

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ГЕОЛОГИЧЕСКОГО ПОЛЯ МЕСТОРОЖДЕНИЯ

И.С. Бондаренко

НИТУ «МИСиС», Москва, Россия, e-mail: innasbondarenko@gmail.com

Аннотация: Рассмотрены вопросы прогнозирования качества добываемых руд на примере железорудных и медно-молибденовых месторождений на основе нейросетевого подхода. Добыча руд на современных горных предприятиях осуществляется в разных точках рудного поля, удаленных одна от другой в горизонтальной и вертикальной плоскостях, и если масса добытой руды обычно известна, то ее качественные свойства характеризуются показателями, являющимися мерой количественного представления средних качественных свойств руд в конкретной позиции. Представлен краткий анализ характеристик геологического (геохимического) поля месторождений, которые возможно использовать для прогнозирования на основе данных детальной разведки, показателей, характеризующих качество руд месторождения. Рассмотрены вопросы слабой формализации закономерности их пространственных изменений в исследуемых объемах недр. Предлагается методика выбора подходящей по определенному критерию нейросетевой модели детерминированной составляющей в условиях ограниченного набора данных. Проводится статистический анализ полученных результатов с построением регрессионной модели дисперсии случайной компоненты пространственной переменной, что позволяет оценивать точность результатов в любой точке поля пространственной переменной. Доказывается возможность построения достаточно точной модели геологического поля месторождения при наличии выявления нейросетью определенных закономерностей в данных.

Ключевые слова: нейронная сеть, моделирование, анализ данных, формализация, автоматизация контроля качества, геологическое поле, геологоразведка, опробирование руд.

Для цитирования: Бондаренко И. С. Нейросетевое моделирование геологического поля месторождения // Горный информационно-аналитический бюллетень. – 2023. – № 6. – С. 19–38. DOI: 10.25018/0236_1493_2023_6_0_19.

Neural network modeling of geological field of mineral deposit

I.S. Bondarenko

National University of Science and Technology «MISIS», Moscow, Russia,
e-mail: innasbondarenko@gmail.com

Abstract: Prediction of the produced ore quality using neural networks is discussed as a case-study of iron ore and copper–molybdenum deposits. Currently mines recover ore at different sites of an ore field, remote from each other horizontally and vertically, and while the mass of the extracted ore is usually known, the qualitative properties of ore are characterized by indicators which are the quantification of the averaged qualitative properties of ore in a certain production site. A brief analysis of characteristics of a mineral deposit geology (geochemistry)

is given; these characteristics can help predict ore qualities using the detailed exploration data. The issues of poor formalization of spatial variation patterns in subsoil are addressed. A procedure is proposed for selecting a deterministic component suitable by a certain criterion of the neural network model in the conditions of a limited set of data. The statistical analysis of the results is carried out with a regression model of dispersion in a random component of a spatial variable, which enables assessment of data precision at any point of a spatially variable field. It is proved that it is possible to construct a sufficiently precise model of geological field of a mineral deposit given the neural network has revealed certain regular data patterns.

Key words: neural network, modeling, data analysis, formalization, quality control automation, geological field, geological exploration, ore assaying.

For citation: Bondarenko I.S. Neural network modeling of geological field of mineral deposit. *MIAB. Mining Inf. Anal. Bull.* 2023;(6):19-38. [In Russ]. DOI: 10.25018/0236_1493_2023_6_0_19.

Введение

В последнее десятилетие наблюдается кратное увеличение потребляемых гео-ресурсов, что предопределяет интенсификацию их извлечения из недр [1, 2]. Человечеству необходимо все больше и больше энергии [3], и тут возникает несколько задач. Помимо интенсификации добычи, это задачи рационального использования полезных ископаемых и эффективного использования энергии [4–6]. Извлечение георесурсов — это достаточно сложный и многоступенчатый процесс [7], который зачастую требует строгого и достаточно быстрого принятия решения [8], обеспечивающего безопасное ведение горных работ [9–11] и их эколого-экономическую эффективность [12, 13].

В связи с интенсификацией извлечения полезного ископаемого происходит постепенное их истощение [14], что предопределяет переход на добычу низкосортного сырья [15–17] или руд сложного вещественного состава [18].

В горнорудной промышленности качество концентрата и его себестоимость в значительной степени зависят от однородности исходного сырья, поступающего в переработку [19, 20]. Высокие кон-

диционные требования к руде, поставляемой на обогащение, позволяют снизить простои из-за переналадки процесса обогащения, уменьшить потери ценного компонента в отходах обогащения, сократить расход реагентов [21]. Технологическая эффективность стабилизации качественных свойств рудного сырья доказана многими исследователями и практикой работы горно-обогатительных предприятий [22, 23].

Высокая степень однородности качества рудного сырья может быть обеспечена за счет стабилизации качества, достигаемой применением специальной технологии добычи, транспортирования, складирования и отгрузки руды. Сам процесс стабилизации качества руд основывается на информации, полученной при апробировании руд в недрах, потоках, транспортных емкостях и на складах [24]. Такая информация интересна не только характеристиками изменчивости и взаимосвязи наблюдаемых параметров, например, концентраций компонентов, но и закономерностями их пространственных изменений в исследуемых объемах недр.

Статические модели здесь непригодны. Это связано с тем, что любой стати-

ческий показатель отражает только средний уровень изменчивости исследуемого признака, независимо от пространственного расположения точек взятия проб, тогда как закономерности в их пространственном расположении может и не быть или она может быть разной. Кроме того, статические характеристики дают объективную оценку наблюдаемого уровня изменчивости признака только в том случае, если данные выборки представляют собой независимый набор случайных величин. Эти недостатки статических методов в некоторой степени устраняются математическим моделированием полей геологических признаков при использовании современных математических характеристик.

Далее будут рассмотрены исследуемая область на предмет анализа исходных данных и процесс создания модели пространственных переменных (ПП) геологического поля¹ месторождения (ГПМ) на основе нейросетевого метода искусственного интеллекта.

Анализ данных детальной разведки, технологического картирования и опробование руд

Первичная информация, характеризующая качество руд, обычно представлена пробами детальной разведки, получаемыми при опробовании керна разведочных скважин. Для железорудных месторождений эти пробы размещаются в плоскости разведочных профилей по сетке 100×100, 100×50 м. В пределах высоты выемочного уступа одна проба характеризует блок руды массой 150—200 тыс. т. Учитывая низкую представительность такой пробы, ее практическая ценность в целях управления качеством руд при добыче незначительна. Однако

опробование рудного керна производится непрерывно, интервалами 2—3 м, что позволяет определить по совокупности интервальных проб корреляционные и спектральные характеристики по оси скважин, а также и дисперсию интервальных проб.

Учитывая, что при открытых работах опробуются буровзрывные скважины, расстояние между которыми колеблется в пределах 5—7 м, эти модульные пробы образуют основной массив информации, характеризующий качество руды. В среднем они представляют 1000 т руды.

Для определения изменчивости качества руды ниже приведены результаты экспериментального опробования двух кусков руды (богатой и бедной), выполненного на одном из рудников (табл. 1).

Два куска руды размером 200 мм были разделены на 10 частей каждый, и для

Таблица 1

Результаты опробования руды Results of ore testing

№ пробы	Богатая руда, Fe, % / S, %	№ пробы	Бедная руда, Fe, % / S, %
1874	65,3/0,11	1884	44,3/0,47
1875	60,3/0,13	1885	43,6/0,36
1876	62,4/0,17	1886	29,8/0,97
1877	67,0/0,09	1887	59,1/0,19
1878	63,9/0,09	1888	37,0/0,64
1879	63,7/0,14	1889	53,3/0,24
1880	64,2/0,08	1891	39,8/0,48
1881	63,3/0,21	1892	43,7/0,45
1882	65,3/0,06	1893	49,8/0,56
1883	59,0/0,16	1894	64,0/0,21
—	—	1895	38,2/0,43
Среднее	63,56/0,132	Среднее	43,86/0,48

¹ Геологическое поле – пространство земной коры, каждому элементарному объему которого может быть поставлено в соответствие определенное значение геологического свойства, являющееся для статических моделей функцией координат пространства, а для динамических моделей еще и времени.

каждой порции были получены анализы содержания железа и серы.

В богатом куске руды содержание железа колебалось в пределах 59–65,3%, серы – 0,06–0,21%, коэффициенты вариации составили соответственно $v_{Fe} = 3,46\%$, $v_S = 3,0\%$. В бедной руде содержание железа изменялось в пределах 29,8–59,5% ($v_{Fe} = 18,3\%$). Таким образом, взаимная корреляция показателей качества даже в небольшом куске руды весьма низка.

Разница содержаний железа в интервальных пробах, отобранных при неодинаковом интервале между пробами, для этого месторождения определялась по совокупности, состоящей более чем из 8 тысяч интервальных проб. Средняя разница содержаний, как показал анализ, не зависит от интервала между пробами и для богатых руд равна 3,2%, для бедных руд – 13,0%, коэффициент ковариации $r = 0,13$. Таким образом, колебания содержания железа в рудах образуют практически «белый шум».

При опробовании скважин детальной разведки и модульных проб получают и другую информацию, характеризующую добываемую руду. По образцам руды определяют текстуру рудоминеральной вкрапленности, крепость руды, ее плотность, содержание в руде попутных компонентов, силикатный модуль, степень окисленности и др. Все эти данные позволяют выделить минералогические и технологические типы руды, определить ее обогатимость. Обычно эти данные сосредоточены в материалах по подсчету запасов и отнесены к крупным блокам руды. Информацию, приуроченную к блокам руды, которые ограничены высотой выемочного уступа, чаще всего получают интерполяцией проб. Ее достоверность полностью зависит от спектрального состава дисперсии показателей [25].

Вся информация, характеризующая запасы руд и полученная при детальной

и эксплуатационной разведке, приурочена к разведочным профилям. Обычно подсчет запасов крупных крутонаклонных месторождений производится методом вертикальных сечений. Учитывая, что открытая отработка залежи осуществляется горизонтальными слоями (уступами), пересчет запасов производится поуступно. При этом вся информация, характеризующая технологические показатели руд, а также содержание в них основных и попутных компонентов, переносится на поуступные планы, включая следующую совокупность данных границы бортового содержания основного компонента: проекции разведочных скважин на плоскость уступа; содержание компонентов в интервалах опробования, пересекающих уступ; показатели, характеризующие текстурные свойства руд и их крепость; границы конкретных технологических сортов руд.

Сущность технологического картирования состоит в создании наглядной графической документации, базирующейся на поуступных планах и включающей в себя всю информацию, на основе которой осуществляется управление технологическим процессом обогащения.

При обогащении железных руд применяется магнитная сепарация, поэтому при технологическом картировании железорудных месторождений на планы наносится следующая информация:

- содержание общего и магнитного железа в руде для окисленных руд;
- содержание серы;
- доля окисленных руд;
- диаметр рудоминеральной вкрапленности;
- крепость руды;
- технологические показатели обогащения, которые установлены при испытании проб на опытной обогатительной фабрике.

Все эти показатели наносятся на план в виде численной информации или сово-

купности изолиний равного значения. В некоторых случаях между тем или иным показателем, характеризующим качество руды, и показателями обогащения установлена надежная корреляционная связь, например, $\gamma = \varphi(a, a_M)$, $\theta = \psi(d, t, a_M)$, $\beta = \varepsilon(d, t)$, представляется возможным построить графики изолиний равного значения для ожидаемых технологических показателей (выхода концентрата, содержания железа в хвостах и концентрате). Подобные графики очень важны для прогнозирования показателей обогащения еще в процессе планирования горных работ.

Чаще всего для построения графика изолиний равного значения технологических показателей обогатительного процесса используются результаты обогащения проб, отобранных из шлама буровзрывных скважин. При этом пробы подвергаются истиранию до заданной степени крупности и обогащаются с помощью магнитных анализаторов. В результате получают прогнозные показатели обогатительного процесса, включая такие показатели, как выход концентрата, содержание в нем железа, содержание железа в хвостах. Это дает возможность после нанесения результатов на прогнозные планы уступов производить отгрузку руды на дробильно-обогатительную фабрику из участков экскаваторных заходок, на которых эти параметры соответствуют их плановому значению.

Параметры обогатительного процесса, которые установлены из результатов опытного обогащения, довольно четко коррелируются с их реальными значениями, полученными в промышленных условиях. Так, содержание железа в концентрате Костомукшской обогатительной фабрики, полученное на рудоиспытательной станции, β_r , связано с фактическим его значением β_ϕ уравнением $\beta_\phi = 2,28\beta_r - 88,8$.

Если дисперсия показателей, характеризующих качество руд, представлена

в основном высокочастотным спектром, то технологическое картирование с помощью графиков изолиний равных значений показателей затруднительно.

Графики изолиний приобретают характер сложного «мелкосопочного» рельефа, при этом достоверность таких графиков низка. В этом случае принято осуществлять сглаживание показателей, усредняя тем самым высокочастотную составляющую. Полученный по сглаженным данным график изолиний будет характеризовать основные закономерности размещения показателей, представленные остаточной низкочастотной составляющей спектра.

Графики технологического картирования являются основной информацией, по которой осуществляется управление процессами обогащения руд.

В процессе исследования было важно рассмотреть методы опробования горной массы на предмет выявления дестабилизирующих факторов, влияющих на точность построения графиков технологического картирования.

Ядерно-физическое опробование руд широко применяется при разведке полезных ископаемых, и его методы детально освещены в специальной литературе.

Опробование руды в вагонетках применяется на урановых, оловянных, флюоритовых, бериллиевых, вольфрамовых и ртутных месторождениях. При этом применяются гамма-гамма метод ГГМ, гамма-абсорбционный (ГАМ), фото-нейтронные, рентгенорадиометрические и флюоресцентные методы.

Гамма-абсорбционный метод, известный под названием метода поглощения гамма-излучения, является одним из наиболее распространенных ядерно-физических методов контроля качества минерального сырья. Он основан на измерении поглощающей способности анализируемого материала при его просвечивании потоком гамма-квантов оп-

ределенного спектрального состава. Гамма-абсорбционный метод реализуется в геометрии просвечивания, когда детектор и источник располагаются диаметрально противоположно друг к другу и по разные стороны от контролируемого объекта. Существующие разновидности ГАМ зависят прежде всего от энергии используемого первичного гамма-излучения. Примером достаточно успешного применения радиометрических методов опробования руд в конвейерных потоках является действующая система на предприятии «Апатит» и Донском хромитовом месторождении.

Применение гамма-абсорбционного метода предполагает строгое постоянство толщины просвечиваемого слоя и резкое отличие в порядковых номерах элемента — поглотителя гамма-излучения и элементов-исполнителей (бинарная смесь). Точность измерений метода зависит и от наличия дестабилизирующих факторов: изменения в гранулометрическом и минеральном составе, влажности, толщине просвечиваемого слоя, плотности. Для снижения влияния мешающих факторов применяют двухлучевой гамма-абсорбционный способ, сущность которого заключается в просвечивании двумя пучками гамма-квантов с резко различными энергиями.

К основным методам апробирования руд следует отнести магнитометрические методы.

Измерение магнитной восприимчивости железных руд обычно проводится датчиками индуктивного или индукционного типа. Широкое распространение получили последние. Наибольшее надежное теоретическое и аппаратное обоснование имеют конструкции, применяемые при исследовании разведочных и буровых скважин. В настоящее время они внедрены на конвейерных трактах основных горнодобывающих предприятий черной металлургии и зарекомендовали

себя как высоконадежные и наиболее точные системы непрерывного контроля содержания магнитного железа в руде [26, 27].

Основные проблемы автоматизации контроля и регулирования качества железорудного сырья возникают при исследовании различных технологических потоков железной руды, при ее транспортировании конвейерами. Железорудное сырье после дробления или измельчения представляет собой изотропный по магнитным свойствам материал. Из-за колебания нагрузки на конвейере исследуемый слой имеет переменную мощность. Поэтому одной из специфических характеристик конвейерного датчика является слой насыщения, под которым понимают такой слой, любое увеличение которого приводит к изменению сигнала измерительной информации на величину, не превышающую порога чувствительности датчика.

Магнитометрические системы более точно характеризуют не содержание магнитного железа, а магнитную массу материала на ленте. Это следует учитывать при стабилизации загрузки конвейерного полотна. Создаваемое ими магнитное поле охватывает только некоторый слой материала, прилипающий к ленте. При значительном недогрузе ленты их показания изменяются так же, как и при снижении содержания магнитного железа в руде. По этой причине показания систем надежно характеризуют содержание магнитного продукта только на том интервале длины ленты, на котором усредняется погонная загрузка. В зависимости от дисперсии погонной загрузки и спектральной плотности дисперсии этот интервал изменяется.

Таким образом, данные методы позволяют на основе анализа данных интервальных или модульных проб горной массы в достаточной мере точно прогнозировать рассмотренные выше пока-

затели, характеризующие качество руд месторождения, но слабо формализуют закономерности их пространственных изменений в исследуемых объемах недр.

Применение интеллектуальных систем управления, создание цифровых двойников горных производств позволяют проводить обработку информации и управлять процессами в реальном времени с высокой точностью [28 – 30]. А стратегическое планирование помогает разрабатывать технологии освоения месторождения на десятки лет вперед [31 – 33].

Моделирование пространственных переменных с помощью нейронных сетей

Для решения слабоформализованных задач сегодня довольно широко используются нейронные сети (НС), как один из эффективных методов искусственного интеллекта. Он нашел свое применение в различных отраслях науки и бизнеса, а также в решении задач автоматизации производственных процессов.

По своему существу нейронные сети являются нелинейными. При моделировании сложных объектов (процессов) с использованием НС возможны как линейные, так и весьма сложные нелинейные зависимости [34]. Главным преимуществом данного метода по сравнению с большинством остальных (традиционных) является совершенствование модели в процессе ее самообучения, т.е. способность к накоплению и обобщению знаний, полученных в результате обучения. С каждым этапом обучения точность НС-модели растет за счет нахождения скрытых закономерных связей между исследуемыми показателями. Это возможно благодаря поступлению достаточного количества статистических данных, описывающих предметную область. В рассматриваемом случае такими данными являются результаты проб

горной массы, взятые на месторождении. Сложная структура геологической среды месторождений относится к категории ГПМ с нелинейным и достаточно плохо формализуемым характером, что значительно затрудняет математическую постановку задач. Таким образом, стоит предположить, что применение НС-подхода для моделирования данного объекта даст весьма хороший результат.

Данные детальной геологической разведки относятся, в большинстве случаев, к дискретному виду нестационарного случайного поля, где возможно различное соотношение случайной и детерминированной составляющих, в том числе и до крайнего преобладания одной из них.

Далее будет предложена математическая модель геологического поля месторождения как некоторая функция координат пространства (ПП), описывающая размещение определенного свойства (показателя) исследуемого объекта в пределах его скопления. Ее построение сводится к созданию НС-моделей детерминированной составляющей (при условии определения критерия адекватности) и дисперсии случайной составляющей поля.

Взятие интервальных или модульных проб при геологоразведке исключает проведение избыточных измерений, поэтому выбор критерия адекватности на основе статистических свойств остатков (отклонений значений реализации от модели закономерной компоненты) является важным и дает возможность использовать весь набор данных для построения модели. Весьма существенно, что на окончательный вид модели ПП оказывают влияние свойства остатков, которые в результате всестороннего исследования могут дать определенную информацию, дополняющую и уточняющую модель.

Аддитивную модель поля ПП рассмотрим как сумму детерминированной и случайной компонент:

$$U(x) = m(x) + R(x), \quad (1)$$

где x — вектор координат пробных выработок месторождения и может иметь размерность 1, 2 и 3.

В настоящее время довольно широко распространены решения задачи распределения изменчивости на детерминированную и случайную составляющие на основе субъективного подхода, когда подбирается возможный вариант формализации ПП. В отличие от данных методов НС распознает неявные закономерности в обучающей выборке и непрерывно их применяет на всей области определения переменной. Найденное решение аналитически никак не выражено, только как сеть с заданной архитектурой (многослойные перцептроны, радиальные базисные функции и т.д.) и конечным числом параметров (весов сети).

Выбор архитектуры сети для каждого конкретного случая чаще всего основывается на опыте разработчика и зависит от характера решаемой задачи. Подбор весов сети происходит, как правило, на основе методов нелинейной оптимизации.

Количество элементов (нейронов) и структура сети определяется эмпирическим путем и зависит от таких факторов, как размерности задачи, объем обучающих данных и пространственная структура аппроксимируемой функции.

Ряд приложений рассматривает НС как универсальный инструмент аппроксимации функции от нескольких переменных. Таким образом, может быть реализована нелинейная функция:

$$\gamma = F(x), \quad (2)$$

где x — входной вектор; γ — реализация векторной функции нескольких переменных.

Для решения поставленной задачи необходимо сначала обучить нейронную сеть. Обучение НС — это интерактивный процесс корректировки синаптиче-

ских весов и порогов. Для обучения нейронной сети применяют два подхода — с учителем и без. В рассматриваемой задаче целесообразно использовать обучение с учителем, так как этот подход предполагает наличие входных сигналов, составляющих вектор x , и ожидаемых выходных сигналов нейрона d_i , составляющих вектор d . Теперь НС будет выступать в роли универсального аппроксиматора обучающих данных (x, d) .

Обучение проводим на фактических данных, т.е. результатах интервальных или модульных проб геологоразведки месторождения. В процессе обучения следует не допускать недообучение или переобучение сети (т.е. излишнюю подгонку модели к данным). В случае недообучения модель будет недостаточно детальной, а при переобучении она не приобретет способности к обобщению. Переобучение сети может произойти из-за бесконтрольного уменьшения ошибки обучения в результате тренировки сети. В построении НС-модели для задачи поиска пространственной переменной ГПМ следует учесть, что сети с большим числом нейронов способны моделировать более сложные функции, но весьма склонны к переобучению. В таких случаях происходит так называемое привыкание сети к случайной изменчивости (шуму). При недостаточном числе нейронов в сети возможна нехватка ее гибкости для моделирования зависимостей. Число нейронов и длительность обучения влияют на качества, которые сеть приобретает в процессе обучения. Так как нет строгого правила для нахождения идеально выбранной архитектуры сети и ее обучения, то процесс разработки и сравнительного анализа НС-моделей представляет собой ряд экспериментов, в результате которых модель, подходящая нам по тем или иным критериям, будет считаться закономерной составляющей ПП. Случайную составляющую ПП следует оцени-

вать статистическими методами по остаткам.

В качестве обучающей выборки для нейронной сети используют представительные данные, подающиеся на вход сети. Здесь главное, чтобы в этих данных существовала некоторая закономерность. В НС-моделировании существует стандартная процедура подготовки исходных данных. Множество имеющихся в наличии данных произвольным образом разбивается на два подмножества: обучающее и тестовое. В свою очередь, обучающее подмножество разбивается на оценочное и контрольное. Оценочное подмножество используется для обучения модели и никак не связано с контрольным, которое служит механизмом кросс-проверки.

При использовании кросс-проверки на контрольном подмножестве и в ходе обучения и проверки на тестовом множестве полученной модели происходит исключение не менее половины данных из процесса обучения сети. При моделировании геологических полей такой подход не всегда приемлем, так как объем исходной информации часто ограничен и исключение некоторой части геологических данных из процесса обучения сети является весьма значимым фактором, который равносителен потере информации. Кросс-проверку при моделировании геологического поля следует использовать только при имеющихся достаточно больших объемах данных, когда, в процессе резервирования контрольного и тестового множеств, разрежение сети опробования не приведет к существенному снижению адекватности модели.

В данном случае может возникнуть следующая проблема, требующая дополнительного изучения: после случайного разбиения программой всей совокупности данных будут ли представительными подмножества, принимая во внимание пространственный характер

размещения показателя и динамическую переменную.

Как рассматривалось выше, при опробовании руд известными методами возможно получение зашумленных данных. В этом отношении нейронные сети являются довольно устойчивыми. Шум в НС может быть представлен как в виде случайных погрешностей измерений показателя, так и как случайная составляющая изменчивости этого показателя. Не исключена вероятность, что доля случайной изменчивости показателя будет высокой и вполне может преобладать над природной. Так, например, на одном из рассматриваемых в процессе сбора данных медно-молибденовом рудном месторождении в общем объеме по всем показателям ГПМ случайная составляющая изменчивости значительно превалировала. Известно, что чем больше уровень шума в данных (доли значений случайной составляющей), тем труднее для НС задача выделения полезного сигнала (доли значения закономерной составляющей) и тем больше должно быть обучающее множество (увеличение частоты интервальных или модульных проб). В таком положении, при неограниченной минимизации дисперсии остатков и стремлении максимально приблизить НС-модель к данным, может возникнуть ситуация, когда наряду с закономерной составляющей сеть начнет моделировать и шум.

Для определения критерия адекватности НС-модели целесообразно принимать во внимание различные свойства остатков или их сочетания. Они представляют собой реализацию случайной составляющей и, как правило, обладают значительной информативностью. Важно не подходить к выбору критерия совсем формальным образом и в полной мере учитывать геологическую природу признака. Следует выбирать критерий разделения ПП на закономерную и случай-

ную составляющие, который наиболее реально отражает структуру признака ГПМ и обеспечивает нужную степень адекватности модели. При рассмотрении одномерной равномерной сети наблюдений (равноинтервальных рядов измерений) решением выбора критерия адекватности может быть равенство оценки дисперсии, вычисленной по первым или вторым разностям, и дисперсии остатков. Этот способ с позиций свойств определенного геологического поля не может быть хоть как-то обоснован и формально возможен только для оценки одномерных равномерных сетей данных. К тому же, по формулам, которые предлагают разные авторы, оценка дисперсии случайной составляющей дает различные результаты.

Рассмотрим случай, когда доля случайной составляющей в общей изменчивости признака весьма велика (свыше 50%) при динамических характеристиках (среднее содержание, дисперсия) геологического поля и поэтому задача выбора критерия адекватности модели будет являться довольно сложной.

Критерий, который будет определять уровень обученности нейронной сети и разбивать общую изменчивость на две составляющие (детерминированную и случайную), выбирается на основе предположения нормального распределения случайной компоненты ГПМ, что, следовательно, относится и к остаткам.

Таким образом, в соответствии с формулой (1) для каждой отдельной реализации $u(x)$ решение сводится к определению динамической случайной функции $U(x)$ оценок ее детерминированной $m(x)$ и случайной $R(x)$ составляющих (компонент):

$$u(x) = m(x) + r(x), \quad (3)$$

где $m(x)$ — оценка детерминированной компоненты; $r(x)$ — оценка случайной компоненты (остатки).

Необходимость использования для обучения всего объема имеющихся данных в случае моделирования ГПМ выше уже была изложена, поэтому деление на подмножества всей совокупности данных не производится.

При наличии достаточной статистической базы данных, как в случае решения задач с имеющимися данным геологоразведки, для построения НС-модели возможно использовать RBF-сети (сеть радиальных базисных функций) и MLP-сети (многослойный перцептрон).

RBF-сеть обладает свойством локальной аппроксимации и довольно легко обучается. MLP-сеть строится при необходимости глобальной аппроксимацией, но в процессе обучения возрастает вероятность появления проблем. Исходя из этих свойств, многослойный перцептрон можно использовать в качестве решения задачи выявления общей тенденции в данных геологоразведки и экстраполяции значений ПП за область известных данных, а для подробного распознавания структуры обучающего множества — сеть радиальных базисных функций. Таким образом, задача выделения полезного сигнала (детерминированной составляющей) из крайне зашумленных данных является наиболее близкой (с точки зрения выбора структуры) к архитектуре этой сети.

Различные варианты модели аппроксимации данных получим, создавая сети с разным количеством нейронов. Такие модели позволят нам после их обучения наглядно оценить степень близости полученных результатов к исходным данным, поле распределения и величину дисперсии остатков. Для каждого модельного варианта $m(x)$ производится оценка распределения случайной компоненты $r(x)$ и из всех выбирается модель, наиболее соответствующая выбранному критерию, т.е. закону нормального распределения.

Таблица 2

Характеристики месторождения (геологоразведка)
Characteristics of the deposit (geological exploration)

1	Месторождение	№ 1382
2	Руда	медно-молибденовая
3	Взятие проб	результаты детальной и опережающей эксплуатационной разведок (РЛ-3, горизонт +1478 м)
4	Исследуемый показатель	содержание общей меди (%) в композированных 16-метровых керновых пробах
5	Скважины	43 шт., шаг 30 м, расстояние между крайними – 1315 м
6	Содержание общей меди	границы профиля – 0,13% и 0,11% (забалансовое содержание – 0,10–0,35%)
7	Максимальное содержание меди в пробе	по выборке 1,60% при среднем – 0,74% и оценке стандарта 0,376%

Входная переменная при обучении сети представляется координатами точек замеров показателя (x), а выходная – соответствующими значениями показателя реализации $u(x)$. Пройдя обучение, сеть начинает генерировать модельные значения детерминированной составляющей в любых точках области определения ПП. Случайные компоненты определяем разностью между значениями показателя взятых из геологических проб и модельными данными.

В табл. 2 представлены исходные данные месторождения, на котором был реализован данный подход.

Для построения нейросетевой модели был выбран программный пакет STATISTICA Neural Networks v.5.0, в котором представлены необходимые для данной задачи алгоритмы построения НС. В качестве базовой для моделирования нейронной сети была взята RBF-сеть (сеть радиальных базисных функций).

На вход подается значение расстояния L (м) от начальной точки (крайней левой скважины по профилю) до каждой из проб, выраженное в переменной x . Содержание общей меди в пробах скважин месторождений (набор значений показателя $cuob_c$ (% вес.)) представлены выходным значением $u(x)$. Для обучения

сети использовались 45 пар данных, причем сеть организовывалась посредством наращивания (число нейронов промежуточного слоя было взято 5). Таким образом, нейронная сеть была застрахована от переобучения на первом этапе. Пройдя обучение, нейросеть прогоняли и получали данные аппроксимации.

В качестве результата разработанная программная реализация, моделирующая ПП, позволяет выводить несколько статистик, таких, например, как среднеквадратическая ошибка (характеризует случайную составляющую), а также позволяет отслеживать пользователю ошибки в обучении.

На рис. 1 представлена часть результатов работы программы в виде графика реализации (ломаная линия) и тренда. Определение остатков (3) демонстрирует вероятностный график на рис. 2. Вероятностный график дает возможность пользователю оценить, насколько близко к нормальному распределению остатков. По этому графику также можно мониторить значения W -статистики критерия Шапиро–Уилка SW-W на нормальность [35]. Эти данные являются решающими при итоговом выборе сети.

В рассматриваемом примере на следующем шаге были добавлены еще 3 ней-

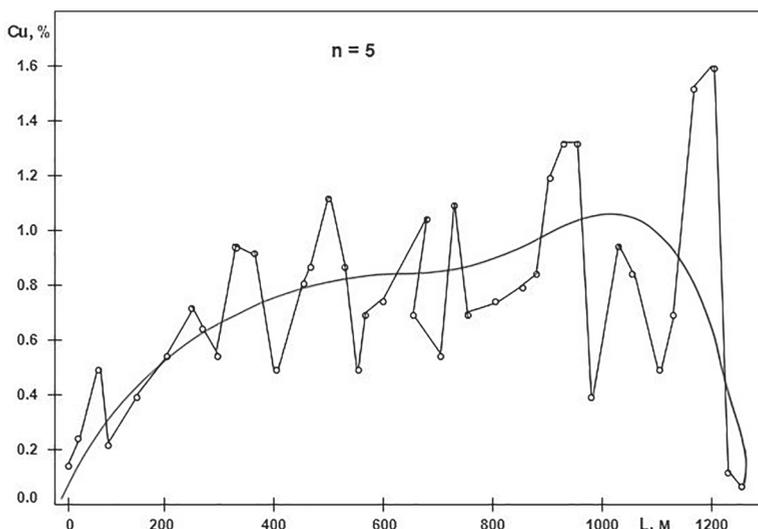


Рис. 1. График реализации и тренд
 Fig. 1. Implementation schedules and trend

рона, и все операции были проведены снова. В итоге построение сети проходило следующим образом: построено 5 вариантов RBF-сетей, число нейронов промежуточного слоя от 5 до 17, шаг 3.

Наращивание нейросети продолжалось, пока распределение остатков после достижения максимального улучшения (в смысле близости к нормальному закону) не стало ухудшаться. В нашем слу-

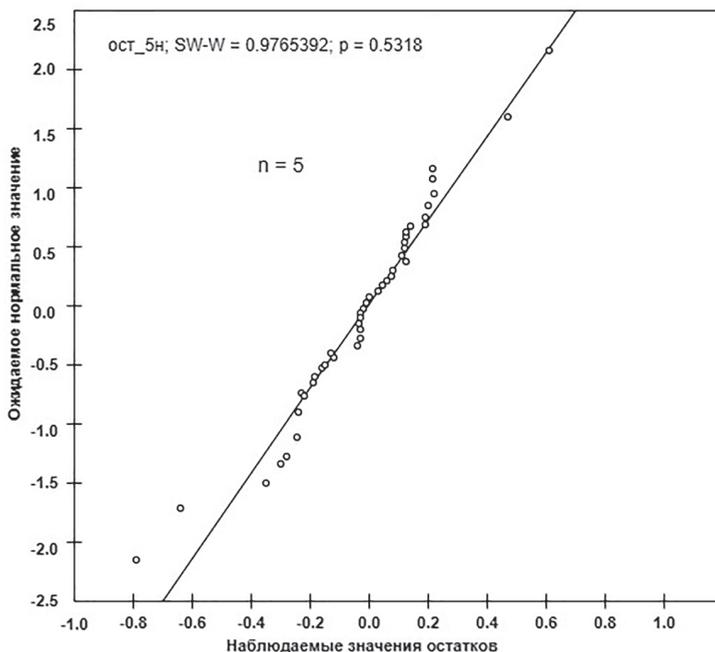


Рис. 2. Вероятностный график распределения остатков
 Fig. 2. Probabilistic graph of the remainder distribution

Таблица 3

Корреляционная матрица
Correlation matrix

	Means, % вес	Std. Dev, % вес	Абс_остатки, % вес	cuob_c, % вес	cuob_c_m, % вес
Абс_остатки, % вес	0,205	0,158	1,00	0,38	0,40
cuob_c, % вес	0,746	0,376	0,38	1,00	0,72
cuob_c_m, % вес	0,735	0,268	0,40	0,72	1,00

чае, т.е. при принятом критерии адекватности, это значит, что наращивание сети нужно прекратить, так как начался процесс переобучения.

Чтобы сделать результаты более наглядными, каждая из полученных сетей была запущена с базовой выборкой и новым набором входных данных. Расстояние было выражено в 10 м от начальной точки.

Полученные результаты продемонстрировали, что с увеличением числа нейронов и обученности нейросети наблюдается явное приближение модели (в виде кривой) к данным. При сравнении вариантов полученных решений был сделан вывод, что наиболее близким показателем к нормальному распределению остатков является нейронная сеть, построенная на основе 11 нейронов. Данная нейросеть в конечном итоге была принята для моделирования. Любое значение из области определения (в данном случае расстояние от начальной скважины до точек на линии разведки) может быть подано на вход сети, и сеть может быть запущена для получения оценки значения модели, соответствующего показателю, т.е. регулярной составляющей.

Полученные остатки по каждому выбранному варианту можно считать значением случайной функции с нулевым математическим ожиданием. При построении графика зависимости остатков от величины закономерной составляющей (среднего значения признака) разброс точек увеличивается по мере увеличения

показателя, что полностью доказывает наличие положительной связи дисперсии и среднего содержания в окрестности точки выборки. Корреляционная матрица, представленная в табл. 3, подтверждает эту взаимосвязь. Абсолютные значения остатков коррелируют как с данными разведки ($r = 0,38$), так и с моделью ($r = 0,40$).

Стандарт распределения зависит от среднего содержания вблизи измерения. Для месторождений цветных металлов в большинстве случаев эта зависимость является линейной [36]:

$$\sigma_i = kX_i. \quad (4)$$

Установить наличие подобной связи непосредственно, когда мы располагаем только одной реализацией случайной функции, да еще представленной незначительным объемом данных, практически невозможно. Однако статистические свойства остатков позволяют нам найти с помощью уравнения регрессии приближенную зависимость между детерминированной и случайной компонентами ПП. Поскольку дисперсия в окрестности проб с увеличением среднего содержания металла должна возрастать, при этом должен в среднем увеличиваться и разброс значений реализаций случайной составляющей относительно закономерной компоненты. Полученная регрессионная зависимость абсолютных значений остатков от закономерной составляющей признака продемонстрировала наличие положительной линейной связи. Придерживаясь принятых ранее

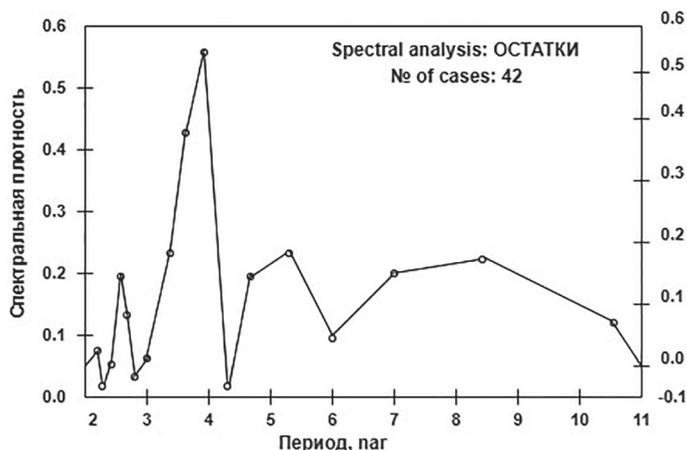


Рис. 3. График спектральной плотности
Fig. 3. Spectral density graph

обозначений и заменив x на L (L определяет положение текущей точки на разведочной линии относительно начальной) для одномерной модели, запишем выражение для оценки средней ошибки (модуля остатков) в точке L поля:

$$\theta(L) = 0,026 + 0,242 * m(L), \quad (5)$$

где L — расстояние от начальной до текущей точки на разведочной линии, м; $m(L) = \text{суб}_c m(L)$ — содержание общей меди по НС-модели в текущей точке, %.

Воспользуемся известным соотношением между средней Θ и среднеквадратическоей m ошибками, полученным для нормального распределения:

$$\theta = m \sqrt{\frac{2}{\pi}} \approx 0,798m. \quad (6)$$

Подставив выражение Θ в формулу (5) вместо $\theta(L)$ и заменив при этом m на $\sigma(L)$, получим регрессионную зависимость стандарта случайной составляющей от модели закономерной компоненты для области определения пространственной переменной:

$$\sigma(L) = 0,032 + 0,303 * m(L), \quad (7)$$

где $\sigma(L)$ — оценка стандарта случайной составляющей. Уравнение (7) позволяет

использовать значение детерминированной компоненты $m(L_i)$ для оценки стандарта случайной компоненты $\sigma(L_i)$, т.е. точности нормальной компоненты, в любой точке поля на линии разведки.

Для рассматриваемой модели при выборке общее среднеквадратическое отклонение составило 0,261%, рассчитанное по остаткам. Общий стандарт данных составил 0,376%, а случайная дисперсия равна 48,1%. Эмпирическая автокорреляционная функция остатков с 95%-ми доверительными границами для гипотезы о нулевом коэффициенте корреляции приводит только к одному значимому значению коэффициента — $\beta = -0,45$, с интервалом разведки равным 2 (лаг). Таким образом, здесь наблюдается такое явление, как отрицательная сериальная корреляция [36], т.е. имеет место наличие циклической составляющей в ряду. На рис. 3 представлен график спектральной плотности. Ее значение в максимуме соответствует лагу равному 3,8 разведочных интервалов, т.е. $3,8 * 31 = 118$ м.

Видно, что при заданной плотности разведочных скважин радиус влияния проб не выявлен, это демонстрирует данная коррелограмма и отсутствие корре-

ляции между пробамии близ расположенных скважин ($\beta = -0,05$ с лагом 1), что также видно и по вариограмме остатков на рис. 4.

При построении эмпирической функции использовалась зависимость значений от расстояния и направления, поэтому она является функцией от векторного аргумента, т.е. построена сообразно правилам геостатистики. Вариограмма остатков дает общее понимание изменений значения признака в зависимости от расстояния, как в определенном направлении, так и в определенной области пространства. По вариограмме остатков можно отследить большинство геологических характеристик рассматриваемого объекта. По своему характеру поведение вариограммы аналогично белому шуму, что видно и по результатам анализа спектральной плотности остатков. Ее распределение в значительной степени согласуется с экспоненциальным законом.

В тех случаях, когда для случайной составляющей определена пространственная структура данных в диапазоне влияния проб (радиуса корреляции), построение ее модели возможно с применением крайгинга. При этом на первом этапе к экспериментальной вариограмме остатков подбирается модель, а далее остатки интерполируются с помощью метода рядового крайгинга [37, 38]. Полученные оценки затем добавляются к значениям трендов (закономерной составляющей в точках проведения замера).

Заключение

Разработанная программная реализация, моделирующая ПП геологического поля, позволила наглядно продемонстрировать, что с помощью нейросети возможно создать модель с высокой степенью точности получаемых результатов по составу и распределению полезных ископаемых в заданной области. Основ-

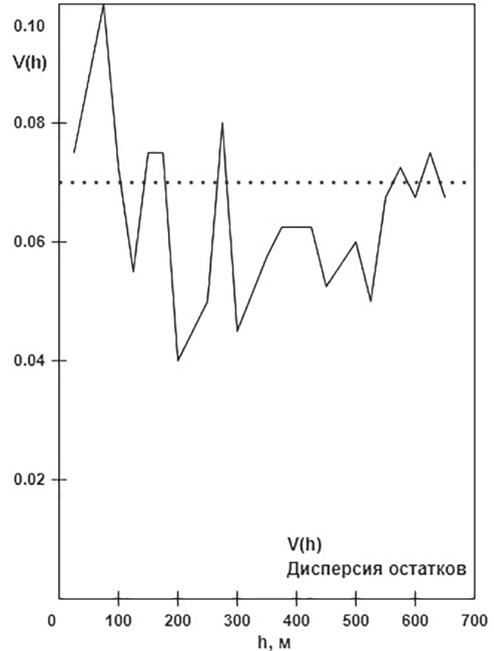


Рис. 4. Вариограмма остатков
Fig. 4. Variogram of residues

ным условием здесь является то, что при обучении нейронной сетью должны быть выявлены определенные закономерности в данных. В случаях ограниченного объема данных необходимо, чтобы уровень обученности сети определялся по какому-либо отдельно взятому критерию в отношении остатков как носителей информации о свойствах рассматриваемого геологического поля ПП. Далее при помощи методов статистики и геостатистики по остаткам возможно оценить случайную составляющую. Точность закономерной составляющей (модельные значения) в любой точке в поле ПП можно оценить на основе регрессионной зависимости стандарта случайной составляющей, построенной с использованием модулей остатков. Модели детерминированной и случайной компонент взаимозависимые, и поэтому анализ остатков в ряде случаев может привести к необходимости внесения некоторых корректировок в модель ПП.

СПИСОК ЛИТЕРАТУРЫ

1. *Litvinenko V. S., Tsvetkov P. S., Molodtsov K. V.* The social and market mechanism of sustainable development of public companies in the mineral resource sector // *Eurasian Mining*. 2020, vol. 2020, no. 1, pp. 36 – 41. DOI: 10.17580/em.2020.01.07.
2. *Каплунов Д. Р., Юков В. А.* О принципах перехода горнодобывающего предприятия к устойчивому экологически сбалансированному развитию // *Горный информационно-аналитический бюллетень*. – 2020. – № 3. – С. 74–86. DOI: 10.25018/02361493-2020-3-0-74-86.
3. *Rogalev N., Sukhareva Y., Mentel G., Brozyna J.* Economic approaches for improving electricity market // *Terra Economicus*. 2018, vol. 16, no. 2, pp. 140–149. DOI: 10.23683/2073-6606-2018-16-2-140-149.
4. *Lisin E., Kurdiukova G.* Energy supply system development management mechanisms from the standpoint of efficient use of energy resources // *IOP Conference Series: Earth and Environmental Science*. 2021, vol. 666, no. 6, article 062090. DOI: 10.1088/1755-1315/666/6/062090.
5. *Shehata A. A., Korovkin N. V., Tolba M. A., Tulsy V. N.* Efficient utilization of the power grid using FACTS devices based on a new metaheuristic optimizer / *Proceedings of the 3rd International Youth Conference on Radio Electronics, Electrical and Power Engineering, REEPE*. 2021, article 9387974. DOI: 10.1109/reepe51337.2021.9387974.
6. *Lisin E., Kurdiukova G., Okley P., Chernova V.* Efficient methods of market pricing in power industry within the context of system integration of renewable energy sources // *Energies*. 2019, vol. 12, no. 17, article 3250. DOI: 10.3390/en12173250.
7. *Khayrutdinov M. M., Golik V. I., Aleksakhin A. V., Trushina E. V., Lazareva N. V., Aleksakhina Y. V.* Proposal of an algorithm for choice of a development system for operational and environmental safety in mining // *Resources*. 2022, vol. 11, no. 10, article 88. DOI: 10.3390/resources11100088.
8. *Каунг П. А., Зотов В. В., Гаджиев М. А., Артемов С. И., Гиреев И. А.* Формализация процесса выбора технологий отработки месторождений полезных ископаемых // *Горный информационно-аналитический бюллетень*. – 2022. – № 2. – С. 124–138. DOI: 10.25018/0236_1493_2022_2_0_124.
9. *Kongar-Syuryun Ch., Ubysz A., Faradzhov V.* Models and algorithms of choice of development technology of deposits when selecting the composition of the backfilling mixture // *IOP Conference Series: Earth and Environmental Science*. 2021, vol. 684, no. 1, article 012008. DOI: 10.1088/1755-1315/684/1/012008.
10. *Гендлер С. Г., Габов В. В., Бабьрь Н. В., Прохорова Е. А.* Обоснование технических решений по снижению производственного травматизма в лавах угольных шахт // *Горный информационно-аналитический бюллетень*. – 2022. – № 1. – С. 5–19. DOI: 10.25018/0236_1493_2022_1_0_5.
11. *Куприянов В. В., Темкин И. О., Бондаренко И. С.* Исследование временных характеристик аварийных ситуаций в угольных шахтах // *Безопасность труда в промышленности*. – 2022. – № 1. – С. 39–45. DOI: 10.24000/0409-2961-2022-1-39-45.
12. *Tsvetkov P.* Engagement of resource-based economies in the fight against rising carbon emissions // *Energy Reports*. 2022, vol. 8, no. 2, pp. 874–883. DOI: 10.1016/j.egy.2022.05.259.
13. *Рыбак Я., Хайрутдинов М. М., Конгар-Сюрюн Ч. Б., Тюляева Ю. С.* Ресурсосберегающие технологии освоения месторождений полезных ископаемых // *Устойчивое развитие горных территорий*. – 2021. – № 13(3). – С. 405–415. DOI: 10.21177/1998-4502-2021-13-3-406-415.
14. *Ponomarenko T., Nevskaya M., Jonek-Kowalska I.* Mineral Resource depletion assessment: Alternatives, problems, results // *Sustainability*. 2021, vol. 13, no. 2, article 862. DOI: 10.3390/su13020862.
15. *Khayrutdinov A., Paleev I., Artemov S.* Replacement of traditional components of the backfill mixture with man-made waste // *IOP Conference Series: Earth and Environmental Science*. 2021, vol. 942, no. 1, article 012005. DOI: 10.1088/1755-1315/942/1/012005.

16. *Cherepovitsyn A. E., Tsvetkov P. S.* Methodical approach to evaluation of the Russian peat deposits exploitation attractiveness based on geology-technological criteria // *International Journal of Applied Engineering Research*. 2016, no. 11, pp. 5072 – 5078.

17. *Якупов Д. Р., Иванова П. В., Иванов С. Л.* Физическое моделирование сопротивления перемещению грузов по поверхности торфяного месторождения на стенде // *Горный информационно-аналитический бюллетень*. – 2021. – № 5-1. – С. 117 – 129. DOI: 10.25018/0236_1493_2021_51_0_117.

18. *Vinnikov V. A., Silberschmidt M. G., Bocharov V. A., Ignatkina V. A., Gzogyan T. N.* Environmental resource – Economized processes of recycling mineral raw materials of complex composition // *Environment Technology Resources. Proceedings of the International Scientific and Practical Conference*. 2015, vol. 1, pp. 209 – 215. DOI: 10.17770/etr2013vol1.837.

19. *Khayrutdinov A., Kongar-Syuryun Ch., Kowalik T., Faradzhev V.* Improvement of the backfilling characteristics by activation of halite enrichment waste for non-waste geotechnology // *IOP Conference Series: Materials Science and Engineering*. 2020, vol. 867, no. 1, article 012018. DOI: 10.1088/1757-899X/867/1/012018.

20. *Мелехина К. А., Ананьев П. П., Плотникова А. В., Тимофеев А. С., Шестак С. А.* Моделирование и оптимизация процесса рудоподготовки комплексных руд при их дезинтеграции в мельнице самоизмельчения // *Горный информационно-аналитический бюллетень*. – 2020. – № 10. – С. 95 – 105. DOI: 10.25018/0236-1493-2020-10-0-95-105.

21. *Kyaw Zay Ya, Goryachev B., Adigamov A., Nurgalieva K., Narozhnyy I.* Thermodynamics and electrochemistry of the interaction of sphalerite with iron (II)-bearing compounds in relation to flotation // *Resources*. 2022, vol. 11, no. 12, article 108. DOI: 10.3390/resources11120108.

22. *Портнов В. С., Юров В. М.* Управление качеством железных руд при их добыче // *Известия Сибирского отделения РАН. Геология, поиски и разведка рудных месторождений*. – 2005. – № 2(28). – С. 85 – 90.

23. *Гончаренко С. Н., Бердалиев Б. А.* Методы прогнозирования и оценки остаточных и технологических концентраций урановой руды при добыче методом подземного выщелачивания // *Горный информационно-аналитический бюллетень*. – 2018. – № 5. – С. 43 – 48. DOI: 10.25018/0236-1493-2018-5-0-43-48.

24. *Ivannikov A., Chumakov A., Prischepov V., Melekhina K.* Express determination of the grain size of nickel-containing minerals in ore material // *Materials Today: Proceedings*. 2020, vol. 38, pp. 2059 – 2062. DOI: 10.1016/j.matpr.2020.10.141.

25. *Отгонбилэг Ш.* Управление рудной массой. – М.: Недра, 1996. – 173 с.

26. *Chumakov A., Prischepov V., Melekhina K., Ivannikov A.* Improving the control system of concentration plants based on express control of dissemination of magnetic minerals // *IOP Conference Series: Earth and Environmental Science*. 2021, vol. 684, no. 1, article 012005. DOI: 10.1088/1755-1315/684/1/012005.

27. *Timofeev A. S., Dvoichenkova G. P., Chernysheva E. N., Popadin E. G.* Express method for estimating particle isometricity for quality control ferrosilicium // *IOP Conference Series: Earth and Environmental Science*. 2020, vol. 459, no. 5, article 052096. DOI: 10.1088/1755-1315/459/5/052096.

28. *Куприянов В. В., Бондаренко И. С.* Факторы влияния на резерв времени для выхода из подземных аварий в шахтах // *Горный информационно-аналитический бюллетень*. – 2022. – № 2. – С. 139 – 149. DOI: 10.25018/0236_1493_2022_2_0_139.

29. *Temkin I. O., Myaskov A. V., Deryabin S. A., Rzazade U. A.* Digital twins and modeling of the transporting-technological processes for on-line dispatch control in open pit mining // *Eurasian Mining*. 2020, no. 2, pp. 55 – 58. DOI: 10.17580/em.2020.02.13.

30. *Trofimov V. B.* An approach to intelligent control of complex industrial processes: an example of ferrous metal industry // *Automation and Remote Control*. 2020, vol. 81, no. 10, pp. 1856 – 1864. DOI: 10.1134/S0005117920100057.

31. *Зайцева Е. В.* Вопросы стратегического управления предприятиями цементной промышленности // *Горный информационно-аналитический бюллетень*. – 2019. – № 2. – С. 214 – 220. DOI: 10.25018/0236-1493-2019-02-0-214-220.

32. Novikova N. V., Barmuta K. A., Kaderova V. A., Il'yaschenko D. P., Abdulov R. E., Aleksakhin A. V. Planning of new products technological mastering and its influence on economic indicators of companies // *International Journal of Economics and Financial Issues*. 2016, vol. 6, no. 8, pp. 65–70. Retrieved from <https://econjournals.com/index.php/ijefi/article/view/3701>.

33. Бондаренко И. С. Разработка планов-прогнозов на основе технико-экономических показателей горнодобывающих предприятий // *Горный информационно-аналитический бюллетень*. — 2022. — № 3. — С. 97–107. DOI: 10.25018/0236_1493_2022_3_0_97.

34. Осовский С. Нейронные сети для обработки информации. Пер. с польского. — М.: Финансы и статистика, 2002. — 344 с.

35. Куприянов В. В. Автоматизация распознавания нештатных ситуаций в угольных шахтах на основе нейронной сети с изменяемыми топологией и весовыми коэффициентами / Труды XVIII-й Всероссийской научной конференции «Нейрокомпьютеры и их применение». — М.: МГППУ, 2020. — С. 59–60.

36. Дрейпер Н., Смит Г. Прикладной регрессионный анализ, 3-е изд. — М.: Издательский дом «Вильямс», 2007. — 912 с.

37. Aristov A. O. Quasi-cellular nets based on models of flow-systems // *Journal of Physics: Conference Series*. 2019, vol. 1392, no. 1, article 012064. DOI: 10.1088/1742-6596/1392/1/012064.

38. Kondybayeva A. B., Solodov S. V. Tricubic interpolation in scientific data visualization problems / *Wave Electronics and its Application in Information and Telecommunication Systems, WECONF. Proceedings of Conference*. 2019, article 8840118. DOI: 10.1109/weconf.2019.8840118. **MIAB**

REFERENCES

1. Litvinenko V. S., Tsvetkov P. S., Molodtsov K. V. The social and market mechanism of sustainable development of public companies in the mineral resource sector. *Eurasian Mining*. 2020, vol. 2020, no. 1, pp. 36–41. DOI: 10.17580/em.2020.01.07.

2. Kaplunov D. R., Yukov V. A. Principles of a mine transition to sustainable and environmentally sound development. *MIAB. Mining Inf. Anal. Bull.* 2020, no. 3, pp. 74–86. [In Russ]. DOI: 10.25018/02361493-2020-3-0-74-86.

3. Rogalev N., Sukhareva Y., Mentel G., Brozyna J. Economic approaches for improving electricity market. *Terra Economicus*. 2018, vol. 16, no. 2, pp. 140–149. DOI: 10.23683/2073-6606-2018-16-2-140-149.

4. Lisin E., Kurdiukova G. Energy supply system development management mechanisms from the standpoint of efficient use of energy resources. *IOP Conference Series: Earth and Environmental Science*. 2021, vol. 666, no. 6, article 062090. DOI: 10.1088/1755-1315/666/6/062090.

5. Shehata A. A., Korovkin N. V., Tolba M. A., Tulsy V. N. Efficient utilization of the power grid using FACTS devices based on a new metaheuristic optimizer. *Proceedings of the 3rd International Youth Conference on Radio Electronics, Electrical and Power Engineering, REEPE*. 2021, article 9387974. DOI: 10.1109/reepe51337.2021.9387974.

6. Lisin E., Kurdiukova G., Okley P., Chernova V. Efficient methods of market pricing in power industry within the context of system integration of renewable energy sources. *Energies*. 2019, vol. 12, no. 17, article 3250. DOI: 10.3390/en12173250.

7. Khayrutdinov M. M., Golik V. I., Aleksakhin A. V., Trushina E. V., Lazareva N. V., Aleksakhina Y. V. Proposal of an algorithm for choice of a development system for operational and environmental safety in mining. *Resources*. 2022, vol. 11, no. 10, article 88. DOI: 10.3390/resources11100088.

8. Kaung P. A., Zotov V. V., Gadzhiev M. A., Artemov S. I., Gireev I. A. Formalization of selection procedure of mineral mining technologies. *MIAB. Mining Inf. Anal. Bull.* 2022, no. 2, pp. 124–138. [In Russ]. DOI: 10.25018/0236_1493_2022_2_0_124.

9. Kongar-Syuryun Ch., Ubysz A., Faradzov V. Models and algorithms of choice of development technology of deposits when selecting the composition of the backfilling mixture. *IOP*

Conference Series: Earth and Environmental Science. 2021, vol. 684, no. 1, article 012008. DOI: 10.1088/1755-1315/684/1/012008.

10. Gendler S. G., Gabov V. V., Babyr N. V., Prokhorova E. A. Justification of engineering solutions on reduction of occupational traumatism in coal longwalls. *MIAB. Mining Inf. Anal. Bull.* 2022, no. 1, pp. 5 – 19. [In Russ]. DOI: 10.25018/0236_1493_2022_1_0_5.

11. Kupriyanov V. V., Temkin I. O., Bondarenko I. S. Study of the time characteristics for emergency situations in the coal mines. *Occupational Safety in Industry*. 2022, no. 1, pp. 39 – 45. [In Russ]. DOI: 10.24000/0409-2961-2022-1-39-45.

12. Tcvetkov P. Engagement of resource-based economies in the fight against rising carbon emissions. *Energy Reports*. 2022, vol. 8, no. 2, pp. 874 – 883. DOI: 10.1016/j.egy.2022.05.259.

13. Rybak Y., Khayrutdinov M. M., Kongar-Syuryun C. B., Tyulyayeva Y. S. Resource-saving technologies for development of mineral deposits. *Sustainable Development of Mountain Territories*. 2021, no. 13(3), pp. 405 – 415. [In Russ]. DOI: 10.21177/1998-4502-2021-13-3-406-415.

14. Ponomarenko T., Nevskaya M., Jonek-Kowalska I. Mineral Resource depletion assessment: Alternatives, problems, results. *Sustainability*. 2021, vol. 13, no. 2, article 862. DOI: 10.3390/su13020862.

15. Khayrutdinov A., Paleev I., Artemov S. Replacement of traditional components of the backfill mixture with man-made waste. *IOP Conference Series: Earth and Environmental Science*. 2021, vol. 942, no. 1, article 012005. DOI: 10.1088/1755-1315/942/1/012005.

16. Cherepovitsyn A. E., Tsvetkov P. S. Methodical approach to evaluation of the Russian peat deposits exploitation attractiveness based on geology-technological criteria. *International Journal of Applied Engineering Research*. 2016, no. 11, pp. 5072 – 5078.

17. Yakupov D. R., Ivanova P. V., Ivanov S. L. Physical simulation of load displacement resistance of peat land surface on test bench. *MIAB. Mining Inf. Anal. Bull.* 2021, no. 5-1, pp. 117 – 129. [In Russ]. DOI: 10.25018/0236_1493_2021_51_0_117.

18. Vinnikov V. A., Silberschmidt M. G., Bocharov V. A., Ignatkina V. A., Gzogyan T. N. Environmental resource – Economized processes of recycling mineral raw materials of complex composition. *Environment Technology Resources. Proceedings of the International Scientific and Practical Conference*. 2015, vol. 1, pp. 209 – 215. DOI: 10.17770/etr2013vol1.837.

19. Khayrutdinov A., Kongar-Syuryun Ch., Kowalik T., Faradzhev V. Improvement of the backfilling characteristics by activation of halite enrichment waste for non-waste geotechnology. *IOP Conference Series: Materials Science and Engineering*. 2020, vol. 867, no. 1, article 012018. DOI: 10.1088/1757-899X/867/1/012018.

20. Melekhina K. A., Ananyev P. P., Plotnikova A. V., Timofeev A. S., Shestak S. A. Modeling and optimization of complex ore pretreatment by disintegration in autogenous mills. *MIAB. Mining Inf. Anal. Bull.* 2020, no. 10, pp. 95 – 105. [In Russ]. DOI: 10.25018/0236-1493-2020-10-0-95-105.

21. Kyaw Zay Ya, Goryachev B., Adigamov A., Nurgalieva K., Narozhnyy I. Thermodynamics and electrochemistry of the interaction of sphalerite with iron (II)-bearing compounds in relation to flotation. *Resources*. 2022, vol. 11, no. 12, article 108. DOI: 10.3390/resources11120108.

22. Portnov V. S., Yurov V. M. Quality management of iron ores during their extraction. *Izvestiya Sibirskogo otdeleniya RAEN. Geologiya, poiski i razvedka rudnykh mestorozhdeniy*. 2005, no. 2(28), pp. 85 – 90. [In Russ].

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

24. Ivannikov A., Chumakov A., Prischepov V., Melekhina K. Express determination of the grain size of nickel-containing minerals in ore material. *Materials Today: Proceedings*. 2020, vol. 38, pp. 2059 – 2062. DOI: 10.1016/j.matpr.2020.10.141.

25. Otgonbileg Sh. *Upravlenie rudnoy massoy* [Ore mass management], Moscow, Nedra, 1996, 173 p.

26. Chumakov A., Prischepov V., Melekhina K., Ivannikov A. Improving the control system of concentration plants based on express control of dissemination of magnetic minerals.

IOP Conference Series: Earth and Environmental Science. 2021, vol. 684, no. 1, article 012005. DOI: 10.1088/1755-1315/684/1/012005.

27. Timofeev A. S., Dvoichenkova G. P., Chernysheva E. N., Popadin E. G. Express method for estimating particle isometricity for quality control ferrosilicium. *IOP Conference Series: Earth and Environmental Science*. 2020, vol. 459, no. 5, article 052096. DOI: 10.1088/1755-1315/459/5/052096.

28. Kupriyanov V. V., Bondarenko I. S. Factor of influence on time allowance in emergency preparedness in underground mines. *MIAB. Mining Inf. Anal. Bull.* 2022, no. 2, pp. 139–149. [In Russ]. DOI: 10.25018/0236_1493_2022_2_0_139.

29. Temkin I. O., Myaskov A. V., Deryabin S. A., Rzazade U. A. Digital twins and modeling of the transporting-technological processes for on-line dispatch control in open pit mining. *Eurasian Mining*. 2020, no. 2, pp. 55–58. DOI: 10.17580/em.2020.02.13.

30. Trofimov V. B. An approach to intelligent control of complex industrial processes: an example of ferrous metal industry. *Automation and Remote Control*. 2020, vol. 81, no. 10, pp. 1856–1864. DOI: 10.1134/S0005117920100057.

31. Zaytseva E. V. Strategic management in the cement industry. *MIAB. Mining Inf. Anal. Bull.* 2019, no. 2, pp. 214–220. [In Russ]. DOI: 10.25018/0236-1493-2019-02-0-214-220.

32. Novikova N. V., Barmuta K. A., Kaderova V. A., Il'yaschenko D. P., Abdulov R. E., Aleksakhin A. V. Planning of new products technological mastering and its influence on economic indicators of companies. *International Journal of Economics and Financial Issues*. 2016, vol. 6, no. 8, pp. 65–70. Retrieved from <https://econjournals.com/index.php/ijefi/article/view/3701>.

33. Bondarenko I. S. Elaboration of plans–forecasts based on engineering-and-economic performance of mines. *MIAB. Mining Inf. Anal. Bull.* 2022, no. 3, pp. 97–107. [In Russ]. DOI: 10.25018/0236_1493_2022_3_0_97.

34. Osovskiy S. *Neyronnye seti dlya obrabotki informatsii*. Per. s pol'skogo [Neural networks for information processing. Polish–Russian translation], Moscow, Finansy i statistika, 2002, 344 p.

35. Kupriyanov V. V. Automation of recognition of emergency situations in coal mines based on a neural network with variable topology and weight coefficients. *Trudy XVIII-y Vserossiyskoy nauchnoy konferentsii «Neyrokomp'yutery i ikh primenenie»* [Proceedings of the XVIII-th All-Russian Scientific Conference «Neurocomputers and their application»], Moscow, МГППУ, 2020, pp. 59–60. [In Russ].

36. Dreyper N., Smit G. *Prikladnoy regressionnyy analiz*, 3-e izd. [Applied regression analysis, 3rd edition], Moscow, Izdatel'skiy dom «Vil'yams», 2007, 912 p.

37. Aristov A. O. Quasi-cellular nets based on models of flow-systems. *Journal of Physics: Conference Series*. 2019, vol. 1392, no. 1, article 012064. DOI: 10.1088/1742-6596/1392/1/012064.

38. Kondybayeva A. B., Solodov S. V. Tricubic interpolation in scientific data visualization problems. *Wave Electronics and its Application in Information and Telecommunication Systems, WECONF. Proceedings of Conference*. 2019, article 8840118. DOI: 10.1109/weconf.2019.8840118.

ИНФОРМАЦИЯ ОБ АВТОРЕ

Бондаренко Инна Сергеевна — канд. техн. наук, доцент,
НИТУ «МИСиС», e-mail: innasbondarenko@gmail.com,
ORCID ID: 0000-0002-4160-8413.

INFORMATION ABOUT THE AUTHOR

I.S. Bondarenko, Cand. Sci. (Eng.), Assistant Professor,
National University of Science and Technology «MISIS»,
119049, Moscow, Russia, e-mail: innasbondarenko@gmail.com,
ORCID ID: 0000-0002-4160-8413.

Получена редакцией 27.02.2023; получена после рецензии 27.03.2023; принята к печати 10.05.2023.
Received by the editors 27.02.2023; received after the review 27.03.2023; accepted for printing 10.05.2023.