

УДК 004.032.26

Е.Е. Федоров (д-р техн. наук, доц.), Ю.Л. Дикова
ГБУЗ «Донецкий национальный технический университет», г. Красноармейск
кафедра компьютерных наук
E-mail: fedorovee75@mail.ru; juli.dikova@gmail.com

РАЗРАБОТКА СПОСОБА ПРОГНОЗА СОДЕРЖАНИЯ ВЗРЫВООПАСНЫХ ГАЗОВ В ГОРНЫХ ВЫРАБОТКАХ

В статье рассмотрены и проанализированы существующие методы прогноза содержания взрывоопасных газов. Исходя из основных преимуществ и недостатков, разработан и реализован нейросетевой способ прогноза содержания взрывоопасных газов в горных выработках. В основу способа заложена нейронная сеть NARX, архитектура которой определена на основе проведенных экспериментов. Критерием выбора архитектуры было минимальное значение MSE. Для оценки эффективности предложенного способа были проведены численные исследования, которые доказывают эффективность выбранной сети и ее архитектуры.

Ключевые слова: прогноз, содержание взрывоопасных газов, нейронная сеть, идентификация структуры и параметров сети, среднеквадратичная ошибка.

Общая постановка проблемы. В настоящее время одной из важнейших проблем, существующих в горной промышленности, является повышение производственной безопасности. На сегодняшний день современные компьютерные системы аэрогазового контроля [1 – 4], используемые на шахтах, не предусматривают возможность прогноза содержания взрывоопасных газов. Это приводит к тому, что мероприятия, направленные на недопущение аварий или снижение их последствий, могут быть проведены слишком поздно. Поэтому разработка способов прогноза содержания взрывоопасных газов в горных выработках, используемых для повышения качества оценки аэрогазовой ситуации, является актуальной.

Постановка задачи исследования. Целью работы является разработка способа исследования высоко динамичного процесса изменения концентрации взрывоопасных газов в шахте. Для достижения цели были поставлены и решены следующие задачи:

- провести анализ существующих методов прогноза;
- выбрать искусственную нейронную сеть прогноза;
- определить структуры модели искусственной нейронной сети;
- выбрать критерий оценки эффективности нейросетевой модели прогноза;
- обучить модели искусственной нейронной сети;
- выполнить численные исследования.

Результаты разработки и исследований. На сегодняшний день в качестве инструмента для прогноза известно множество подходов, среди которых можно выделить:

- регрессионные и авторегрессионные методы прогнозирования;
- методы, основанные на экспоненциальном сглаживании;
- методы на базе цепей Маркова;
- на базе классификационно-регрессионных деревьев;
- нейросетевые методы прогноза.

В работе [5] приведена сравнительная характеристика перечисленных способов. Поскольку использование нейронных сетей при прогнозировании дает ощутимое преимущество, которое заключается в том, что: взаимосвязи между факторами исследуются на готовых моделях; не требуются никакие предположения относительно распределения факторов;

априорная информация о факторах может отсутствовать; исходные данные могут сильно коррелировать, быть неполными или зашумленными; возможен анализ систем с высокой степенью не линейности; быстрая разработка модели; высокая адаптивность; возможен анализ систем с большим количеством факторов; не требуется полный перебор всех возможных моделей; возможен анализ систем с неоднородными факторами, в статье будет использоваться нейросетевой способ прогноза.

Поскольку концентрация взрывоопасных газов быстро изменяется во времени, то прогноз осуществляется на основе динамических (с временной задержкой) искусственных нейронных сетей. В качестве таких сетей чаще всего используются:

– нейросеть Джордона (JNN) [6], которая является динамической рекуррентной двухслойной сетью и построена на базе MLP.

– нейросеть Элмана (ENN) или простая рекуррентная сеть (SRN) [6], которая является динамической рекуррентной двухслойной сетью и построена на базе MLP.

– рекуррентный многослойный персептрон RMLP[7], который является динамической рекуррентной многослойной сетью и построен на базе MLP.

– модель нелинейной авторегрессии с экзогенными (т.е. внешними) входами NARX[7], которая является динамической рекуррентной двухслойной сетью и построена на базе MLP.

– нейросеть с задержкой по времени (TDNN) [7], которая является динамической (с временной задержкой) нерекуррентной многослойной сетью.

– распределенная сеть прямого распространения с задержкой по времени (distributed TLFN)[7], которая является динамической нерекуррентной двухслойной сетью.

– динамическая (с временной задержкой) нерекуррентная многослойная сеть VNN[8], классы которой разделяются гиперплоскостями. В общем случае количество уровней может быть больше трех. Эта сеть относится к нейросетям высокого порядка.

В таблице 1 приведены сравнительные характеристики динамических сетей. Количество нейронов входного слоя соответствует количеству контролируемых параметров. Исследования проводились для одного показателя – значения концентрации метана, полученного с датчика метана TX 3261. Это соответствует одному нейрону входного слоя.

Таблица 1 – Результаты экспериментальных исследований нейронных сетей

Критерий \ Сеть	RLMP	JNN	ENN(SRN)	NARX	TDNN	TLFN	VNN
Наличие обратной связи	+	+	+	+	–	–	–
Задержка во входном слое	–	–	–	+	+	+	+
Точность прогноза, %	90	80	85	98	88	83	87

Поскольку NARX дает наибольшую точность прогноза, эта сеть выбирается для решения задачи прогнозирования. На рисунке 1 представлена структура модели выбранной нейросети. Модель NARX представлена в виде:

$$y_j^{(1)}(n) = f^{(1)}(b_j^{(1)} + \sum_{i=1}^{M^{(0)}} w_{ij}^{(1)} x(n-(i-1)) + \sum_{i=M^{(0)}+1}^{M^{(0)}+M^{(1)}} w_{ij}^{(1)} y_j^{(2)}(n-i)); \quad j \in \overline{1, N^{(1)}}; \quad (1)$$

$$y_i^{(2)}(n) = f^{(2)}(b_i^{(2)} + \sum_{i=1}^{N^{(1)}} w_i^{(2)} y_i^{(1)}(n)); \quad (2)$$

где $N^{(k)}$ – количество нейронов в k -м слое, $M^{(k)}$ – задержка в k -м слое; $w_{ij}^{(1)}(n)$ – вес связи от нейрона в момент времени $n-(i-1)$ к j -му нейрону в первом слое в момент времени n ; $w_i^{(2)}(n)$ – вес связи от i -го нейрона к нейрону во втором слое в момент времени n ; $y_j^{(1)}(n)$ –

выход j -го нейрона в первом слое; $y^{(2)}(n)$ – выход нейрона во втором слое; $f^{(k)}$ – функция активация нейронов k -го слоя (логистическая или гиперболический тангенс).

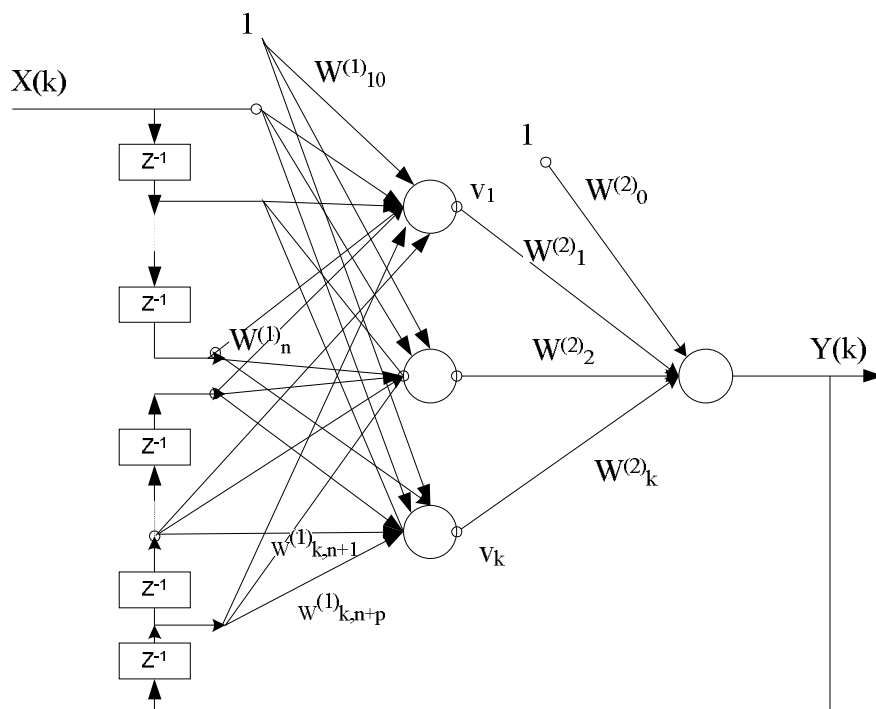


Рисунок 1 – Нелинейная авторегрессия с экзогенными входами (NARX)

Для определения структуры модели NARX (1, 2) (определения количества скрытых нейронов) был проведен ряд экспериментов, результаты которых представлены на рисунке 2. В качестве входных данных для обучения нейросети были использована выборка значений показаний датчиков метана объемом 29000. Критерием выбора структуры модели сети было минимальная среднеквадратичная ошибка прогноза. Как видно из рисунка 2, с увеличением количества скрытых нейронов значение ошибки уменьшается. Для прогноза концентрации метана достаточно использовать 10 скрытых нейронов, поскольку при дальнейшем увеличении количества нейронов изменение значения ошибки незначительно.

В работе для обучения модели выбран критерий адекватности модели, который означает выбор таких значений параметров $w_{ij}^{(1)}$ и $w_i^{(2)}$, которые доставляют минимум среднеквадратичной ошибки (разности выхода по модели и желаемого выхода):

$$F = \frac{1}{P} \sum_{p=1}^P (y_p - d_p)^2 \rightarrow \min_{w_{ij}^{(1)}, w_i^{(2)}}, \quad (3)$$

где P – количество тестовых реализаций; y_p – прогноз, полученный по модели; d_p – желаемый прогноз.

Обучение модели нейросети (1, 2) подчинено критерию (3), для чего могут использоваться алгоритм обратного распространения и генетический алгоритм. Рассмотрим алгоритм обратного распространения ошибки.

1. Номер итерации обучения $n = 1$, $y^{(1)}(n-i) = 0$, $i \in \overline{1, N^{(1)}}$, инициализация всех смещений (порогов) $b_j^{(k)}(n)$ и весов сети в слоях $w_{ij}^{(1)}(n)$, $i \in \overline{1, M^{(0)} + M^{(1)}}$, $j \in \overline{1, N^{(1)}}$, $i \in \overline{1, N^{(1)}}$, где $N^{(1)}$ – количество нейронов в первом слое, $M^{(k)}$ – задержка в k -м слое.

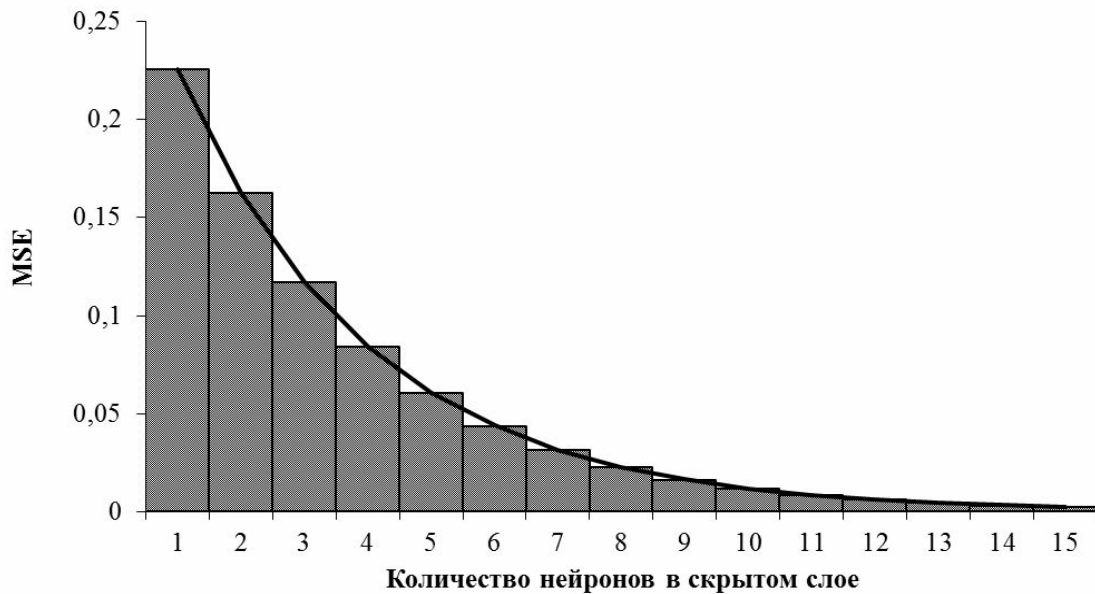


Рисунок 2 – Гистограмма зависимости значения среднеквадратичной ошибки от количества нейронов в скрытом слое

2. Задается обучающее множество $\{(x, d) \mid x_\mu \in R, d_\mu \in R\}$, $\mu \in \overline{1, P}$, где x_μ – μ -й вектор факторов, d_μ – μ -й вектор желаемых откликов, P – мощность обучающего множества. Номер текущей пары из обучающего множества $\mu = 1$.

3. Вычисление выходного сигнала для каждого слоя (прямой ход):

$$\begin{aligned}
 y^{(0)}(n - (i - 1)) &= x_{\mu - (i - 1)}, \quad i \in \overline{1, M^{(0)}}; \\
 y_j^{(1)}(n) &= f^{(1)}(s_j^{(1)}(n)), \quad j \in \overline{1, N^{(1)}}; \\
 s_j^{(1)}(n) &= \sum_{i=0}^{M^{(0)}} w_{ij}^{(1)}(n) y^{(0)}(n - (i - 1)) + \sum_{i=M^{(0)}+1}^{M^{(0)}+M^{(1)}} w_{ij}^{(1)}(n) y^{(2)}(n - i); \\
 y^{(2)}(n) &= f^{(2)}(s^{(2)}(n)), \quad s^{(2)}(n) = \sum_{i=0}^{N^{(1)}} w_i^{(2)}(n) y_i^{(1)}(n).
 \end{aligned}$$

Считается, что

$$w_{0j}^{(1)}(n) = b_j^{(1)}(n), w_0^{(2)}(n) = b^{(1)}(n), y^{(0)}(n) = y_0^{(1)}(n) = 1.$$

4. Вычисление среднеквадратичной ошибки прогноза нейросети:

$$E(n) = \frac{1}{2} e^2(n), \quad e(n) = y^{(2)}(n) - d_\mu.$$

5. Настройка синаптических весов (обратный ход). Для настройки весовых коэффициентов используется рекурсивный алгоритм, который сначала применяется к выходным нейронам сети, а затем проходит сеть в обратном направлении до первого слоя. Синаптические веса настраиваются в соответствии с формулой:

$$w_{ij}^{(1)}(n + 1) = w_{ij}^{(1)}(n) - \eta \frac{\partial E(n)}{\partial w_{ij}^{(1)}(n)};$$

$$w_i^{(2)}(n+1) = w_i^{(2)}(n) - \eta \frac{\partial E(n)}{\partial w_i^{(2)}(n)},$$

где η – параметр, определяющий скорость обучения (при большом η обучение происходит быстрее, но увеличивается опасность получить неверное решение), $0 < \eta < 1$.

$$\begin{aligned} \frac{\partial E(n)}{\partial w_i^{(2)}(n)} &= y_i^{(1)}(n) g^{(2)}(n); \\ \frac{\partial E(n)}{\partial w_{ij}^{(1)}(n)} &= \begin{cases} y^{(2)}(n-i) g_j^{(1)}(n), & \text{если } i > M^{(0)} \\ y^{(0)}(n-(i-1)) g_j^{(1)}(n), & \text{если } i \leq M^{(0)} \end{cases}, \\ g^{(2)}(n) &= f^{(2)}(s^{(2)}(n))(y^{(2)}(n) - d_\mu); \\ g_j^{(1)}(n) &= f^{(1)}(s_j^{(1)}(n)) w_j^{(2)}(n) g^{(2)}(n). \end{aligned}$$

6. Проверка условия завершения. Если очередная эпоха обучения не закончена, увеличив счетчик итераций на 1, переходим к следующему обучающему примеру (шаг 3). Если же очередная эпоха обучения завершена, и средняя ошибка обучения превышает заданный порог, то начинается новая эпоха обучения (шаг 2). И, наконец, если очередная эпоха обучения завершена и средняя ошибка обучения меньше заданного порога, то обучение завершено.

Альтернативой алгоритму обратного распространения является генетический алгоритм. В качестве особи в генетическом алгоритме используется вектор весов $w_{ij}^{(1)}$ и $w_i^{(2)}$, а в качестве фитнес-функции используется критерий (3).

Авторами исследовались три типа генетического алгоритма (таблица 3) [9, 10]. Первый тип исследует все пространство поиска и не является направленным. Для этого типа возможна потеря лучших решений. Он требует значительного времени поиска. Второй тип является направленным. Для этого типа возможно попадание в локальный оптимум. Третий тип является комбинированным, т.е. совмещает направленность поиска с исследованием всего пространства поиска. Для выбора наиболее эффективного алгоритма обучения было проведено численное исследование, результаты которого представлены в таблице 4. Для оценки эффективности были выбраны такие критерии, как количество итераций и точность прогноза.

Таблица 3 – Структура генетических алгоритмов трех типов

Операторы генетических алгоритмов	Типы генетических алгоритмов		
	Тип 1	Тип 2	Тип 3
Репродукция	равновероятный отбор	линейно упорядоченный отбор	комбинация равновероятного и линейно упорядоченного отбора
Кроссинговер	равновероятный, отбор особей – скрещивание лучших особей с худшими	равновероятный, отбор особей – скрещивание лучших особей с лучшими	равновероятный, отбор особей – комбинация скрещиваний лучших особей с худшими и лучших особей с лучшими
Мутация	однородная с высокой вероятностью	однородная с низкой вероятностью	неоднородная
Редукция	равновероятная схема	селекционная схема	комбинация равновероятной и селекционной схемы

Таблица 4 – Сравнительные характеристики алгоритмов обучения нейронной сети

Характеристика	Алгоритм	Алгоритм обратного рас- пространения	Генетический алгоритм		
			Тип 1	Тип 2	Тип 3
Количество итераций		1000	160	130	100
Точность прогноза (СКО)		$118 \cdot 10^{-3}$	$180 \cdot 10^{-4}$	$180 \cdot 10^{-4}$	$150 \cdot 10^{-4}$

Согласно результатам сравнения, генетический алгоритм типа 3 в задаче обучения нейронной сети является наиболее подходящим для процедуры обучения сети.

Выводы.

1. Для решения проблемы повышения производственной безопасности в горной промышленности исследованы существующие методы прогноза содержания взрывоопасных газов в шахтах. Данные исследования показали, что на сегодняшний день наиболее эффективным является использование искусственных нейронных сетей.

2. Для повышения качества прогноза была выбрана наиболее эффективная динамическая нейросеть и определена структура ее модели. Проведенные эксперименты показали, что при десяти скрытых нейронах, значение среднеквадратичной ошибки существенно не изменяется, и выбранная сеть дает результаты прогноза с минимальным отклонением.

3. В качестве критерия оценки эффективности нейросетевой модели прогноза и был выбраны количество итераций и точность прогноза. Определено, что наиболее эффективным алгоритмом обучения модели нейросети является комбинированный алгоритм, позволяющий совместить направленность поиска с исследованием всего пространства поиска. Это позволило повысить точность прогноза.

Список использованной литературы

1. Червяков А.Е. Мониторинг и оперативное прогнозирование аэрогазового режима на очистных участках угольных шахт / А.Е. Червяков // Горный информационно-аналитический бюллетень, 2008. – № 1. – С. 30 – 34.
2. Айруни А. Прогнозирование и предотвращение газодинамических явлений в угольных шахтах / А. Айруни. – М.: Наука, 1987. – 310 с.
3. Мамаев В. Предупреждение взрывов пылеметановоздушных смесей / В. Мамаев, Ж. Ибраев, В. Лигай [и др.]. – М.: Недра, 1990. – 159 с.
4. Бондаренко В.И. Основные научные положения прогноза динамики метановыделения при отработке газоносных угольных пластов / В.И. Бондаренко // Науковий вісник НГУ, 2013. – № 5.– С. 24 – 30.
5. Чучуева И.А. Модель прогнозирования временных рядов по выборке максимального подобия: дис. . . . кандидата технических наук: 05.13.18 – математическое моделирование, численные методы и комплексы программ / Чучуева Ирина Александровна. – Москва, 2012. – 153 с.
6. Бодянский Е.В. Искусственные нейронные сети: архитектуры, обучение, применения / Е.В. Бодянский, О.Г. Руденко. – Харьков: Телетех, 2004. – 159 с.
7. Haykin S. Neural networks / S. Haykin. – NY: Pearson Education, 1999. – p. 823.
8. Осовский С. Нейронные сети для обработки информации / С. Осовский; пер. с польского И.Д. Рудинского. – М.: Финансы и статистика. – 2002. – 344 с.
9. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская. – М.: Горячая линия – Телеком, 2006. – 452 с.
10. Скобцов Ю.А. Метаэвристики: [монография] / Ю.А. Скобцов, Е.Е. Федоров. – Донецк: Ноулидж, 2013. – 426 с.

References

1. Chervyakov, A.E. (2008), «Monitoring i operativnoe prognozirovanie aerogazovogo rezhima na ochildnyih uchastkah ugolnyih shaht», *Gornyyi informatsionno-analiticheskiy byulleten*, № 1, pp. 30-34.
2. Ayruni, A. (1987), *Prognozirovanie i predotvraschenie gazodinamicheskikh yavleniy v ugolnyih shahtah* [Monitoring and operational forecasting of air and gas treatment regime on the areas of coal mines], Nauka, Moscow, Russia.
3. Mamaev, V., Ibraev Zh., Ligay V. and others. (1990), *Preduprezhdenie vzryivov pyilemetano-vozdushnyih smesey*. [Preventing explosions of dust-methane-air mixtures], Nedra, Moscow, Russia.
4. Bondarenko, V.I. (2013), «Osnovnyie nauchnyie polozheniya prognoza dinamiki metanovy-ideleniya pri otrabotke gazonosnyih ugolnyih plastov», *Naukoviy visnik NGU*, №5. pp. 24-30.
5. Chuchueva, I.A. (2012), Model of time series prediction based on a sample of maximum similarity, Ph.D. Thesis, Mathematical modeling, numerical methods and complexes of programs, State Higher Educational Establishment «Moscow State Technical University of N.E. Bauman», Moscow, Russia.
6. Bodyanskiy, E.V. and Rudenko O.G. (2004), *Iskusstvennyie neyronnyie seti: arhitekturyi, obuchenie, primeneniya* [Artificial neural networks: architecture, education, application], Telethe, Kharkov, Ukraine.
7. Haykin, S. (1999), *Neural networks*, Pearson Education, New York, USA.
8. Osovskiy, S. (2002), *Neyronnyie seti dlya obrabotki informatsii* [Neural network for processing information], Finansyi i statistika, Moskow, Russia.
9. Rutkovskaya, D. (2006), *Neyronnyie seti, geneticheskie algoritmyi i nechetkie sistemy* [Neural networks, genetic algorithms and fuzzy systems], Goryachaya liniya – Telekom, Moskow, Russia.
10. Skobcov, Y.A. and Fedorov E.E. (2013), *Metaevristiki* [Metaheuristics], Noulidzh, Donetsk, Ukraine.

Поступила в редакцію:
26.04.2015

Рецензент:
д-р техн. наук, проф. Е.А. Башков

Є.Є. Федоров, Ю.Л. Дікова

ДВНЗ «Донецький національний технічний університет»

Розробка способу прогнозу вмісту вибухонебезпечних газів в гірничих виробках

У статті розглянуто та проаналізовано існуючі методи прогнозу вмісту вибухонебезпечних газів. Виходячи з основних переваг і недоліків, розроблено і реалізовано нейромережевий спосіб прогнозу вмісту вибухонебезпечних газів в гірничих виробках. В основу способу закладена нейронна мережа NARX, архітектура якої визначена на основі проведених експериментів. Критерієм вибору архітектури було мінімальне значення MSE. Для оцінки ефективності запропонованого способу були проведені чисельні дослідження, які доводять ефективність обраної мережі та її архітектури.

Ключові слова: прогноз, зміст вибухонебезпечних газів, нейронна мережа, вибір архітектури мережі, середньоквадратичне відхилення.

E.E. Fedorov, Y.L. Dikova

Donetsk National Technical University

Development of the method of prediction of content of explosive gases in mines

Despite the rapid development of computer systems in coal mines emergencies caused by high concentrations of explosive gases continue to occur. Therefore, the development of methods for fore-

casting the content of combustible gases in mines, used to improve the quality of air and gas situation assessment is urgent. To solve the problem of forecasting the article analyzed the most common methods of forecasting - regression and autoregressive methods; methods based on exponential smoothing methods based on Markov chains; methods based on the classification and regression trees; neural network forecasting methods. The main criteria for the choice of the method were: the relationship between the factors examined for the finished model; it does not require any assumptions about the distribution of the factors, a priori information about the factors may be absent; the original data can be highly correlated, be incomplete or noisy; systems can be analyzed with a high degree of nonlinearity; the rapid development of the model; high adaptability; systems can be analyzed with many factors; it does not require an exhaustive search of all possible models; it is possible to analyze systems with heterogeneous factors. On the basis of the comparative characteristics the choice was made in favor of the neural network method. We examined neural networks, which are designed to meet the challenges of the forecast. The main criteria for selecting a particular neural network were such as the presence of feedback delay in the input layer and the accuracy of the forecast. Among the considered networks the most appropriate one was NARX. To determine the selected network architecture we carried out numerical experiments. Architecture selection criterion was the minimum value of MSE. Experiments have shown that with the increase of neurons in the hidden layer MSE value decreases rapidly. According to the results of the study we chose network architecture with the number of neurons at 10. As a tool for neural network training three types of genetic algorithm and back-propagation algorithm were examined. As it was shown by the experimental results, the combined genetic algorithm that uses the combination of the search direction to research all of the search space, is a more effective tool for training the neural network. To evaluate the effectiveness of the proposed method we carried out numerical studies that proved the effectiveness of the selected network, its architecture and learning algorithm.

Keywords: forecast, content of explosive gases, neural network, selection of a network architecture mean square error.



Федоров Евгений Евгеньевич, Украина, окончил Донецкий национальный технический университет, д-р техн. наук, доц., профессор кафедры компьютерных наук. ГВУЗ «Донецкий национальный технический университет» (пл. Шибанкова, 2, г. Красноармейск, 85300, Украина). Основное направление научной деятельности – методы идентификации и верификации диктора; распознавания и синтеза речи; методы анализа и синтеза естественно-языковых объектов.



Дикова Юлия Леонидовна, Украина, окончила ГВУЗ «Донецкий национальный технический университет», аспирант кафедры компьютерных наук. ГВУЗ «Донецкий национальный технический университет» (пл. Шибанкова, 2, г. Красноармейск, 85300, Украина). Основное направление научной деятельности – компьютерные системы диагностики и контроля.