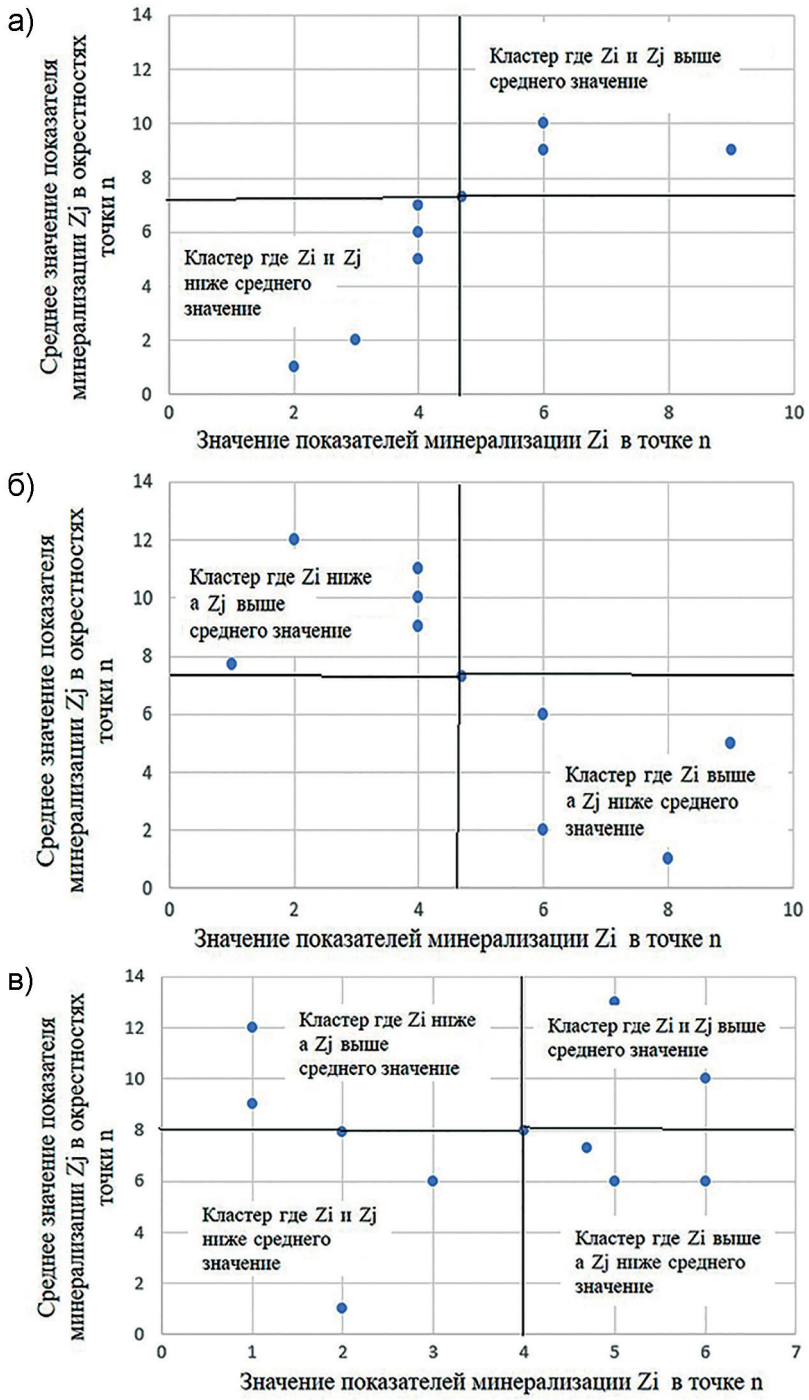

Рис. 1. Индекс Морана I: положительный, и близок к 1 (а); отрицательный и близок к –1 (б); положительный, но не близок к 1 (в)

Fig. 1. Moran's index I: positive and close to 1 (a); negativeve and close to –1 (b); positive but not close to 1 (v)

Разработка архитектуры нейронной сети на основе собранных данных геологической разведки для определения количества нейронов на входном слое сети

Различные кластеры минерализации, выявленные с помощью расчета пространственной автокорреляции, весьма вероятно, согласно альтернативной гипотезе (H1), являются результатом ненаблюдаемых или сложных процессов, которые связывают разные места месторождения и, следовательно, приводят к пространственной структуризации минерализации [15].

Таким образом, попытка спрогнозировать расположение различных скоплений минерализации означает выбор соответствующих параметров, влияющих на формирование минерализации. Однако эти параметры зависят от типа рассматриваемого месторождения.

Что касается экзогенного оруденения, то помимо литолого-тектонического строения необходимо учитывать гидроморфологические параметры. Моделирование этих типов месторождений с помощью нейронной сети сводится к выбору соответствующих параметров на входе сети, отображенных в таблице.

Предлагается разработанная архитектура нейронной сети, изображенная на рис. 2, для прогнозного картирования крупномасштабных перспективных локальных зон на месторождениях полезных ископаемых, зависящих от типа месторождения:

- Факторы, влияющие на установление минерализации, подаются на вход нейронной сети в качестве параметров. Каждый нейрон входного слоя сети фактически представляет собой учитываемый и возникающий в результате влияющих факторов параметр.
- Выходной слой сети содержит пять нейронов, которые представляют неоднородное распределение минерализации, смоделированное индексом Морана. Функция активации, используемая для выходного слоя, является «Sigmoid», поскольку она основана на расчетах вероятности принадлежности к классам для выполнения прогнозирования [16—17].
- Количество скрытых слоев и нейронов на каждый скрытый слой определяется методом «проб и ошибок» на этапах обучения и оценки производительности модели. Изменение этих двух гиперпараметров позволяет улучшить производительность модели.

Классификация параметров на входе в сеть и источник их происхождения по типу моделируемой минерализации
Classification of parameters at the entrance to the network and their source of origin according to the type of modeled mineralization

Тип минерализации	Исходные параметры нейронной сети	Источник данных параметра
Эндогенная	литологический	геологическая карта
	структурно-тектонический	геологическая карта и спутниковый снимок
	гидротермальные процессы	спутниковый снимок
Экзогенная	литологический	геологическая карта
	структурно-тектонический	геологическая карта и спутниковый снимок
	гидрологические	гидрографическая карта
	морфологические	цифровая модель рельефа или топологическая карта

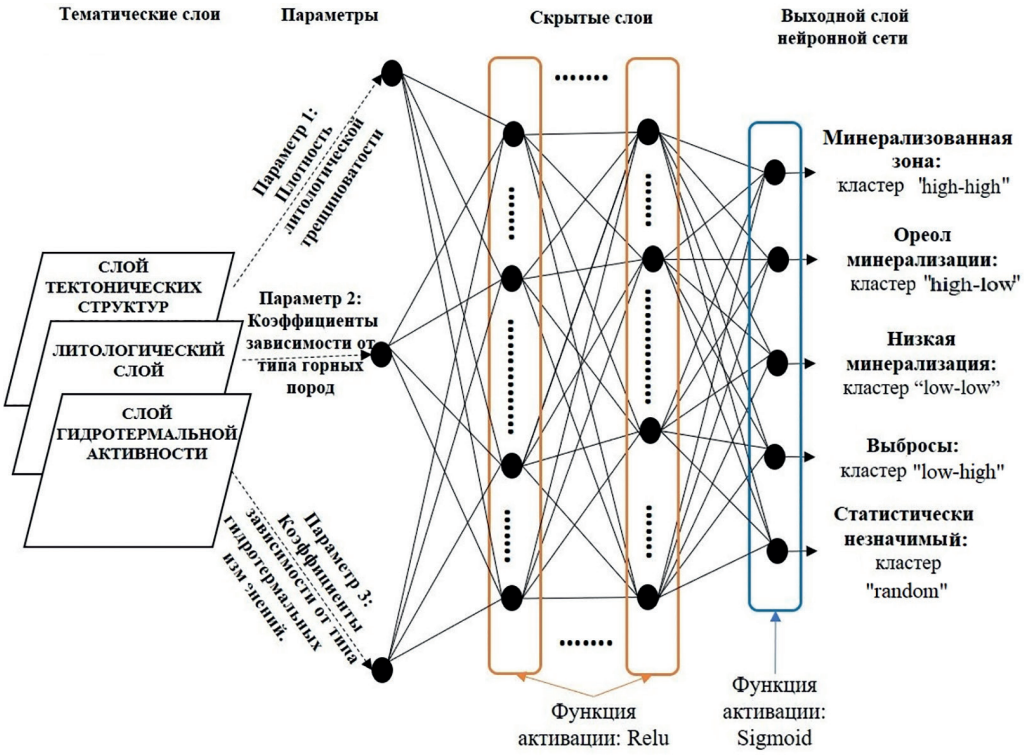

Рис. 2 Архитектура нейронной сети для прогнозного картирования крупномасштабных перспективных эндогенных месторождений полезных ископаемых с учетом трех факторов, влияющих на минерализацию

Fig. 2. Neural network architecture for predictive mapping of large-scale prospective endogenous mineral deposits taking into account three factors affecting mineralization

Результаты

Экспериментальный этап разработки прогнозной карты золоторудного комплекса «Агбау». На экспериментальном этапе использовали нейронную сеть, состоящую из 11 скрытых слоев по 200 нейронов в каждом (рис. 2), для картирования областей, способствующих обнаружению золотого оруденения эндогенного типа на комплексе «Агбау». Для активации функции скрытых слоев была использована функция Relu, поскольку она заставляет сигнал распространяться в сети, когда его суммарное значение превышает определенный порог (обычно 0) [18].

Экспериментальным участком является золотодобывающий комплекс «Агбау», расположенный в юго-западной части Кот-д'Ивуара (Западная Африка) и принадлежащий компании Endeavour Mining Corporation (см. рис. 3)

Согласно отчету Mineral Resource and Reserve Update for the Agbaou Gold Mine Côte d'Ivoire West Africa, опубликованному в 2015 г., месторождение состоит из следующих областей: участка добычи золота (A) и участка разведки (B), изображенных на рис. 3.

Используя данные по содержанию золота (показатель минерализации) участка A (рис. 3), была поставлена задача составить карту наиболее перспективных зон для разведки на участке B. Поскольку минерализация комплекса «Агбау» является эндогенной [19], в ка-

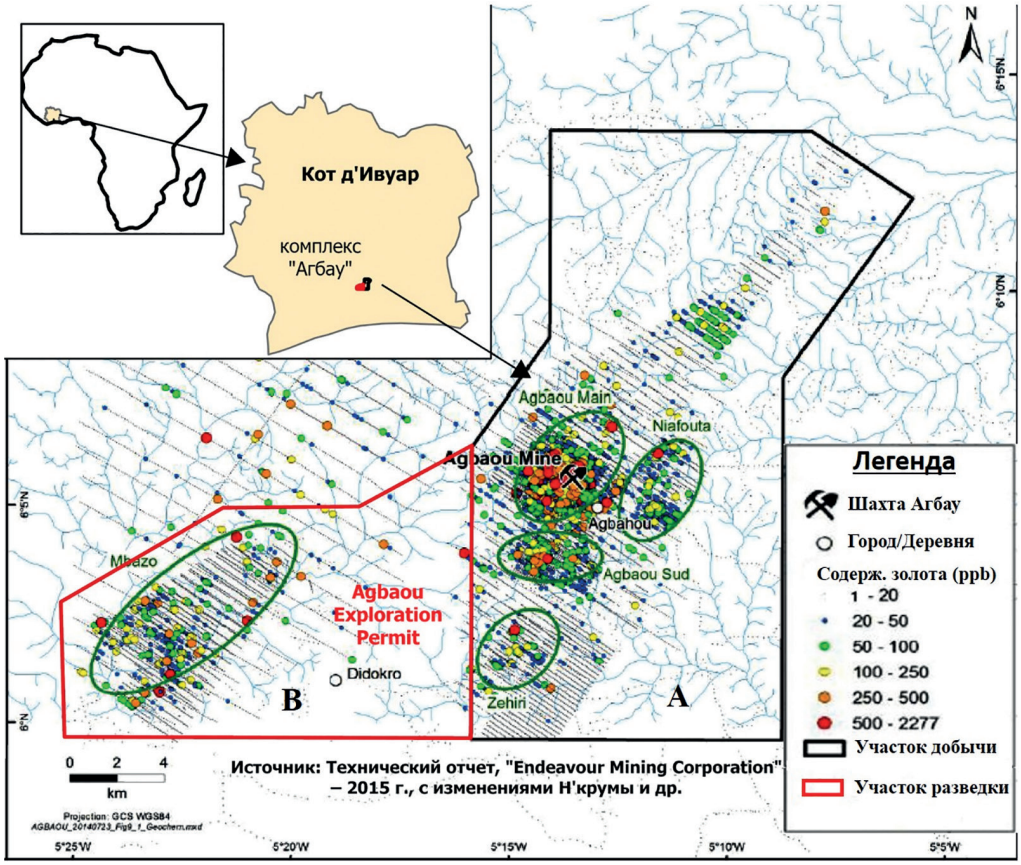

Рис. 3. Золоторудный комплекс «Агбау»: A – место добычи золота; B – разведочный участок для расширения месторождения

Fig. 3. Gold complex «Agbaou»: A – gold mining site; B – exploration area for expansion of the deposit

честве факторов влияния были выбраны литологические единицы, тектонические структуры и гидротермальность [20].

Моделирование неоднородного распределения значений содержания золота описано выше в настоящей статье. Проведена оцифровка комплекса геологических, литолого-структурных карт участка.

Для определения гидротермальности использовались спутниковые снимки Landsate 8 [21—22]. Все эти данные (показатель минерализации и влияющие факторы) были преобразованы в шейпфайлы, которые использовались в качестве входных параметров для нейросетевой модели (рис. 2). Таблицы атрибутов векторных слоев были объединены в обучающие и прогнозные наборы данных в соответствии с пространственным покрытием участка A (обучающий участок) или участка B (прогнозный участок). На этапе обучения и оценки модель достигла общей эффективности 90% за 37 000 итераций с набором данных, содержащим 1183 показателя минерализации с участка A.

На этапе прогнозирования на участке B были предприняты следующие шаги:

• по всему участку были размещены фиктивные точки отбора проб (см. рис. 4, *a*);

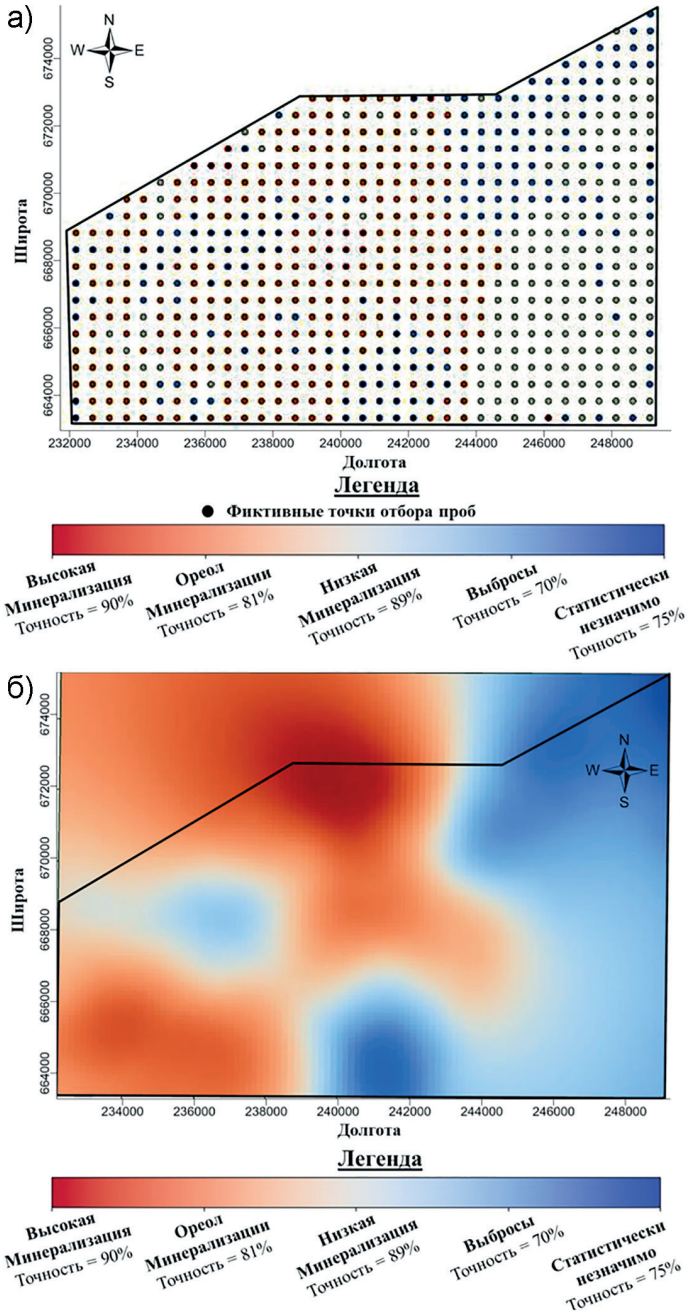

Рис. 4. Прогнозирование на участке B зон, благоприятных для расширения месторождения, разрабатываемого на участке A: пространственное распределение фиктивных прогнозных точек (а); результативная карта, полученная путем применения метода интерполяции по обратному средневзвешенному расстоянию (IDW) результатов прогнозирования в фиктивных точках на участке B (б)

Fig. 4. Forecasting on sit. B of zones favorable for the expansion of the field developed on site A: spatial distribution of fictitious forecast points (a); resulting map obtained by applying the inverse distance weighted (IDW) interpolation method to the forecast results at fictitious points in prospect B (b)

• литологические параметры, параметры гидротермального изменения и плотности трещин в фиктивных точках использовались в качестве входных параметров модели для прогнозирования соответствующих классов содержания минерализации.

На рис. 4, *б* представлена результативная карта прогноза появления золота на участке B, на которой каждый цвет соответствует прогнозному классу. Результативная карта получена путем применения метода интерполяции по обратному средневзвешенному расстоянию

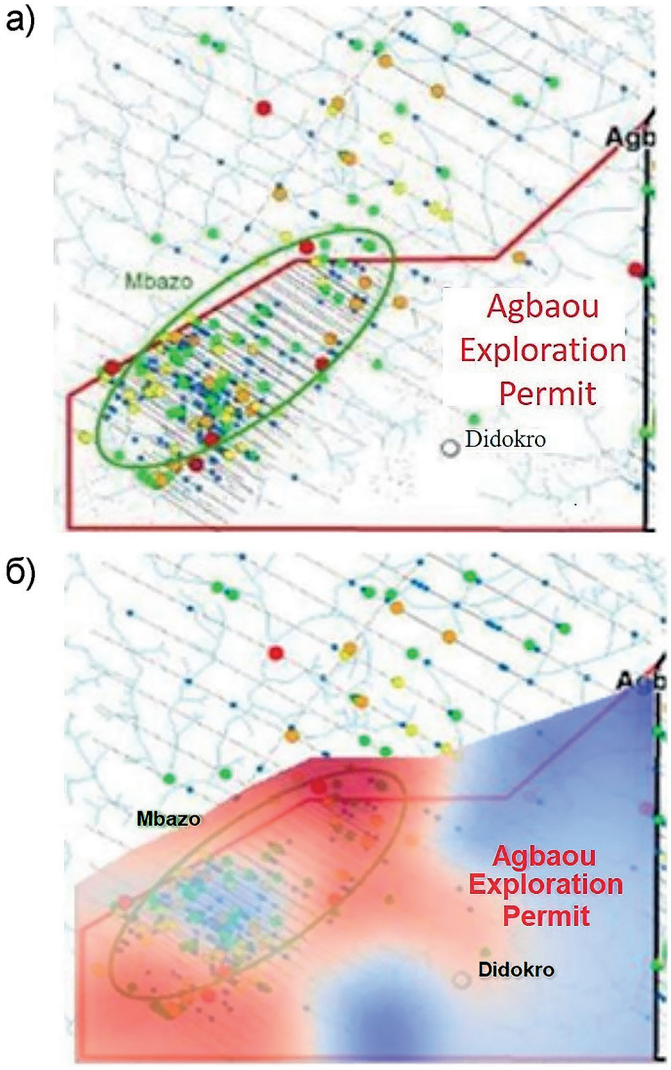

Рис. 5. Сравнительный анализ между предварительными работами на участке B и прогнозной моделью: результат предварительного геохимического исследования почвы, проведенного на участке B (а); наложение прогнозной карты модели на результат геохимических исследований почвы на участке B (б)

Fig. 5. Comparative analysis between preliminary work at site B and model prediction: result of preliminary soil geochemical investigation conducted at site B (a); overlay of the forecast map of the model on the result of soil geochemical studies at prospect B (b)

(IDW — Inverse Distance Weighting) результатов прогнозирования в фиктивных точках на участке.

Полученные результаты сравнивались с предварительными разведочными работами (анализ химического состава почвы), проведенными компанией Endeavour на участке В. На рис. 5, *а* зеленым овалом выделена область, являющаяся перспективной по данным отбора проб и ручного анализа. Модель имеет примерно похожую форму (рис. 5, *б*), что позволяет сделать вывод о ее достаточно высокой точности и реальной применимости.

Заключение

В статье рассмотрен метод, позволяющий спроектировать архитектуру искусственной нейронной сети для прогнозного картирования перспективности полезных ископаемых на этапе разведки и освоения месторождений. Метод предполагает следующее:

1. Количество нейронов на входном слое сети определяется в зависимости от факторов, влияющих на минерализацию, зависящих от типа рассматриваемого месторождения.

2. Количество нейронов на выходном слое сети напрямую связано с различными кластерами (показателями минерализации), которые можно встретить на месторождении. Статистические инструменты пространственной автокорреляции (в нашем случае индекс Морана) позволяют моделировать эти кластеры.

3. Количество слоев кэша и нейронов на каждый слой кэша определяется методом «проб и ошибок». Оптимальное определение этих гиперпараметров позволяет улучшить производительность модели.

Проведен экспериментальный этап на золоторудном комплексе «Агбау» для картирования областей на участке Б, перспективных с точки зрения минерализации.

Предполагаемый метод использования нейросетевой модели, возможно, в дальнейшем успешно применять с целью прогнозирования новых перспективных локальных зон на месторождениях полезных ископаемых.

СПИСОК ЛИТЕРАТУРЫ

1. *Некрасов Е. М.* Принципы выбора рудных районов для поиска золоторудных месторождений // Известия высших учебных заведений. Геология и разведка. — 2022. — № 63(6). — С. 77—86. DOI: 10.32454/0016-7762-2020-63-6-77-86.

2. *Минбалеев А. В.*, *Берестнев М. А.*, *Евсиков К. С.* Регулирование использования искусственного интеллекта в добывающей промышленности // Известия ТулГУ. Науки о Земле. — 2022. — № 2. — С. 509—525. DOI: 10.46689/2218-5194-2022-2-1-509-525.

3. *Потехин Д. В.*, *Галкин С. В.* Применение технологии машинного обучения при моделировании распределения литотипов на пермокарбоновой залежи нефти Усинского месторождения // Записки Горного института. — 2023. — Т. 259. — С. 41—51. DOI: 10.31897/PMI.2022.101.

4. *Майоров К. Н.*, *Калашникова М. Т.* Применение алгоритмов машинного обучения для решения задач нефтегазовой сферы // Интеллектуальные системы в производстве. — 2021. — № 3. — С. 55 — 64. DOI: 10.22213/2410-9304-2021-3-55-64.

5. *Рыльникова М. В.*, *Клебанов Д. А.*, *Макеев М. А.*, *Кадочников М. В.* Применение искусственного интеллекта и перспективы развития аналитических систем больших данных в горной промышленности // Горная промышленность. — 2022. — № 3. — С. 89—92. DOI: 10.30686/1609-9192-2022-3-89-92.

6. *Ghezelbash R., Maghsoudi A., Carranza E. J. M.* Optimization of geochemical anomaly detection using a novel genetic K-means clustering (GKMC) algorithm // Computers & Geosciences. 2020, vol. 134, article 104335. DOI: 10.1016/j.cageo.2019.104335.

7. *Shirmard H., Farahbakhsh E., Müller R. D., Chandra R.* A review of machine learning in processing remote sensing data for mineral exploration // Remote Sensing of Environment. 2022, vol. 268, article 112750. DOI: 10.1016/j.rse.2021.112750.

8. *Шайбаков Р. А.* Использование нейросетевого аппарата для идентификации границ геологических объектов / Технические науки: традиции и инновации. Сборник научных трудов международной научной конференции. — Челябинск, 2012. — С. 8—11.

9. *Валиев Н. Г.*, *Пропп В. Д.*, *Колесников А. А.*, *Беркович В. Х.*, *Шадрин Д. М.* Совершенствование технологии подземной добычи полиметаллических руд на Корбалихинском руднике АО «Сибирь-полиметаллы» // Известия вузов. Горный журнал. — 2022. — № 2. — С. 36—47.

10. *Ghezelbash R., Maghsoudi A., Carranza E. J.* Sensitivity analysis of prospectivity modeling to evidence maps: Enhancing success of targeting for epithermal gold, Takab district, NW Iran // Ore Geology Reviews. 2020, vol. 120, article 103394. DOI: 10.1016/j.cageo.2019.104335.

11. *Daviran M., Maghsoudi A., Ghezelbash R., Pradhan B.* A new strategy for spatial predictive mapping of mineral prospectivity: Automated hyperparameter tuning of random forest approach // Computers & Geosciences. 2021, vol. 148, article 104688. DOI: 10.1016/j.cageo.2021.104688.

12. *Rigol-Sanchez J. P., Chica-Olmo M., Abarca-Hernandez F.* Artificial neural networks as a tool for mineral potential mapping with GIS // International Journal of Remote Sensing. 2003, vol. 24, no. 5, pp. 1151—1156. DOI: 10.1080/0143116021000031791.

13. *Красных С. С.* Пространственная автокорреляционная модель внедрения цифровых технологий в бизнес Российской Федерации // Вестник Академии знаний. — 2020. — № 4 (39). — С. 228—235. DOI: 10.24411/2304-6139-2020-10467.

14. *Shaw K. O.*, *Goïta K., Germain M.* Prospectivity mapping of heavy mineral ore deposits based upon machine-learning algorithms: Columbite-tantalite deposits in West-Central Côte d'Ivoire // Minerals. 2022, vol. 12, no. 11, article 1453. DOI: 10.3390/min12111453.

15. *Osadebey M., Pedersen M., Arnold D., Wendel-Mitoraj K.* Local indicators of spatial autocorrelation (LISA): Application to blind noise-based perceptual quality metric index for magnetic resonance images // Journal of Imaging. 2019, vol. 5, no. 1, article 20. DOI: 10.3390/jimaging5010020.

16. *Осовский С.* Нейронные сети для обработки информации. Пер. с польского И.Д. Рудинского. — М.: Финансы и статистика, 2002. — 344 с.

17. *Portance K., Elysée K., Sow L., Marie L.* Cartographie géotechnique par deep learning — Approche par réseaux de neurones artificiels // European Scientific Journal. 2019, vol. 15, pp. 233—251. DOI: 10.19044/esj.2019.v15n12p233.

18. *Allou G., Boya T. K., Inza C., Eric B., Yacouba C.* Etude metallogenique du prospect aurifere de Aoulo-Aoulo (Zone D'afema, sud est de la Cote d'Ivore) // European Scientific Journal. 2022, vol. 8. DOI: 10.19044/esipreprint.8. 2022.p313.

19. *Гугали Ф., Котельников А. Е.* Особенности размещения золоторудных месторождений Алжира // Известия УГГУ. — 2023. — № 3(71). — С. 32—39. DOI: 10.21440/2307-2091-2023-3-32-39.

20. *Ouedraogo B., Sié P., Issan K.* Apport de la télédétection et des SIG à l'exploration d'un site aurifère: cas de Dodougou au Burkina Faso // Revue Burkinabè de la Recherche. 2020, vol. 39, pp. 71—84.

21. *Pak U. S.*, *Pak C. U.* Detection of hydrothermal alteration zones using Landsat 8 OLI image: A case study of gold prospecting in Nyongwon Area, DPR Korea // Journal of the Indian Society of Remote Sensing. 2021, vol. 49, no. 9, pp. 2249—2259. DOI: 10.1007/s12524-021-01385-8.

22. *El-Desoky H. M., Tende A. W., Abdel-Rahman A. M., Ene A., Awad H. A., Fahmy W., El-Awny H., Zakaly H. M. H.* Hydrothermal alteration mapping using Landsat 8 and ASTER Data and geochemical characteristics of precambrian rocks in the Egyptian shield: A case study from Abu Ghalaga, Southeastern Desert, Egypt // Remote Sensing. 2022, vol. 14, no. 14, article 3456. DOI: 10.3390/rs1414 3456. ГИАБ

REFERENCES

1. Nekrasov E. M. Principles governing the selection of ore regions for gold deposit search. *Proceedings of higher educational establishments. Geology and Exploration*. 2022, no. 63(6), pp. 77—86. [In Russ]. DOI: 10.32454/0016-7762-2020-63-6-77-86.

2. Minbaleev A. V., Berestnev M. A., Evsikov K. S. Regulating the use of artificial intelligence in the mining industry. *News of the Tula state university. Sciences of Earth*. 2022, no. 2, pp. 509 — 525. [In Russ]. DOI: 10.46689/2218-5194-2022-2-1-509-525.

3. Potekhin D. V., Galkin S. V. Application of machine learning technology in modeling lithotype distribution in the Permo-Carboniferous oil deposit of the Usinskoye field. *Journal of Mining Institute*. 2023, vol. 259, pp. 41 — 51. [In Russ]. DOI: 10.31897/PMI.2022.101.

4. Maiorov K. N., Kalashnikov M. T. Application of machine learning algorithms for solving problems in the oil and gas sector. *Intelligent systems in manufacturing*. 2021, no. 3, pp. 55 — 64. [In Russ]. DOI: 10.22213/2410-9304-2021-3-55-64.

5. Rylnikova M. V., Klebanov D. A., Makeev M. A., Kadochnikov M. V. Application of artificial intelligence and the future of big data analytics in the mining industry. *Russian Mining Industry Journal*. 2022, no. 3, pp. 89 — 92. [In Russ]. DOI: 10.30686/1609-9192-2022-3-89-92.

6. Ghezelbash R., Maghsoudi A., Carranza E. J. M. Optimization of geochemical anomaly detection using a novel genetic K-means clustering (GKMC) algorithm. *Computers & Geosciences*. 2020, vol. 134, article 104335. DOI: 10.1016/j.cageo.2019.104335.

7. Shirmard H., Farahbakhsh E., Müller R. D., Chandra R. A review of machine learning in processing remote sensing data for mineral exploration. *Remote Sensing of Environmen*t. 2022, vol. 268, article 112750. DOI: 10.1016/j.rse.2021.112750.

8. Shaibakov R. A. Using a neural network device to identify the boundaries of geological objects. *Tekhnicheskie nauki: traditsii i innovatsii. Sbornik nauchnykh trudov mezhdunarodnoy nauchnoy konferentsii* [Technical sciences: Traditions and innovations. Collection of scientific papers of the international scientific conference], Chelyabinsk, 2012, pp. 8 — 11. [In Russ].

9. Valiev N. G., Propp V. D., Kolesnikov A. A., Berkovich B. H. Improving the technology of underground mining of polymetallic ores at the Korbalikhinsky mine of Sibir-Polymetals JSC. *Minerals and Mining Engineering*. 2022, no. 2, pp. 36 — 47. [In Russ].

10. Ghezelbash R., Maghsoudi A., Carranza E. J. Sensitivity analysis of prospectivity modeling to evidence maps: Enhancing success of targeting for epithermal gold, Takab district, NW Iran. *Ore Geology Reviews*. 2020, vol. 120, article 103394. DOI: 10.1016/j.cageo.2019.104335.

11. Daviran M., Maghsoudi A., Ghezelbash R., Pradhan B. A new strategy for spatial predictive mapping of mineral prospectivity: Automated hyperparameter tuning of random forest approach. *Computers & Geosciences*. 2021, vol. 148, article 104688. DOI: 10.1016/j.cageo.2021.104688.

12. Rigol-Sanchez J. P., Chica-Olmo M., Abarca-Hernandez F. Artificial neural networks as a tool for mineral potential mapping with GIS. *International Journal of Remote Sensing*. 2003, vol. 24, no. 5, pp. 1151 — 1156. DOI: 10.1080/0143116021000031791.

13. Krasnykh S. S. Spatial autocorrelation model of the introduction of digital technologies into the business of the Russian Federation. *Bulletin of the Academy of Knowledge*. 2020, no. 4 (39), pp. 228 — 235. [In Russ]. DOI: 10.24411/2304-6139-2020-10467.

14. Shaw K. O., Goïta K., Germain M. Prospectivity mapping of heavy mineral ore deposits based upon machine-learning algorithms: Columbite-tantalite deposits in West-Central Côte d'Ivoire. *Minerals*. 2022, vol. 12, no. 11, article 1453. DOI: 10.3390/min12111453.

15. Osadebey M., Pedersen M., Arnold D., Wendel-Mitoraj K. Local indicators of spatial autocorrelation (LISA): Application to blind noise-based perceptual quality metric index for magnetic resonance images. *Journal of Imaging*. 2019, vol. 5, no. 1, article 20. DOI: 10.3390/jimaging5010020.

16. Osovsky S. *Neyronnye seti dlya obrabotki informatsi*i. Per. s pol'skogo I.D. Rudinskogo [Neural networks for information processing. Transl. from Polish Rudinsky I. D.], Moscow, Finansy i statistika, 2002, 344 p.

17. Portance K., Elysée K., Sow L., Marie L. Cartographie géotechnique par deep learning — Approche par réseaux de neurones artificiels. *European Scientific Journal*. 2019, vol. 15, pp. 233 — 251. DOI: 10.19044/esj.2019.v15n12p233.

18. Allou G., Boya T. K., Inza C., Eric B., Yacouba C. Etude metallogenique du prospect aurifere de Aoulo-Aoulo (Zone D'afema, sud est de la Cote d'Ivore). *European Scientific Journal*. 2022, vol. 8. DOI: 10.19044/esipreprint.8. 2022.p313.

19. Gougali F., Kotel'nikov AE., The features of the placement of gold deposits in Algeria. *News of the Ural State Mining University*. 2023, no. 3(71), pp. 32 — 39. [In Russ]. DOI: 10.21440/2307-2091-2023-3-32-39.

20. Ouedraogo B., Sié P., Issan K. Apport de la télédétection et des SIG à l'exploration d'un site aurifère : cas de Dodougou au Burkina Faso. *Revue Burkinabè de la Recherche*. 2020, vol. 39, pp. 71 – 84.

21. Pak U. S., Pak C. U. Detection of hydrothermal alteration zones using Landsat 8 OLI image: A case study of gold prospecting in Nyongwon Area, DPR Korea. *Journal of the Indian Society of Remote Sensing*. 2021, vol. 49, no. 9, pp. 2249 – 2259. DOI: 10.1007/s12524-021-01385-8.

22. El-Desoky H. M., Tende A. W., Abdel-Rahman A. M., Ene A., Awad H. A., Fahmy W., El-Awny H., Zakaly H. M. H. Hydrothermal alteration mapping using Landsat 8 and ASTER Data and geochemical characteristics of precambrian rocks in the Egyptian shield: A case study from Abu Ghalaga, Southeastern Desert, Egypt. *Remote Sensing*. 2022, vol. 14, no. 14, article 3456. DOI: 10.3390/rs14143456.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Ассуму Херве Мэтью Нкрума[1] – аспирант,
e-mail: nkvetcho@gmail.com,
Силина Тамара Сергеевна – канд. геол.-минерал. наук,
доцент, Уральский государственный
горный университет, e-mail: tamarasil @mail.ru,
Файзрахманов Рустам Абубакирович[1] – д-р экон. наук,
профессор, зав. кафедрой,
e-mail: Fayzrakhmanov@gmail.com,
[1] Пермский национальный исследовательский политехнический университет.
Для контактов: Силина Т.С., e-mail: tamarasil @mail.ru.

INFORMATION ABOUT THE AUTHORS

Nkrumah Assoumou Herve Mathieu[1], Graduate Student,
e-mail: nkvetcho@gmail.com,
T.S. Silina, Cand. Sci. (Geol. Mineral.),
Assistant Professor, Ural State Mining University,
620144, Ekaterinburg, Russia,
e-mail: tamarasil @mail.ru,
R.A. Faizrakhmanov[1], Dr. Sci. (Econ.),
Professor, Head of Chair,
e-mail: Fayzrakhmanov@gmail.com,
[1] Perm National Research Polytechnic University,
614990, Perm, Russia.
Corresponding author: T.S. Silina, e-mail: tamarasil @mail.ru.

Получена редакцией 16.07.2024; получена после рецензии 26.11.2024; принята к печати 10.12.2024.
Received by the editors 16.07.2024; received after the review 26.11.2024; accepted for printing 10.12.2024.