

УДК 622.14:553:004.032.26

ШОЛОМИЦКИЙ А.А., СЕЛЕЗНЕВ А.Е (Донецкий национальный технический университет), БЕЛЯКОВ С.Л. (Таганрогский государственный радиотехнический университет)

ИСПОЛЬЗОВАНИЕ ГЕОСТАТИСТИКИ И НЕЙРОННЫХ СЕТЕЙ ПРИ ОЦЕНКЕ ЗАПАСОВ ПОЛЕЗНЫХ ИСКОПАЕМЫХ

В статье рассмотрены вопросы применения геостатистических методов и нейронных сетей для оценки запасов полезных ископаемых на месторождениях различных типов. Исследованы возможности применения обучаемых нейронных сетей при подсчете запасов добываемого полезного ископаемого. Результаты показали хорошую сходимость оценок тоннажа полезного ископаемого, как с использованием геостатистических методов, так и нейронных сетей.

Большинство существующих месторождений полезных ископаемых Украины и стран СНГ разрабатываются на основе данных, полученных в результате работ по геологическому изучению недр, проведенных еще в 60-80х годах прошлого столетия. В результате этого многие месторождения полезных ископаемых практически полностью отработаны или их дальнейшая эксплуатация является экономически невыгодной и неперспективной.

Согласно Кодекса Украины "О недрах" [1] работы по геологическому изучению недр проводятся и организуются специально уполномоченным центральным органом исполнительной власти по геологическому изучению и обеспечению рационального использования недр на основе специальных комплексных или целевых программ и финансируются из государственного бюджета Украины, за счет поступлений от горных предприятий за выполненные раньше геологоразведочные работы, которые финансировались из государственного бюджета. Но, ввиду того, что с 2002 года горные предприятия временно освобождены от уплаты данного платежа, фактически работы по геологическому изучению недр носят точечный характер и не позволяют выявить и включить в Государственный фонд месторождений полезных ископаемых для дальнейшей промышленной разработки новые перспективные месторождения [2].

Поэтому многие горные предприятия вынуждены кроме дорогостоящей лицензии на добычу полезных ископаемых (от 1 млн. грн.) приобретать дополнительную лицензию на геологическое изучение полезных ископаемых для разведки новых месторождений. При этом, учитывая дороговизну комплекса горно-буровых и эксплуатационных работ, горные предприятия (как частной, так и государственной форм собственности) стремятся привлечь иностранные инвестиции в финансирование разработки нового месторождения, с целью компенсирования затрат на его разведку.

Но, для привлечения иностранных инвестиций, инвестор должен быть уверен в эффективности вложения своих средств в разработку нового месторождения, т.е. получения прибыли. Для этого, в 1989 году Австралийский Объединенный Комитет по Рудным Запасам (Joint Ore Reserves Committee ('JORC')) опубликовал "JORC Code", в который входили рекомендации по классификации и составлению публичной отчетности по рудным запасам. На основе этой публикации созданный в 1994 году Совет Горных и Металлургических Организаций (the Council of Mining and Metallurgical Institutions ('CMMI')), впоследствии переименованный в Combined Reserves International Reporting Standards Committee ('CRIRSCO'), утвердил в 1997 году Международный шаблон отчетности для опубликования результатов разведки месторождения полезных ископаемых, его минеральных ресурсов и минеральных запасов. По этому стандарту мине-

ральные ресурсы делятся на номинальные и подсчитанные, а минеральные запасы на возможные и оцененные. Составленный по международному шаблону отчет является "визитной карточкой" месторождения, и его публикация позволяет горному предприятию рассчитывать на реальные иностранные инвестиции.

Основная проблема для внедрения данной формы отчетности на горных предприятиях Украины и стран СНГ заключается в том, что подсчет минеральных запасов, должен производиться с учетом современных методов количественной локальной экстра- и интерполяции данных бурения. Одним из таких методов является геостатистика, который позволяет повысить эффективность геологоразведочных работ и снизить затраты на горно-буровые работы. При этом при обработке данных бурения с помощью данного метода есть ряд существенных ограничений (например, однородность обрабатываемого материала, стационарность пространственной функции, нормальность распределения вероятностей показателей данных бурения, линейность интерполяционной функции), которые можно снять с помощью бурно развивающейся технологии обучаемых нейронных сетей.

Использование нейронных сетей в геологии, в частности при интерполяции данных опробования скважин, является актуальным и перспективным направлением развития процедур создания блочных моделей. Так работы по использованию нейронных сетей для решения различных инженерно-технических задач широко ведутся в Болгарии, Румынии, странах Прибалтики [3,4,5].

Главная задача заключается в подборе хорошей архитектуры нейронной сети, которая давала бы минимальную ошибку на тестовой (интерполяционной) выборке. Схема процесса создания блочной модели с использованием нейронной сети представлена на рис.1.

При этом возможность применения нейронных сетей для оценки запасов в данное время ещё недостаточно изучена. Так как еще не совсем понятно, по каким критериям выполнять обучение, как влияет размерность входных и выходных данных на обучаемую сеть, на каком расстоянии или в какой области от исходных данных можно считать прогнозы сети достаточно надежными для решения поставленных задач (образно говоря критерии надежности) [6,7].

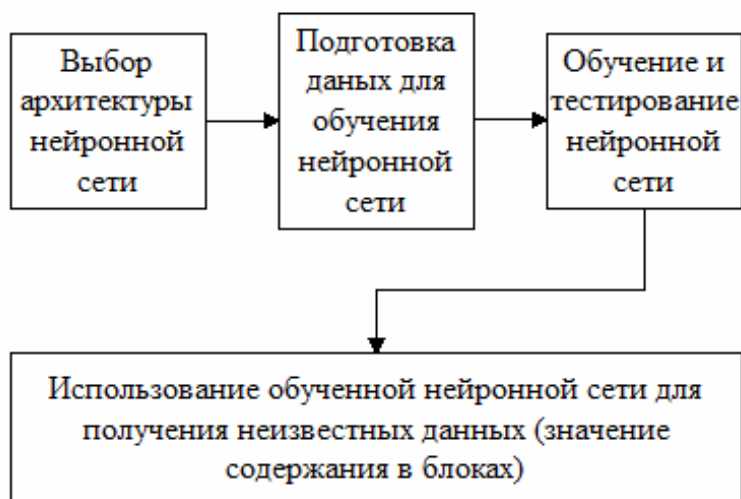


Рис.1. Создание блочной модели с использованием нейронной сети

Нейронная сеть состоит из совокупности искусственных нейронов.

Основные функции искусственного нейрона:

а) он получает входные сигналы через несколько входных каналов;

- б) каждый входной сигнал проходит через соединение, имеющее определенную интенсивность (вес);
- в) этот вес соответствует синаптической активности биологического нейрона;
- г) с каждым нейроном связано определенное пороговое значение;
- д) вычисляется взвешенная сумма входов, из нее вычитается пороговое значение и в результате получается величина активации нейрона (пост-синаптический потенциал нейрона);
- е) сигнал активации преобразуется с помощью функции активации и в результате получается выходной сигнал нейрона.

Обычно нейронная сеть имеет входы (принимающие значения интересующих нас переменных из внешнего мира) и выходы (прогнозы или управляющие сигналы), они также называются входными и выходными слоями. Кроме этих слоев, в нейронной сети может быть еще много промежуточных (скрытых) нейронов, выполняющих внутренние функции. Входные, скрытые и выходные нейроны должны быть связаны между собой синаптическими связями, отражающие степень влияния одного нейрона на другой. Простейшая нейронная сеть имеет структуру прямой передачи сигнала: сигналы проходят от входов через скрытые элементы и приходят на выходные элементы.

Анализ данных бурения и оценка запасов полезных ископаемых с помощью геостатистического метода предполагает выполнение ряд последовательных математических операций над совокупностью данных, таких как: построение гистограмм, оценка основных статистик, расчет вариограмм, кригинг, условное моделирование.

Для примера рассмотрим оценку запасов полезных ископаемых золоторудного месторождения «Солнечное» с использованием геостатистики и нейронных сетей.

Основные горно-буровые работы на месторождении проведены в сентябре-октябре 1999г. Главным полезным ископаемым является металл Au (золото). Площадь разведки составляет 35 га, протяженность в направлении В-З – 482 м, в направлении С-Ю – 720 м. Пробурено 94 скважины, в результате опробования которых получено 729 проб со средней длиной 2 метра.

Совокупность данных количественного содержания (г/т) золота в каждой пробе обработана и проанализирована с помощью статистических программных пакетов (рис.2 - рис.5).




Рис.2. Гистограмма содержаний золота по кварцевой жиле (предельная величина - 9.36 г/т) при ширине класса 0.5 г/т

Параметры процедуры обычного кригинга и условного моделирования для оценки значений блочной модели получены после расчета вариограмм, как в двумерном, так и в трехмерном пространстве и кросс-проверки полученной вариограммной модели.




Рис.3. Гистограмма содержаний золота по блочной модели (20x20x20м) (обычный кригинг) при ширине класса 0.25 г/т




Рис.4. Гистограмма содержаний блока по блочной модели (20x20x20м) (условное моделирование) при ширине класса 0.2 г/т




Рис.5. Гистограмма содержаний золота по блочной модели (20x20x20м) (нейронная сеть) при ширине класса 0.2 г/т

Выбор архитектуры нейронной сети зависит от задачи, которую необходимо решить и размерности входных и выходных векторов. Поэтому, исходя из того, что нейронная будет использоваться для прогнозирования (оценки) неизвестных значений блочной модели, т.е. входным вектором будет вектор координат, а выходным - вектор содержаний золота, использована архитектура многослойного персептрона с алгоритмом обучения - сопряженные градиенты (рис.6). Применение данной архитектуры при

решении геологических задач обосновано в работе болгарских ученых Топалова и Христова [8].

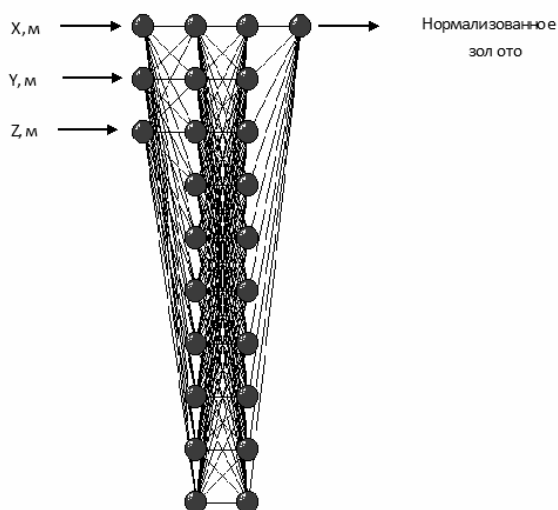


Рис.6. Архитектура нейронной сети. Количество входов - 3. Количество выходов - 1. Количество скрытых слоев - 2. Количество нейронов в скрытом слое - 40 (на рисунке изображена только часть нейронов скрытых слоев)

Число нейронов в скрытом слое согласно [6] рассчитывается по формуле:

$$\frac{N}{10} - n - m \leq L \leq \frac{N}{2} - n - m, \quad (1)$$

где N - число элементов в обучающей выборке; n - размерность входного сигнала; m - размерность выходного сигнала; L - число нейронов в двухслойной сети.

Учитывая, что $N=790$, $n=3$, $m=1$, то для проектируемой нейронной сети было принято решение использовать по сорок нейронов на каждом из двух скрытых слоев (общее количество – восемьдесят нейронов).

При обучении сети в качестве эталонных выходов использовались нормализованные значения содержаний золота, так как в процессе обучения на нетрансформированных данных было установлено, что нейронная сеть обучается прогнозировать значения во всем диапазоне R , при этом исходные данные по золоту определены только на R^+ . Результаты обучения нейронной сети приведены в табл. 1

Табл.1. Результаты обучения нейронной сети

Показатель	Значение
Количество эпох обучения	3296
Средняя оценка обучения	0.00345
Допустимая ошибка	0.1
Кол-во правильно решенных примеров	200
Средняя ошибка	0.19
Выборочная оценка константы Липшица	74.03
Алгоритм обучения	Сопряженные градиенты
Предобработка входных данных:	
- X	(X-1684.09)/241.02
- Y	(Y-7339.82)/218.33
- Z	(Z-118.96)/119.05
Значимость входов:	
- X	1
- Y	0.9988618
- Z	0.865808

Рассчитанные блочные модели достаточно близки друг к другу, о чем свидетельствуют как гистограммы содержаний, так и погоризонтные срезы (рис.7- рис.11).

Общие запасы золота по этим трем блочным моделям составили 18,3 тонн (обычный кригинг), 14,67 тонн (условное моделирование), 19,93 (нейронная сеть) соответственно.




Рис.7. Горизонтальное сечение блочной модели (обычный кригинг) (золото, г/т)




Рис.8. Горизонтальное сечение блочной модели (обычный кригинг) (дисперсия оценки)

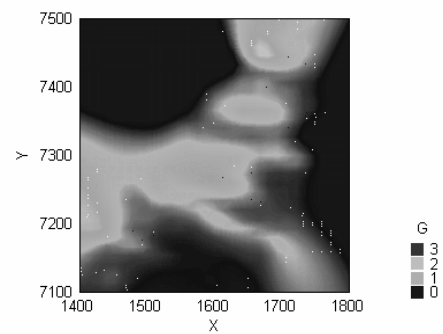


Рис.9. Горизонтальное сечение блочной модели (условное моделирование) (золото, г/т)




Рис.10. Горизонтальное сечение блочной модели (условное моделирование) (дисперсия оценки)

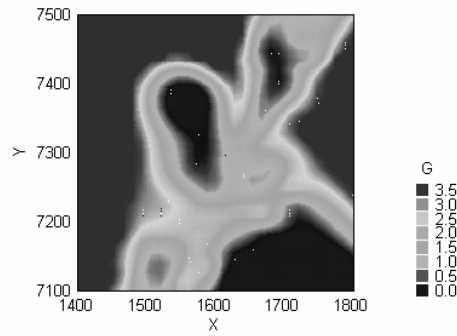


Рис.11. Горизонтальное сечение блочной модели (нейронная сеть) (золото, г/т)

Таким образом, видно, что запасы по блочной модели, полученной обычным кригингом и запасы по блочной модели, спрогнозированной нейронной сетью практически близки друг другу (отличие только в форме графика тоннаж-насыщение (рис.12)), что может говорить о возможности применения нейронных сетей для оценки запасов. При этом преимущество нейронных сетей перед геостатистикой заключается в более простом пути расчета, в отличие от геостатистического метода.

На рис.13 приведена трехмерная визуализация полученной блочной модели (нейронная сеть) с использованием разработанного программного обеспечения. Из рисунка видно, что месторождение структурировано, т.е. имеется возможность по результатам обучения нейронной сети выполнить геометризацию отдельных групп качественных свойств горных пород.




Рис.12. Графики зависимостей тоннажа от насыщения по блочным моделям (ОК – обычный кригинг, УМ – условное моделирование и НС – нейронная сеть)

На рисунке блочная модель представлена в двух ракурсах. В результате сравнения блочных моделей, значения которых были рассчитаны геостатистическим методом и, используя обучаемую нейронную сеть, отклонение полученных результатов составило 8%. Следовательно, имеется возможность использовать обучаемую нейронную сеть для оценки запасов полезных ископаемых на месторождении (особенно на месторождениях с многовершинной функцией плотности распределения вероятностей полезного ископаемого). Для этого должна быть обоснована архитектура и количество нейронов на скрытых слоях для конкретного типа месторождения. Кроме того, при использовании нейронной сети необходимо иметь в виду, что этот метод не дает 100% оценок для каждого элемента блочной модели. Существуют блоки, для которых нейронная сеть

дает неправильное решение (оценка существенно превышает порог в 3δ) или не находит его вообще. Такие данные необходимо либо исключать из общей массы значений либо, если их количество превышает определенный порог, произвести повторное обучение и вычисления на нейронной сети, но уже с новыми значениями параметров. Для установления величины порога на конкретный тип месторождения необходимо провести дополнительные исследования.




Рис.13. Визуализированная в 3D блочная модель (нейронная сеть) с размерами блока 20x20x20 м (светлые блоки, золото: 1-3 г/т; темные блоки, золото: 0-1 г/т).

Использование нейронной сети для оценки запасов полезных ископаемых на месторождении на данном этапе ещё недостаточно хорошо изучено и требует дополнительных исследований, в плане выбора архитектуры и количества нейронов для конкретного типа месторождения полезных ископаемых (россыпное, осадочное и т.д.). Также необходимо решить проблему получения неправильных оценок истинных значений для отдельных элементов блочной модели.

Библиографический список

1. Кодекс Украины "О недрах" // Ведомости Верховной Рады (ВВР). – Киев, 1994. – №36. – ст.340.
2. Горный Закон Украины // Ведомости Верховной Рады (ВВР). – Киев, 1999. – №50. – ст.433.
3. Басу Д., Майтра Б. Моделирование скорости потока в гетерогенном пространстве движения с использованием искусственных нейронных сетей (ИНС) // Transport (Транспорт). – Vilnius: Technika, 2006. – Т. 21, № 4. – р. 269-273.
4. Пунишкис Д., Лауритис Р., Дирмейкис Р. Нейронные сети для фильтрации спама в электронной почте // Электроника и электротехника. – Каунас: Технология, 2006. – № 5(69). – с. 73–76.
5. Атанасова Т. Интелигентни компютерни системи. – Варна: Издателство "Наука и икономика", 2005. – 156 с.
6. Круглов В. В., Дли М. И., Голунов Р. Ю. Нечеткая логика и искусственные нейронные сети. – СПб.: НейроЛит, 2003. – 384 с.
7. Яхьяева Г.Э. Нечеткие множества и нейронные сети. – М.: БИНОМ, 2006. – 238 с.
8. Topalov S., Hristov V. Prognostication of Geological Parameters Value Using Neural Networks. – Budapest.: Mine Surveying XIII International Congress, 2007. – р. 15-20.
9. Давид М. Геостатистические методы при оценке запасов руд. – М.: Недра, 1980. – 360 с.
10. Давыденко Е.В. Воксельная технология моделирования объектов // Графика и мультимедиа. – 2002. – №3. – с.12 – 15.
11. Капутин Ю.Е. Горные компьютерные технологии и геостатистика. – М.: Недра, 2002. – 424с.
12. Матерон Ж. Основы прикладной геостатистики. – М.: Недра, 1968. – 365 с.
13. Эйнджел Э. Интерактивная компьютерная графика. – М.: Издательский дом "Вильямс", 2001. – 471 с.
14. Deutsch C.V., Journel A.G. GSLIB – Geostatistical Software Library. – New York.: Oxford University Press, 1992. – 312 p.