

ГЕОИНФОРМАТИКА

УДК 622.013.34:553.31:004.032.26

СРАВНЕНИЕ РАЗЛИЧНЫХ МЕТОДОВ ОЦЕНКИ СОДЕРЖАНИЯ ЖЕЛЕЗА В РУДНОМ ТЕЛЕ

С. Д. Мозави¹, М. Шаестехфар¹, П. Моарефванд²

¹Керманский университет им. Шахида Бахонара,
E-mail: mousavij@eng.uk.ac.ir, г. Керман, Иран

²Технологический университет им. Амира Кабира, г. Тегеран, Иран

Рассмотрено распределение содержания железа в одном из рудных тел Центрального Ирана с применением следующих методов: обычный кригинг, последовательное гауссово моделирование и искусственная нейронная сеть. Сравнение результатов исследований выполнено с целью выявления метода, дающего наиболее точные результаты оценки запасов полезного ископаемого.

Геостатистика, обычный кригинг, последовательное гауссово моделирование, искусственная нейронная сеть, рудное тело “Озеро Сиах”, Иран

DOI: 10.15372/FTPRPI20220119

Почти все горнодобывающие проекты начинаются с определения содержания металла в руде, характеризующего ее ценность. Обычно данная задача решается моделированием пространственного распределения значений содержания металла [1–2]. Это, в свою очередь, напрямую влияет на оценку функций извлечения, таких как объем добываемой руды, количество металла и среднее содержание, превышающее бортовое [3]. Корректная оценка запасов и содержания металла в руде помогает горнодобывающим предприятиям в принятии инвестиционных решений в рамках своих проектов [4, 5]. Прогнозирование содержания металла в руде — существенный фактор оценки ценности рудного месторождения и прибыльности горнодобывающих предприятий. Основной проблемой данного этапа является выбор подходящего метода, так как любое рудное месторождение обладает сложной геологической структурой, включающей множество параметров. Один из наиболее важных — распределение содержания металла в руде. Можно выделить несколько критериев при сравнении методов его оценки: корреляция между спрогнозированными и фактическими значениями, соотношение “содержание — объем” [6]; степень сглаживания, определяемая методами интерполяции или точными методами измерения среднеквадратичной ошибки, средней абсолютной ошибки, а также доходов и затрат [7].

Работа выполнена при финансовой поддержке Керманского университета им. Шахида Бахонара и Департамента горнодобывающей промышленности Ирана.

Основными методами для прогнозирования содержания металла в руде являются геостатистические методы, а также моделирование, связанное с искусственной нейронной сетью (ИНС). Они принципиально отличаются друг от друга. Геостатистические методы, например обычный кригинг (ОК), связаны с моделями, в основе которых лежат пространственные корреляции параметров рудного тела при условии неизменности системы во времени. Линейные модели формируются для локальной структуры окрестности. ИНС работает с нелинейным распределением, надежным при наличии данных с высоким содержанием металла в руде.

Согласно научным работам, более предпочтительными для прогнозирования содержания и оценки извлекаемых запасов являются геостатистические методы. Они подходят для моделирования пространственного распространения содержания металла в руде [8–10]. Многие исследователи применяли данные методы для прогнозирования содержания металла и запасов на различных месторождениях по всему миру [11–14]. Геостатистическое моделирование заключается в воспроизведении пространственной неравномерности в массивах данных [15].

Недавние разработки в области программного обеспечения позволили использовать алгоритмы машинного обучения, или ИНС-методы. Они могут применяться для оценки месторождений и содержания металла в руде [16, 17], моделируя нелинейную зависимость данных, выявлять функциональную зависимость на основе доступных образцов [18, 19]. В ряде работ с помощью этого метода проводились прогнозы рудных запасов [20, 21].

В настоящей статье рассмотрены оценки распределения содержания металла в руде для выявления слабых мест, возникающих при его нахождении. Использованы геостатистические методы, последовательное гауссово моделирование и метод машинного обучения, в частности ИНС. Представлено сравнение геостатистических и ИНС-методов оценки содержания железа и запасов руды на примере месторождения “Озеро Сиах”, Центральный Иран. По результатам сравнения выявлены и проанализированы различия рассматриваемых методов.

ОПИСАНИЕ ИССЛЕДУЕМОЙ ОБЛАСТИ

Исследуемая область находится на востоке провинции Язд, Иран. Железо-апатитовое рудное тело “Озеро Сиах” расположено между месторождениями Куск и Эсфорди в 40 км на северо-восток от г. Бафк (31°46'47" с. ш. и 55°42'56" в. д.). Оценочная площадь месторождения составляет 5 км². Рудные месторождения металлогенической провинции протерозойского периода принадлежат классической генетической модели гидротермальных месторождений оксида железа (Cu, Au, U, редкоземельные элементы) и относятся к железоксидному медно-золоторудному (IOCG) и железоксидному апатитовому (IOA) классу [22].

АНАЛИЗ МЕТОДОВ И МАТЕРИАЛОВ

Геостатистические методы оценки запасов месторождения в первом приближении могут быть разделены на методы количественной оценки пространственного распределения месторождения и методы интерполяции содержания металла (в том числе пространственную) [9, 23]. Методы геостатистической оценки предлагают наиболее точную линейную случайную переменную при минимальной дисперсии [24]. Метод кригинга используется для линейной оценки точечных значений (точечный кригинг) или средних значений по блоку (блочный кригинг) с минимальной дисперсией ошибок [2, 25]. Структурный анализ в геостатистике является крайне эффективным инструментом, однако он сложен в осуществлении, требует временных затрат и большого объема входных данных. При пространственном анализе строятся как направленные, так и ненаправленные вариограммы. Обычный кригинг — геостатистический метод оценки локальных переменных величин с помощью интерполяции. Геостатистические методы генерируют несколько результатов с одинаковой вероятностью, которые могут быть совместно использованы для локальной неопределенной оценки с помощью последователь-

ного гауссового моделирования (ПГМ) и направленного последовательного моделирования (НПМ) [26]. В [27, 28] рассмотрено моделирование с помощью гистограмм и вариограмм, которые заключены в смежных подобластях.


Развитие компьютерных технологий позволило разработать различные алгоритмы машинного обучения, в том числе искусственную нейронную сеть, способную моделировать нелинейные процессы. ИНС выявляет взаимосвязь между входными и выходными переменными множества обрабатываемых элементов, называемых нейронами [29, 30]. Нейроны организованы в ряд слоев: входной, скрытый и выходной [31]. Искусственные нейронные сети успешно применяются для прогнозирования пространственных распределений в широком диапазоне ситуаций, в частности для оценки содержания металла в руде. При ИНС-моделировании не используются никакие предположения о факторе и/или зависимости, связанные с пространственным распределением содержания металла. Искусственные сети выявляют скрытую функциональную зависимость, присутствующую в данных доступных образцов [32]. Выбор подходящего алгоритма обучения обеспечивает максимальную прогнозирующую способность ИНС-моделей [33]. В настоящей работе ИНС-модели обучались по двум разным направлениям: по алгоритму Левенберга–Марквардта и по методу сопряженных градиентов. Оценка результатов проводилась исходя из прогнозирующей способности. Выбор оптимального алгоритма ИНС осуществлен на основе эффективности прогнозирования, которое определяется по коэффициенту статистической регрессии (R^2), суммарной квадратичной ошибке (SSE) и средней квадратичной ошибке (RMSE) [34].

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Анализ исходных данных. Перед выполнением геостатистического анализа, моделирования и интерполяции необходимо выполнить статистический анализ данных разведки [9, 10, 35]. Получено 1247 образцов из 29 буровых скважин, среднее расстояние между ними составило около 50 м. Глубина скважин варьировалась от 51 до 194.35 м, в среднем 142.75 м. Исследовано содержание Fe, FeO, P и S (табл. 1), однако для оценки рудного тела выбрано содержание Fe из-за его высокой значимости. На рис. 1 представлена гистограмма распределения содержания железа.

ТАБЛИЦА 1. Статистика содержания различных элементов в исследуемой области, %

Параметр	Fe	FeO	S	P
Количество образцов	1247	1247	1247	1247
Минимальное значение	0.53	0.54	0	0.0075
Максимальное значение	72.34	23.50	3.35	6.27
Диапазон	71.81	22.96	3.35	6.26
Среднее значение	37.94	11.70	0.11	0.15
Вариация	448.78	51.22	0.07	0.14
Среднеквадратичное отклонение	21.18	7.15	0.27	0.37



Общие выборки	1182
Минимум	0.53
Максимум	72.34
Диапазон	71.81
Среднее значение	37.94
Отклонение	448.78
Стандартное отклонение	21.18
Ассиметрия	–0.12
Коэффициент эксцесса	–1.45

Рис. 1. Частотное распределение статистических параметров содержания железа в руде (данные разведочных скважин)

Результаты вариографии. Построение вариограмм и определение анизотропного эллипсоида — ключевые факторы геостатистического анализа. После анализа исходных данных рассмотрено пространственное распределение содержания железа путем построения полувариограммных моделей. На основании результатов создана ненаправленная вариограмма содержания железа, скорректированная сферической моделью с диапазоном, составляющим 92 м, наггет-эффектом $C_0 = 131.81$ при пороговом значении 326.49 (рис. 2а).




Рис. 2. Вариограммы содержания железа в железорудном месторождении “Озеро Сиах” с указанием линий аппроксимации: ненаправленная модель (а); направленные модели с азимутом 150° , падением 0° (б); азимутом 240° , падением 75° (в); азимутом 60° , падением 15° (г)

На рис. 2б, в, г представлены направленные вариограммы содержания железа с использованием сферической модели в различных направлениях. В табл. 2 приведены параметры вариограммной модели исследуемой области.

ТАБЛИЦА 2. Параметры направленных вариограммных моделей

Вариограммная модель	Азимут	Падение	Диапазон, м	Пороговое значение	Наггет-эффект
Сферическая	240	75	85	310.12	137.221
	150	0	62	310.12	137.221
	60	15	108	310.12	137.221

Результаты обычного кригинга. В программе Surpac построена трехмерная блочная модель железорудного тела “Озеро Сиах” с размерами блоков $2 \times 2 \times 2$ м. Содержание металла в блоках смоделировано для следующей классификации областей: область низкого содержания металла (W), область среднего содержания металла (LG), область высокого содержания металла (HG) [2]. В зависимости от оценки содержания Fe области месторождения делятся на три категории. Область верхнего порога характеризуется крайне высоким присутствием железа ($>40\%$), область среднего содержания имеет $20-40\%$ Fe, область нижнего порога $<20\%$ Fe. На рис. 3 представлены результаты оценки содержания Fe с помощью ОК. Для сравнения ре-

зультатов оценки моделей с фактическими значениями исходных данных использованы инструменты перекрестной проверки — коэффициент корреляции $R^2 = 0.87$ (степень аппроксимации допустимая).




Рис. 3. Трехмерная модель оценки содержания железа методом обычного кригинга в железорудном месторождении “Озеро Сиах” (выборочное изображение)

Результаты последовательного гауссова моделирования. Последовательное гауссово моделирование использовалось в качестве основного метода оценки извлекаемых запасов и содержания металла в руде. Для выявления пространственной структуры статического гауссова случайного поля необходимо преобразовать данные о содержании металла в нормальное стандартное распределение. Учитывая, что количество итераций моделирования для оценки переменной величины оказывает влияние на получаемые результаты, в работе принято 10 итераций. Построено 10 моделей с равной вероятностью пространственного распределения железа с помощью ПГМ в исследуемой области при размере блоков $2 \times 2 \times 2$ м. Разница между десятью вариантами моделей позволит количественно определить пространственную неопределенность оценки содержания металла. При усреднении всех вариантов получена более сглаженная версия распределения содержания железа (рис. 4). Видно, что последовательное гауссово моделирование предлагает более детализированную информацию по сравнению с обычным кригингом. На основе полученных результатов можно сделать вывод о том, что ПГМ-метод имеет меньший сглаживающий эффект по сравнению с ОК, а также учитывает пространственное распределение данных.

Результаты применения искусственной нейронной сети. Искусственная нейронная сеть построена на основе анализа данных, полученных в результате разведочного бурения, для обучения, отладки и проверки ИНС-модели. Сеть после обучения должна обладать достаточным объемом информации для выполнения оценки пространственного распределения содержания железа в рассматриваемой области. Для этой цели сеть разведочных скважин покрывала значительную часть исследуемой области. Структура сети состоит из трех вход-

ных нейронов (X , Y и Z), скрытых слоев и одного выходного слоя, показывающего значение содержания железа. Количество скрытых нейронов выбрано из расчета минимального количества обобщенных ошибок ИНС-модели.




Рис. 4. Оценка содержания железа, рассчитанная на основе десяти ПГМ-моделей (выборочное изображение)

Сеть обучена по алгоритму Левенберга–Марквардта (ЛМ) и по методу сопряженных градиентов (МСГ). Для определения наиболее эффективного метода обучения ИНС-модели оценены коэффициентом регрессии (R^2), суммарной квадратичной ошибкой (SSE) и средней квадратичной ошибкой (RMSE). В табл. 3 представлены данные, характеризующие каждый этап обучения, отладки и проверки моделей с соответствующими значениям корреляции. Видно, что при алгоритме ЛМ образуется меньшее количество среднеквадратичных ошибок, которые более равномерны по сравнению с МСГ. В данном случае МСГ является неподходящим алгоритмом обучения, так как при его использовании образуется большое количество среднеквадратичных ошибок. Значения R^2 лежат в диапазоне от 0 до 1. Если значение R^2 стремится к единице, то прослеживается устойчивая зависимость между оцененными и целевыми значениями.

ТАБЛИЦА 3. Результаты ИНС-моделирования

Проверка			Отладка			Обучение			Алгоритм обучения	Количество нейронов в скрытом слое	Ряд
R^2	SSE	RMSE	R^2	SSE	RMSE	R^2	SSE	RMSE			
0.57	1.82	0.63	0.53	1.80	0.63	0.66	1.71	0.61	МСГ	2	1
0.58	1.72	0.60	0.59	1.74	0.61	0.68	1.68	0.55	МСГ	3	2
0.73	1.61	0.57	0.64	1.73	0.54	0.72	1.62	0.51	ЛМ	4	3
0.64	1.66	0.58	0.72	1.62	0.58	0.79	1.59	0.49	ЛМ	5	4
0.78	1.55	0.54	0.73	1.63	0.56	0.81	1.54	0.44	ЛМ	6	5
0.73	1.55	1.54	0.78	1.59	0.50	0.87	1.41	0.43	ЛМ	7	6
0.84	1.59	0.59	0.81	1.49	0.48	0.89	1.37	0.39	ЛМ	8	7
0.89	1.56	0.54	0.88	1.14	0.35	0.93	1.24	0.37	ЛМ	9	8
0.85	1.56	0.54	0.84	1.59	0.44	0.90	1.46	0.63	МСГ	10	9
0.79	1.76	0.68	0.81	1.62	0.54	0.87	1.51	0.72	МСГ	11	10

Результаты моделирования позволяют сделать вывод о том, что алгоритм Левенберга–Марквардта — наиболее подходящий алгоритм для прогноза содержания металла в руде. В табл. 3 выделены наиболее точные результаты после обучения и анализа данных, на рис. 5 представлена оценка содержания металла во всех блоках железорудного тела “Озеро Сиах”.




Рис. 5. Объемная модель оценки содержания железа, полученная с помощью ИНС-моделирования исследуемой области (выборочное изображение)

Соотношение содержание – объем блочной модели оценено различными методами при разных значениях бортового содержания (табл. 4). Зафиксированная высокая регрессия данных обучения, отладки и проверки показала, что нейронная сеть обладает способностью определять зависимость между входными и выходными данными с точностью до 92 %.

ТАБЛИЦА 4. Сравнение рассмотренных методов оценки содержания руды

Метод	Бортовое содержание, %	Среднее содержание, %	Объем добычи, млн т
Обычный кригинг	20	41.48	439.25
Последовательное гауссово моделирование	20	42.28	441.15
Искусственная нейронная сеть	20	42.98	450.16

ВЫВОДЫ

Установлено, что все три метода предлагают похожие рисунки распределения, которые близки к фактическим данным. Основная проблема при использовании геостатистических методов — низкая точность при построении вариограмм, а также непостоянство входных данных. Последовательное гауссово моделирование обладает меньшим сглаживающим эффектом по сравнению с обычным кригингом и учитывает пространственную рассеянность данных. Методы обычного кригинга и последовательного гауссова модели-

рования дают похожие оценки содержания и объема свыше значения бортового содержания. Однако последовательное гауссово моделирование, по сравнению с обычным кригингом, представляет более точные значения пространственного распределения содержания. Обычный кригинг не учитывает изменчивость данных и не может быть использован в тех случаях, где локальное распределение содержания имеет высокое значение. Таким образом, последовательное гауссово моделирование — более подходящий метод локальной оценки запасов по сравнению с обычным кригингом.

Результаты моделирования с помощью искусственной нейронной сети показали, что, несмотря на простоту выполняемых расчетов и отсутствие необходимости построения вариограмм, получаемая оценка запасов является корректной. Можно сделать вывод о надежности применения ИНС-моделирования для оценки содержания и запасов месторождения. Отличие между геостатистическим и ИНС-подходом лежит в оценке неизвестных значений. ИНС-метод дает возможность выполнять оценку содержания металла с высокой эффективностью и точностью.

Рекомендуется использовать все три метода определения содержания металла для оценки альтернативных вариантов и более эффективного планирования разработки рудных месторождений.

СПИСОК ЛИТЕРАТУРЫ

1. **Rezaei A., Hassani H., Moarefvand P., and Golmohammadi A.** Investigation the effect of structural pattern on mineralization model in the C-North ore deposit, Sangam, NE Iran, *J. Min. Res. Eng. (JMRE)*, 2019, Vol. 4(2). — P. 1–5.
2. **Rezaei A., Hassani H., Moarefvand P., and Golmohammadi A.** Grade 3D block modeling and reserve estimation of the C-North iron skarn ore deposit, Sangam, NE Iran, *Global J. Earth Sci. Eng.*, 2019, Vol. 6. — P. 23–37.
3. **Battalgazy N. and Madani N.** Categorization of mineral resources based on different geostatistical simulation algorithms: a case study from an iron ore deposit. *Nat. Res. Res.*, 2019, Vol. 28, No. 4. — P. 1329–1351.
4. **Jafrasteh B., Fathianpour N., and Suarez A.** Comparison of machine learning methods for copper ore grade estimation, *Comput. Geosci.*, 2018, Vol. 22. — P. 1371–1388.
5. **Afeni T. B., Akeju V. O., and Aladejare A. E.** A comparative study of geometric and geostatistical methods for qualitative reserve estimation of limestone deposit, *Geoscience Frontiers*, 2021, Vol. 12, Issue 1. — P. 243–253.
6. **Ravenscroft P. J.** Recoverable reserve estimation by conditional simulation, Geological Society, London, Special Publications, 1992, Vol. 63. — P. 289–298.
7. **Verly G.** Grade control classification of ore and waste: a critical review of estimation and simulation procedures, *Mathematical Geology*, 2005, Vol. 37, No. 5. — P. 451–475.
8. **Erarslan K.** Computer aided ore body modelling and mine valuation, In book: *Earth Sciences*, Ed. Ahmad Dar, InTech, UK, 2012. — P. 345–372.
9. **Silva D. and Almeida J.** Geostatistical methodology to characterize volcanogenic massive and stockwork ore deposits, *Miner.*, 2017, Vol. 7, No. 12.
10. **Abdessattar L., Dimitriy N., and Messaoud M.** Geostatistical modeling by the ordinary kriging in the estimation of mineral resources on the Kieselguhr mine, Algeria. In: *IOP Conference Series: Earth and Environmental Sci.*, 2019. DOI:10.1088/1755-1315/362/1/012051.
11. **Sarkar B. C. and Roy I.** A geostatistical approach to resource evaluation of kala iron ore deposit, Sundergarh dist., Orissa. *J. Geol. Soc. India*, 2005, Vol. 65, No. 5. — P. 553–561.

12. **Taghvaeenezhad M., Shayestehfar M. R., Moarefvand P., and Rezaei A.** Quantifying the criteria for classification of mineral resources and reserves through the estimation of block model uncertainty using geostatistical methods: a case study of Khoshoumi Uranium deposit in Yazd, Iran, *J. Geosystem Eng.*, 2020, Vol. 23. — P. 216–225.
13. **Shayestehfar M. R., Mohammadi M., and Rezaei A.** Modeling, ore estimation and preliminary design of the chromite ore, mine six, Abdasht Esfandoghe Kerman, Iran, *J. Economic Geology, Iran*, 2011, Vol. 1, Issue 4. — P. 29–40.
14. **Akeju V. O. and Afeni T. B.** Investigation of the spatial variability in Oyo-Iwa limestone deposit for quality control, *J. Eng. Sci. Technol.*, 2015, Vol. 10, No. 8. — P. 1065–1085.
15. **Chilès J. P. and Delfiner P.** *Geostatistics: modeling spatial uncertainty*, 2nd ed., Wiley, New York, 2012. DOI: 10.1002/9781118136188.
16. **Tadeusiewicz R.** Neural networks in mining sciences — General overview and some representative examples, *Arch. Min. Sci.*, 2015, Vol. 60, No. 4. — P. 971–984.
17. **Jalloh A., Sasaki K., Jalloh Y., and Barrie A. K.** The integration artificial neural networks and geostatistical 3D geological block modeling: a case study on a mineral sand deposit, *Proc. 24th Int. Min. Congress of Turkey, IMCET*, 2016. — P. 257–263.
18. **Al-Alawi S. M. and Tawo E. E.** A comparison between artificial neural network and a geostatistical technique in the estimation of regionalized variables, *Eng. J. Univ Qatar*, 1999, Vol. 12. — P. 125–149.
19. **Dutta S., Bandopadhyay S., Ganguli R., and Mishra D.** Machine learning algorithms and their application to ore reserve estimation of sparse and imprecise data, *J. Intell. Learn. Syst. Appl.*, 2010, Vol. 2. — P. 86–96.
20. **William W. G.** A novel application of neural networks for instant iron-ore grade estimation, *Expert. Syst. Appl.*, 2010, Vol. 37, Issue 12. — P. 8729–8735.
21. **Nezamolhosseini S. A., Mojtahedzadeh S. H., and Gholamnejad J.** The application of artificial neural networks to ore reserve estimation at Choghart iron ore deposit, *Anal. Numer. Methods Min. Eng.*, 2017, Vol. 6. — P. 73–83.
22. **Torab F. M.** *Geochemistry and metallogeny of magnetite-apatite deposits of the Bafq mining district, Central Iran. Unpublished Ph. D. Thesis, Technical University of Clausthal, Clausthal, Germany, 2008. — 131 p.*
23. **Isaaks E. H. and Srivastava R. M.** *An introduction to applied geostatistics*, Oxford University Press, New York, 1989. — 562 p.
24. **Morshedy H., Torabi S. A., and Memarian H.** A new method for 3D designing of complementary exploration drilling layout based on ore value and objective functions, *Arab. J. Geosci.*, 2015, Vol. 8, P. 8175–8195.
25. **Krige D. G.** *A statistical approach to some mine valuations and allied problems at the Witwatersrand, University of Witwatersrand, Johannesburg, South Africa, 1951.*
26. **Almeida J.** Modelling of cement raw material compositional indices with direct sequential cosimulation, *Eng. Geol.*, 2010, Vol. 114. — P. 26–33.
27. **Deutsch C. V.** *Geostatistical reservoir modeling*, New York, Oxford University Press, 2002.
28. **Leuangthong O., Prins C., and Deutsch C. V.** *SGSIM_LVA: Gaussian simulation with locally varying angles*, Centre for Computational Geostatistics, 2006, Paper 408, Report 8.
29. **Haykin S.** *Neural Networks: a comprehensive foundation*, Prentice Hall, Upper Saddle River, 1999. — 842 p.

- 30. Allahkarami E., Nuri O. S., Abdollahzadeh A., Rezai B., and Chegini M.** Estimation of copper and molybdenum grades and recoveries in the industrial flotation plant using the artificial neural network, *Int. J. Nonferr. Metall.*, 2016, Vol. 5, No. 3. — P. 23–32.
- 31. Bishop C. M.** Neural networks for pattern recognition, Clarendon Press, Oxford, 1995. — 482 p.
- 32. Jalloh A. B., Sasaki K., Jalloh Y., and Barrie A. K.** Integrating artificial neural networks and geostatistics for optimum 3D geological block modelling in mineral reserve estimation: a case study, 4th World Conference on Applied Sciences, Engineering & Technology 24–26 October 2015, Kumamoto University, Japan.
- 33. Plumb A. P., Rowe R. C., York P., and Brown M.** Optimisation of the predictive ability of artificial neural network (ANN) models: A comparison of three ANN programs and four classes of training algorithm, *Eur. J. Pharm. Sci.*, 2005, Vol. 25, No. 4–5. — P. 395–405.
- 34. Iraj H., Mohammadi M. A., Shakouri B., and Meshram S. G.** Predicting reservoir volume reduction using artificial neural network, *Arabian J. Geosci.*, 2020, Vol. 13.
- 35. Rezaei A., Hassani H., Fard Mousavi S. B., and Jabbari N.** Evaluation of heavy metals concentration in Jajarm Bauxite deposit in Northeast of Iran using environmental pollution indices, *Malaysian J. Geosci.*, 2019, Vol. 3, No. 1. — P. 12–20.

Поступила в редакцию 02/V 2021

После доработки 23/IX 2021

Принята к публикации 24/XII 2021