

УДК 004.032.26

Ю.Л. ДИКОВА, асп., ГВУЗ "ДонНТУ", Красноармейск,
Е.Е. ФЕДОРОВ, д-р техн. наук, доцент, ГВУЗ "ДонНТУ",
Красноармейск,
Д.Е. ИВАНОВ, д-р техн. наук, доц., с.н.с. отдела прикладных
проблем современного анализа Института математики НАНУ, Киев

МЕТОД ДИАГНОСТИКИ ШАХТНОГО ОБОРУДОВАНИЯ НА ОСНОВЕ СЕТИ СО СМЕШАННЫМИ ФУНКЦИЯМИ АКТИВАЦИИ

В статье рассматривается метод комплексной диагностики горно-шахтного оборудования (ГШО) на основе нейронной сети со смешанными функциями активации. Критерием эффективности предложенной модели является ее адекватность состоянию объекта. Для численного исследования предложенного метода были использованы данные, полученные с датчиков измерения температуры и вибрации ГШО. Ил.: 3. Табл.: 1. Библиогр.: 10 назв.

Ключевые слова: комплексная диагностика, горно-шахтное оборудование, нейронная сеть, функции активации.

Постановка проблемы. Несмотря на высокий уровень автоматизации производственной безопасности в шахтах и внедрение автоматизированных систем, в шахтах по-прежнему происходят аварии, вызванные износом оборудования. Проблема аварийности горно-шахтного оборудования (ГШО) усугубляется сокращением финансирования и устареванием оборудования, износы которого достигают 50% – 80%. В большинстве случаев возникновение аварии можно было предотвратить, идентифицировав её на начальной стадии и выполнив превентивные действия, направленные на ее недопущение. Одним из подходов, решающих данную задачу, является разработка соответствующих систем автоматизированного диагностирования ГШО, которые используют новейшие технологии и методы обработки информации.

На многих шахтах в эксплуатации находятся системы обеспечения комплексной безопасности [1], которые позволяют индицировать текущие значения физических параметров с помощью различных датчиков: тока, температуры, давления, вибрации радиального или продольного смещения и т.д. [2]. Основными контролируемыми объектами являются главные и местные вентиляторы проветривания, забойные и магистральные конвейеры, проходческие и добычные

комбайны, насосные установки. На основе показаний датчиков, обычно, предоставляется информация о трёх состояниях объекта (нормальная работа, предаварийное состояние, аварийное состояние). Однако поступающая информация обрабатывается и анализируется по каждому датчику в отдельности, что позволяет выявить наличие дефекта только по одному признаку. Такая обработка информации не дает возможности получить комплексную оценку состояния ГШО.

Анализ исследований. Исследования показали, что задача диагностики ГШО сводится к задаче распознавания его состояния, для решения которой чаще всего применяются такие методы, как решающие деревья, статистические методы, искусственные нейронные сети [3 – 5].

Наряду с достоинствами указанных методов, каждый из них обладает рядом недостатков. Так, к недостаткам решающих деревьев относится необходимость знания их структуры и их порогов, с которыми сравниваются значения диагностических признаков.

Статистические методы требуют большого объема обучающей выборки и необходимости установления взаимосвязи между диагностическим признаками. Для них отсутствует автоматизация процесса определения структуры и параметров модели, затруднен анализ систем с высокой степенью нелинейности, с неоднородными диагностическим признаками. Исходные данные не должны сильно коррелировать, быть неполными или зашумленными.

Наиболее распространёнными ИНС являются: многослойный персептрон, сеть с радиально-базисными функциями, вероятностная сеть, сеть Кохонена и другие. Для многослойного персептрона, сети с радиально-базисными функциями и вероятностной сети не автоматизирован процесс определения их структуры. Кроме того, персептрон требует достаточно много вычислительных ресурсов, применение сети с радиально-базисными функциями предполагает экспоненциальный рост количества функций при увеличении размерности входного пространства, а сеть Кохонена часто не обеспечивает необходимый уровень распознавания.

Вероятностные сети в силу большой размерности скрытого слоя обладают большой вычислительной сложностью процедуры прогноза.

В связи с этим возникает необходимость создания ИНС, способной устранить перечисленные недостатки.

В статье предлагается метод диагностики, основанный на ИНС, который сочетает в себе анализ нескольких показателей разной физической природы, что позволит существенно повысить вероятность распознавания неисправности ГШО или отдельных узлов.

Цели и задачи исследования. Цель – разработка метода комплексной диагностики шахтного оборудования с применением нейросетевого подхода. Для достижения цели были поставлены и решены следующие задачи:

- усовершенствование структуры модели диагностики;
- разработка процедуры диагностики на основании модели;
- выбор критерия качества для обучения модели;
- адаптация параметров модели с целью повышения её адекватности.

Результаты разработки и исследований. Диагностика – комплекс средств и методов, направленных на определение технического состояния ГШО. Для определения технического состояния оборудования выполняется чтение информации с датчиков, установленных на находящемся в эксплуатации оборудовании, и проводится анализ данных, на основе которых делается вывод о техническом состоянии оборудования. В настоящей статье рассматриваются только наиболее важные показатели оценки состояния контролируемого объекта – показатели виброскорости и температуры нагрева [2].

В таблице приведены возможные комбинации диапазонов значений показателей виброскорости и температуры с итоговой комплексной оценкой состояния оборудования. Диапазоны значений были установлены согласно условным границам интервалов работы для ГШО класса 2 [6].

Для решения задачи диагностики в статье использована модель нейронной сети, состоящей из двух слоёв:

- входной (нулевой) слой содержит нейроны, которые соответствуют диагностическим признакам;
- первый слой является скрытым. Он содержит нейроны, количество которых соответствует количеству возможных комбинаций диапазонов, приведенных в табл.;
- выходной (второй) слой содержит нейроны, количество которых соответствует возможным состояниям оборудования (табл.).

Предложенная модель не требует эмпирического определения количества скрытых слоев и нейронов в скрытых слоях, поскольку структура ИНС определяется количеством возможных комбинаций диапазонов диагностических признаков. Структура модели ИНС, учитывающая табл., представлена на рис. 1.

Модель ИНС представлена в виде:

$$y_j = \frac{1}{3} \sum_{i=1}^3 w_{3(j-1)+i,j} f_{3(j-1)+i}(x_1, x_2), \quad j \in \overline{1, 3}.$$

Таблица

Соответствие комбинации диапазонов значений диагностических признаков комплексной оценке состояния оборудования

№ п/п	Диапазон значений виброскорости, мм/сек	Диапазон значений температуры, °С	Комплексная оценка состояния оборудования
1	< 4,5	< 70	"эксплуатация без ограничения сроков"
2	< 4,5	70 – 80	"эксплуатация без ограничения сроков"
3	4,5 – 11,2	< 70	"эксплуатация без ограничения сроков"
4	< 4,5	> 80	"эксплуатация с ограниченным сроком"
5	4,5 – 11,2	70 – 80	"эксплуатация с ограниченным сроком"
6	> 11,2	< 70	"эксплуатация с ограниченным сроком"
7	4,5 – 11,2	> 80	"не пригодно для эксплуатации"
8	> 11,2	70 – 80	"не пригодно для эксплуатации"
9	> 11,2	> 80	"не пригодно для эксплуатации"

Функция активации каждого нейрона скрытого слоя [7] представляет собой агрегацию функций активации рассматриваемых диагностических признаков, и представлена в виде

$$f_i(x_1, x_2) = f_i(x_1) f_i(x_2).$$

Каждому диапазону диагностического признака соответствует определенная функция активации. Так, диапазону значений виброскорости "< 4,5" и диапазону значений температуры "< 70" соответствует функция активации

$$f(x) = \left(\frac{1}{1 + \exp(-ax + b)} \right).$$




Рис. 1. Структура модели ИНС

Диапазону значений виброскорости "4,5 – 11,2" и диапазону значений температуры "70 – 80" соответствует функция активации

$$f(x) = \exp\left(-\frac{(x-m)^2}{2\sigma^2}\right).$$

Диапазону значений виброскорости "> 11,2" и диапазону значений температуры "> 80" соответствует функция активации

$$f(x) = \left(\frac{1}{1 + \exp(-cx + d)} \right).$$

Тогда, агрегированные функции активации для скрытых нейронов

будут представлены в виде:

$$f_1(x_1, x_2) = \left(\frac{1}{1 + \exp(-a_{11}x_1 + b_{11})} \right) * \left(\frac{1}{1 + \exp(-a_{21}x_2 + b_{21})} \right),$$

$$f_2(x_1, x_2) = \left(\frac{1}{1 + \exp(-a_{12}x_1 + b_{12})} \right) * \exp\left(-\frac{(x_2 - m_{22})^2}{2\sigma_{22}^2}\right),$$

$$f_3(x_1, x_2) = \exp\left(-\frac{(x_1 - m_{13})^2}{2\sigma_{13}^2}\right) * \left(\frac{1}{1 + \exp(-a_{23}x_2 + b_{23})} \right),$$

$$f_4(x_1, x_2) = \left(\frac{1}{1 + \exp(-a_{14}x_1 + b_{14})} \right) * \left(\frac{1}{1 + \exp(-c_{24}x_2 + d_{24})} \right),$$

$$f_5(x_1, x_2) = \exp\left(-\frac{(x_1 - m_{15})^2}{2\sigma_{15}^2}\right) * \exp\left(-\frac{(x_2 - m_{25})^2}{2\sigma_{25}^2}\right),$$

$$f_6(x_1, x_2) = \left(\frac{1}{1 + \exp(-c_{16}x_1 + d_{16})} \right) * \left(\frac{1}{1 + \exp(-a_{26}x_2 + b_{26})} \right),$$

$$f_7(x_1, x_2) = \exp\left(-\frac{(x_1 - m_{17})^2}{2\sigma_{17}^2}\right) * \left(\frac{1}{1 + \exp(-c_{27}x_2 + d_{27})} \right),$$

$$f_8(x_1, x_2) = \left(\frac{1}{1 + \exp(-c_{18}x_1 + d_{18})} \right) * \exp\left(-\frac{(x_2 - m_{28})^2}{2\sigma_{28}^2}\right),$$

$$f_9(x_1, x_2) = \left(\frac{1}{1 + \exp(-c_{19}x_1 + d_{19})} \right) * \left(\frac{1}{1 + \exp(-c_{29}x_2 + d_{29})} \right),$$

где параметры функций активации $f_j(x_1, x_2)$ ($j = \overline{1, 9}$), полученные эмпирическим путем [8], обозначены следующим образом

$$\begin{aligned} & a_{11}, \dots, a_{26}, b_{11}, \dots, b_{26}, m_{13}, \dots, m_{28}, \\ & \sigma_{13}, \dots, \sigma_{28}, c_{16}, \dots, c_{29}, d_{16}, \dots, d_{29}. \end{aligned} \quad (1)$$

Здесь x_1, x_2 – диагностические признаки.

Выбор критерия качества для обучения модели. В работе для обучения модели выбран критерий адекватности модели на основе СКО, который семантически показывает выбор таких значений параметров (1) и w_{ij} ($i, j = \overline{1, 3}$), при которых разность выхода по модели и желаемого выхода достигает минимума:

$$F = \frac{1}{3P} \sum_{p=1}^P \sum_{j=1}^3 (y_{pj} - d_{pj})^2 \rightarrow \min_{a_{ij}, b_{ij}, c_{ij}, d_{ij}, m_{ij}, \sigma_{ij}, w_{ij}},$$

где P – мощность тестового множества $\{(x_p, d_p) | x_p = (x_{p1}, x_{p2}), d_p = (d_{p1}, d_{p2}, d_{p3})\}$,

y_{pj} – полученный на основе моделирования j -й выход ИНС для p -й тестовой реализации,

d_{pj} – тестовый (измеренный) j -й выход ИНС для p -й тестовой реализации,

x_{pi} – тестовый i -й вход ИНС для p -й тестовой реализации

Адаптация параметров модели. Целью адаптации модели является настройка ее параметров (1) и w_{ij} . Для этого в модели ИНС используется процедура Back Propagation [9].

Численное исследование способа оценки состояния. Для численного исследования в MatLab [10] была создана модель нейронной сети с описанной структурой, проведены эксперименты на тестовых данных. При этом для виброскорости брался диапазон от 0 до 15 [мм/сек], а для температуры – от 65 до 85 °С, что соответствует наиболее типичным режимам работы ГШО. Исследовалась зависимость состояния ГШО от параметров температуры и виброскорости. Результаты моделирования приведены на рис. 2.

Результаты работы модели с данными, полученными на шахте "Новгородовская" ГП "Селидовуголь", приведены на рис. 3. Проведенные эксперименты показали, что вероятность ошибки предлагаемой сети составила 0,07, что на 13% лучше по сравнению с другими нейросетевыми подходами.

Предлагаемые метод и модель могут быть обобщены на задачи диагностирования ГШО разных типов, использующих другие датчики.

Структура модели не накладывает ограничений на количество диагностических признаков и количество их возможных диапазонов значений.




Рис. 2. Результаты работы предложенной модели ИНС с тестовыми данными

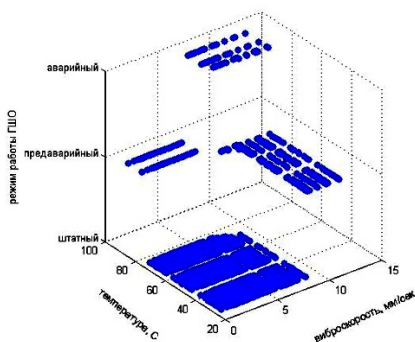


Рис. 3. Результаты моделирования с практическими данными

Выводы. 1. Для повышения эффективности диагностики ГШО усовершенствована модель искусственной нейронной сети, которая в отличие от существующих позволяет анализировать совокупность диагностических признаков разной физической природы, что позволяет проводить комплексную оценку состояния ГШО.

2. Предложенная модель не требует эмпирического определения количества скрытых слоев и нейронов в скрытых слоях. Данные параметры ИНС определяются количеством возможных комбинаций диапазонов диагностических признаков. В рассмотренном в статье случае предложена сеть с одним скрытым слоем с девятью нейронами.

3. Каждому нейрону скрытого слоя соответствует своя функция активации, полученная эмпирическим путем.

4. Проведено численное исследование, которое позволило определить, что предложенный способ диагностики является эффективным, а предложенная модель является адекватной. Вероятность ошибки предложенной ИНС составила 0,07.

5. Рассмотренный в статье метод и модель позволяют проводить диагностику различного шахтного оборудования.

6. Предложенная модель может быть адаптирована для любого количества диагностических признаков ГШО.

Список литературы: 1. Шахтар Галичини [Электронный ресурс]. Режим доступа: <http://www.lvug.com.ua/2013/12/09/sistema-utas-na-shahte-stepovaya/> 2. Петровский завод угольного машиностроения [Электронный ресурс]. Режим доступа: <http://itras.com.ua/> 3. *Высочина О.С.* Сравнительный анализ моделей нейронных структур для решения задачи классификации состояний телекоммуникационной сети / *О.С. Высочина, С.И. Шматков* // Всеукраинский межведомственный научно-технический сборник "Автоматизированные системы управления и приборы автоматки". – Харьков: ХНУРЭ, 2009. – Вып. 146. – С. 70-75. 4. *Воронцов К.В.* Логические алгоритмы классификации. [Электронный ресурс]. Режим доступа: <http://www.machinelearning.ru/wiki/images/9/97/Voron-ML-Logic-slides.pdf> 5. *Радченко С.Г.* Методология регрессионного анализа: Монография / *С.Г. Радченко*. – К.: "Корнийчук", 2011. – С. 376. 6. *Федоров Е.Е.* Методики интеллектуальной диагностики: монография / *Е.Е. Федоров*. – Донец. акад. автомоб. трансп. – Донецк: Ноулдидж, 2010. – 303 с. 7. *Рутковская Д.* Нейронные сети, генетические алгоритмы и нечеткие системы: Пер. с польск. И.Д. Рудинского / *Д. Рутковская*. – М.: Горячая линия – Телеком, 2006. – 452 с. 8. *Дикова Ю.Л.* Разработка нейросетевого способа диагностики шахтного оборудования / *Ю.Л. Дикова, Е.Е. Федоров*. – Харьков: ХНУРЭ, БИОНИКА ИНТЕЛЛЕКТА. – 2015. – № 1 (84). – С. 80-84. 9. *Хайкин С.* Нейронные сети: полный курс / *С. Хайкин*. – М.: Издательский дом "Вильямс", 2006. – 1104 с. 10. *Sivanandam S.N.* Introduction to Neural Networks using Matlab 6.0 / *S.N. Sivanandam, S. Sumathi, S.N. Deepa* – New Delhi: The McGraw-Hill Comp., Inc., 2006. – 660 p.

Bibliography (transliterated): 1. Shahtar Galichini [Jelektronnyj resurs]. Rezhim dostupa: <http://www.lvug.com.ua/2013/12/09/sistema-utas-na-shahte-stepovaya/> 2. Petrovskij zavod ugol'nogo mashinostroeniija [Jelektronnyj resurs]. Rezhim dostupa: <http://itras.com.ua/> 3. *Vysochina O.S.* Sravnitel'nyj analiz modelej nejronnyh struktur dlja reshenija zadachi klassifikacii sostojanij telekommunikacionnoj seti / *O.S. Vysochina, S.I. Shmatkov* // Vseukrainskij mezhdvedomstvennyj nauchno-tehnicheskij sbornik "Avtomatizirovannye sistemy upravlenija i pribory avtomatiki". – Har'kov: HNURJe, 2009. – Vyp. 146. – P. 70-75. 4. *Voroncov K.V.* Logicheskie algoritmy klassifikacii. [Jelektronnyj resurs]. Rezhim dostupa: <http://www.machinelearning.ru/wiki/images/9/97/Voron-ML-Logic-slides.pdf> 5. *Radchenko S.G.* Metodologija regressionnogo analiza: Monografija / *S.G. Radchenko*. – K.: "Kornijchuk", 2011. – P. 376. 6. *Fedorov E. E.* Metodiki intellektual'noj diagnostiki: monografija / *E.E. Fedorov*; Donec. akad. avtomob. transp. – Doneck: Noulidzh, 2010. – 303 p. 7. *Rutkovskaja D.* Nejronnye seti, geneticheskie algoritmy i nechetkie sistemy: Per. s pol'sk. I.D. Rudinskogo / *D. Rutkovskaja*. – M.: Gorjachaja linija – Telekom, 2006. – 452 p. 8. *Dikova Ju.L.* Razrabotka nejrosetevogo sposoba diagnostiki shahtnogo oborudovanija / *Ju.L. Dikova, E.E. Fedrov*. – Har'kov: HNURJe, BIONIKA INTELLEKTA, 2015. – № 1 (84). – P. 80-84. 9. *Hajkin S.* Nejronnye seti: polnyj kurs / *S. Hajkin*. – M.: Izdatel'skij dom "Vil'jams", 2006. – 1104 p. 10. *Sivanandam S.N.* Introduction to Neural

Networks using Matlab 6.0 / S.N. Sivanandam, S. Sumathi, S.N. Deepa. – New Delhi: The McGraw-Hill Comp., Inc., 2006. – 660 p.

*Поступила (received) 15.07.2015
Повторно 05.10.2015*

Статью представил д.т.н., проф. каф. ПМИ, проректор по научной работе ГВУЗ "ДонНТУ" (г. Красноармейск) Башков Е.А.

Dikova Yuliya, postgraduate
State Higher Educational Institution " Donetsk National Technical University"
Sqr. Shibankova, 2, Krasnoarmiysk, Ukraine, 85300
tel./phone: (099) 902-54-13, e-mail: juli.dikova@gmail.com
ORCID ID: 0000-0002-8196-0817

Fedorov Eugene, Dr.Sci.Tech, Professor
State Higher Educational Institution " Donetsk National Technical University"
Sqr. Shibankova, 2, Krasnoarmiysk, Ukraine, 85300
tel./phone: (050) 053-15-20, e-mail: fedorovee75@mail.ru
ORCID ID: 0000-0002-2962-7478

Dmytro Ivanov, Dr. of Technical Science, Associate Professor, Senior scientific researcher
Institute of Mathematics of National Academy of Sciences of Ukraine
Str. Tereschenkivska 3, Kiev-4, Ukraine, 01601
tel./phone: (067)-281-2648; email: dmitry.ivanov.iamm@gmail.com
ORCID ID: 0000-0001-9956-6589