

УДК 514.8:539.3.621

**МЕТОДЫ ПРОГНОЗИРОВАНИЯ НЕИСПРАВНОСТЕЙ
ВАГОННОГО ОБОРУДОВАНИЯ ПАССАЖИРСКИХ
ЖЕЛЕЗНОДОРОЖНЫХ ПОДВИЖНЫХ СОСТАВОВ НА ОСНОВЕ
МНОГОСЛОЙНОЙ НЕЙРОННОЙ СЕТИ С ИСПОЛЬЗОВАНИЕМ
ГЕНЕТИЧЕСКОГО АЛГОРИТМА, А ТАКЖЕ НЕЙРОННЫХ
ЭХО-СЕТЕЙ: СРАВНИТЕЛЬНЫЙ АНАЛИЗ¹**

Иванова Е.И.

Кафедра информационных технологий

Поступила в редакцию 22.03.2014, после переработки 24.04.2014.

В статье отражены основные научные результаты по исследованию методов прогнозирования неисправностей вагонного оборудования подвижных железнодорожных пассажирских составов на основе многослойной нейронной сети с использованием генетического алгоритма, а также на основе нейронных эхо-сетей. Описаны результаты и сравнительный анализ использования этих методов на реальных данных.

Ключевые слова: информационная система, железнодорожный транспорт, диагностика, прогнозирование, принятие решений, мягкие вычисления, генетический алгоритм, нейронная сеть, многослойная нейронная сеть, нейронная эхо-сеть.

Вестник ТвГУ. Серия: Прикладная математика. 2014. № 2. С. 67-79.

Введение

В соответствии с распоряжением Правительства РФ от 17.06.2008 № 877-р «О стратегии развития железнодорожного транспорта в Российской Федерации до 2030 года», а также в связи с актуальностью проблемы прогнозирования неисправностей оборудования на железнодорожном транспорте была разработана модель комплексной информационной системы диагностики и прогнозирования состояния оборудования подвижного состава [2] были разработаны и исследованы различные способы прогнозирования неисправностей вагонного оборудования пассажирских железнодорожных подвижных составов на основе нейронных сетей.

С точки зрения машинного обучения, в данном случае нейронные сети представляют собой метод кластеризации состояния вагонного электрооборудования по наличию или отсутствию тех или иных неисправностей. Возможность обучения нейронных сетей — это главное преимущество над традиционными алгоритмами кластеризации — иерархическими, статистическими и т.д. Процесс обучения нейронной сети заключается в процедуре настройки весов и порогов с целью

¹Работа выполнена при финансовой поддержке РФФИ (проект №13-07-13160_офи_м_ржд).

уменьшения разности между целевыми векторами и векторами, получаемыми на выходе.

В ходе исследования моделей прогнозирования неисправностей вагонного электрооборудования были изучены следующие методы прогнозирования на основе нейронных сетей:

- обучение с учителем многослойной нейронной сети (МНС) с использованием генетического алгоритма [1,3];
- обучение с учителем нейронной эхо-сети (НЭС) [4].

В статье представлено краткое описание, а также сравнительный анализ данных методов.

1. Данные с электрооборудования вагонов

В качестве анализируемых данных взята база данных срезов значений параметров КУЭВ [2]. База данных содержит имена сигналов вагонного оборудования и их значения в текущий момент времени.

Имена параметров КУЭВ обозначаются N_1, \dots, N_p . Моменты времени обозначаются t_1, \dots, t_m . В момент времени t_i переменная с именем N_j будет иметь значение V_{ij} при $i \in \{1, \dots, m\}$, $j \in \{1, \dots, p\}$.

Период наполнения базы данных срезами – 5 секунд.

2. Прогнозирование на основе МНС с использованием генетического алгоритма

Данный метод заключается в решении поставленной задачи, основываясь на использовании МНС и генетического алгоритма [3].

Перед запуском алгоритма вводятся настройки работы алгоритма: количество хромосом в популяции, количество итераций цикла алгоритма, количество особей, для которых будут применены генетические операторы, количество операций скрещивания и количество операций мутации на каждой итерации алгоритма, а также вероятности скрещивания и мутации, соответственно.

При запуске алгоритма происходит формирование популяции хромосом с помощью операций мутаций и скрещивания, а затем на этапе селекции производится расчет качества каждой хромосомы и выбор хромосом, которые будут участвовать в создании потомков для следующего поколения. В данном случае расчетом качества является результат работы МНС на данных, преобразованных с учетом значений полученных хромосом.

Архитектура МНС представляет собой нейронную сеть прямого распространения с тремя слоями нейронов – входным, скрытым и выходным. МНС работает с векторами, сформированными из блоков срезов следующим образом:

$$[V_{11}, \dots, V_{1p}, \dots, V_{k1}, \dots, V_{kp}]^T.$$

Каждая из хромосом определяет значения, которые будут поданы на вход МНС. После обучения на данных из обучающего множества проводится проверка качества прогнозирования с помощью критерия качества на данных из контрольного множества. При этом отбор значений для проверки осуществляется аналогичным образом с учетом хромосомы.

Критерий качества характеризует качество применяемого метода по тем данным, которые не использовались в процессе обучения МНС. В разработанном алгоритме в качестве внешнего критерия использовался следующий критерий:

$$E(o_i) = \frac{1}{m} \sum_{k=1}^m [-y_k \log(x_k) - (1-y_k) \log(1-x_k)],$$

где m – количество векторов в контрольном наборе, y_k – ожидаемое значение для k -го вектора в контрольном наборе, x_k – значение, выданное МНС для k -го вектора в контрольном наборе.

Функция пригодности хромосомы имеет вид

$$J(o_i) = 1 - E(o_i) = 1 - \frac{1}{m} \sum_{k=1}^m [-y_k \log(x_k) - (1-y_k) \log(1-x_k)].$$

Результат алгоритма после выполнения определенного количества итераций – это хромосома наивысшего качества. Затем на основе данной хромосомы строится и обучается на реальных данных результирующая МНС.

3. Прогнозирование на основе НЭС

Данный метод заключается в решении поставленной задачи, основываясь на использовании разновидности рекурсивных нейронных сетей, называемой НЭС [4].

Архитектура НЭС, в соответствии с Рис. 1, включает три слоя: входной слой, скрытый слой, охваченный обратными связями и называемый также «динамическим резервуаром», и выходной слой, считывающий информацию из скрытого слоя.

Здесь $u(n) \in R^{N_u}$ – входной сигнал, $y^{target}(n) \in R^{N_y}$ – выходной целевой сигнал, $n = 1, \dots, T$ – дискретное время, и T – число элементов в обучающем множестве, $y(n) \in R^{N_y}$ – получаемый сигнал, $x(n) \in R^{N_x}$ – вектор активаций нейронов резервуара, $W^{in} \in R^{N_x \times (1+N_u)}$ и $W \in R^{N_x \times N_x}$, $W^{out} \in R^{N_y \times (1+N_u+N_x)}$ – матрицы входных весов, резервуара и выходных весов, соответственно.

В качестве меры меры ошибки используется среднеквадратичная ошибка:

$$E(y, y_{target}) = \frac{1}{T} \sum_{n=1}^T (y(n) - y_{target})^2.$$

4. Сравнение результатов работы

Для анализа данных использовались заранее подготовленные блоки срезов значений параметров КУЭВ. С учетом выбранных прогнозного горизонта и периода прогноза каждый блок состоит из 360 срезов по 28 параметрам.

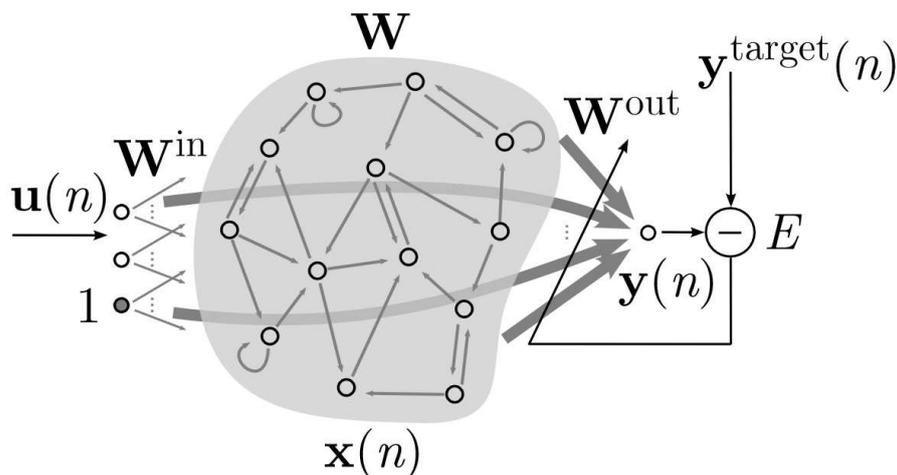


Рис. 1: Архитектура НЭС

В качестве «целевых неисправностей» выбраны неисправность устройства HEATEQ с кодом 17721 (далее – HEATEQ_17721) и неисправность устройства COND с кодом 0002 (далее – COND_0002). Построенные нейронные сети были обучены для прогнозирования возникновения данных неисправностей.

В процессе работы алгоритма, основанного на использовании МНС совместно с генетическим алгоритмом, был построен график зависимости значения критерия $J(o_i)$ от количества отобранных входов МНС (Рис. 2).

Изначально предполагалась работа МНС на 10080 нейронах во входном слое. На графике видно, что наименьшие показатели критерия $J(o_i)$ достигаются для данной неисправности при количестве входов от 4830 до 4900, это значит, что можно не учитывать половину входных данных при обучении МНС.

После обучения МНС и подачи на вход контрольных данных был получен критерий $J(o_i) = 0.59$. Результаты работы интерпретировались следующим образом: возникновение неисправности, если результат ≥ 0.4 , отсутствие неисправности – в противном случае.

При работе алгоритма, основанного на использовании НЭС, была построена НЭС с уровнем утечки $\alpha = 1$.

При проверке на вход НЭС подавались срезы из блоков контрольной выборки, а затем вычислялось значение выходного вектора. Затем значения, полученные на выходе, сокращались и обрабатывались с помощью пороговой функции.

Вычисленные выходные сигналы $y(n)$ для неисправностей HEATEQ_17721 и COND_0002 представлены на Рис. 3 и 4 соответственно.

Для неисправностей HEATEQ_17721 и COND_0004 были получены средне-квадратичные ошибки, равные 0.238 и 0.312 соответственно.

Основные характеристики алгоритмов приведены в Таблице 1.

Сравнивая результаты работы МНС и НЭС, можно сделать следующие выводы о более высоком качестве прогноза при использовании НЭС. При использовании МНС правильный прогноз был построен примерно в 75% случаев, из которых при-

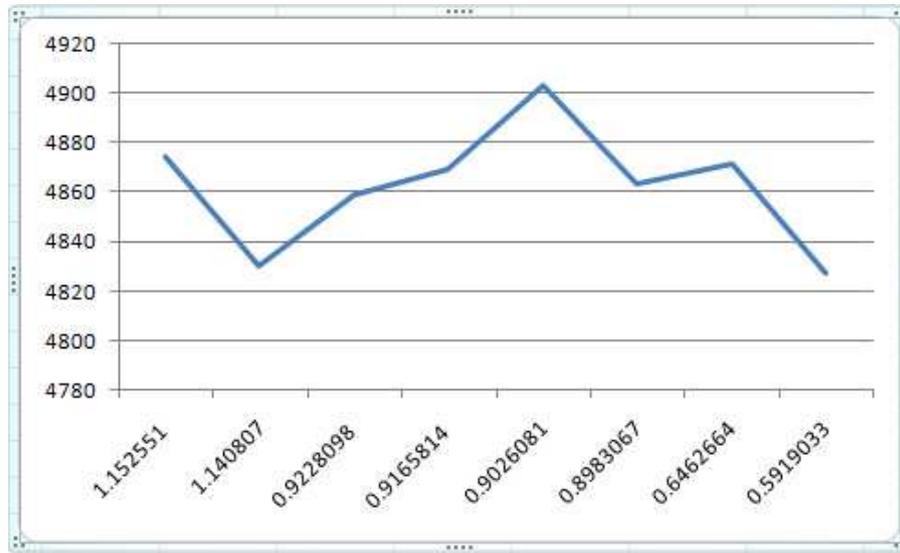


Рис. 2: График зависимости значения критерия $J(o_i)$ от количества отобранных входов для МНС

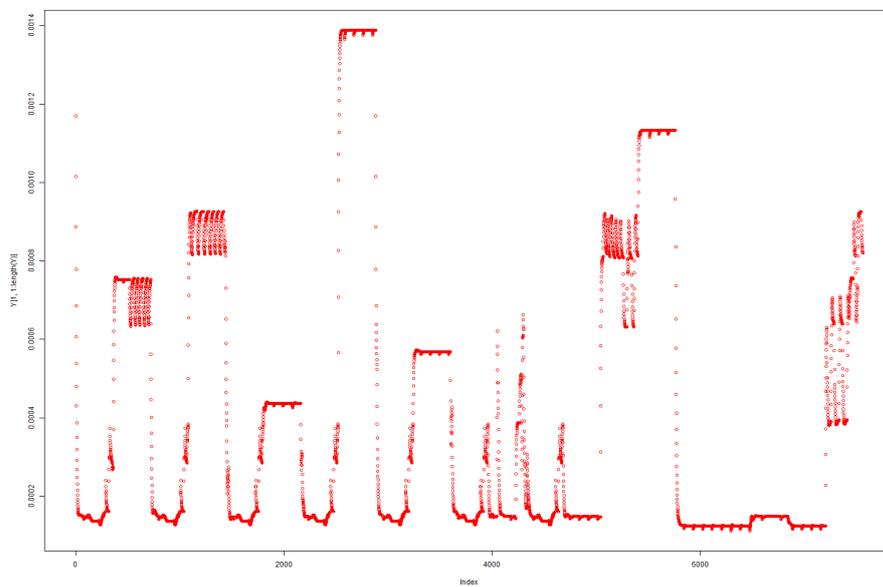


Рис. 3: Вычисленный выходной сигнал $y(n)$ для неисправности HEATEQ_17721

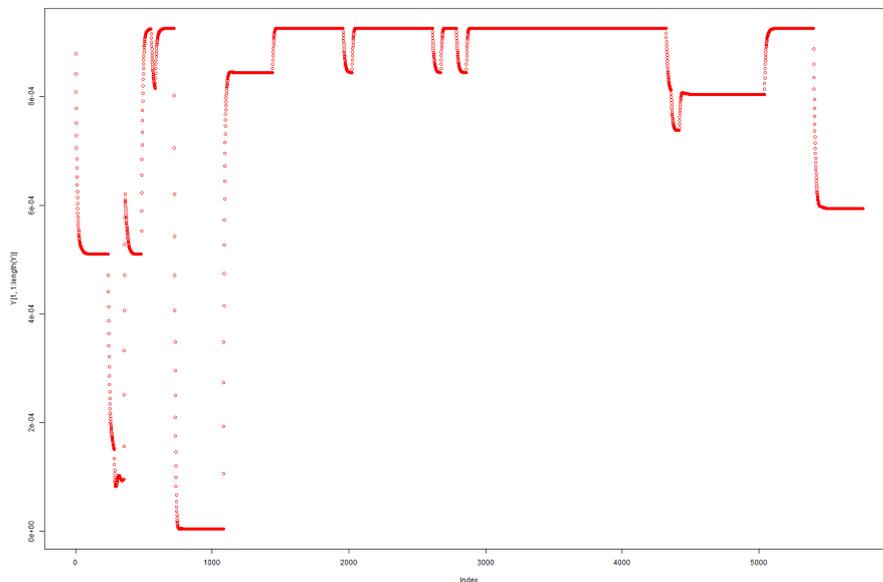


Рис. 4: Вычисленный выходной сигнал $y(n)$ для неисправности COND_0002

мерно 65% в случае возникновения неисправности и примерно 83% в случае отсутствия неисправности. В случае НЭС правильный прогноз был построен примерно с той же точностью примерно 75%, из которых примерно 78% в случае возникновения неисправности и примерно 70% в случае отсутствия неисправности. Основная цель исследований поставленной задачи – прогнозирование возникновения неисправности, так как в контексте рассматриваемой проблемы важно предсказать именно выход из строя электрооборудования. Поэтому, учитывая что точность прогнозирования возникновения неисправности НЭС выше, чем при использовании МНС, можно сказать, что в рамках данной задачи НЭС более пригодны для ее решения.

Для оценки результатов работы алгоритмов использовался метод ROC-кривой, представляющей собой характеристику качества бинарного классификатора, а также зависимость доли верных положительных классификаций от доли ложных положительных классификаций при варьировании порога решающего правила [7].

На основании результатов прогнозирования неисправностей COND_0004 и HEATEQ_17721 с помощью МНС и НЭС были построены ROC-кривые, представленные на Рис. 5-8 соответственно.

Площадь под ROC-кривой AUC (Area Under Curve) является агрегированной характеристикой качества классификации, не зависящей от соотношения цен ошибок. Чем больше значение AUC, тем «лучше» модель классификации. Показатель AUC в данном случае используется для сравнительного анализа описанных моделей прогнозирования, значения данного показателя приведены в Таблице 2.

В соответствии с представленной в Таблице 3 экспертной шкалой для значений AUC можно судить о качестве используемых моделей.

Таблица 1: Основные характеристики алгоритма, основанного на обучении МНС, и алгоритма, основанного на обучении НЭС

	Алгоритм, основанный на обучении МНС	Алгоритм, основанный на обучении НЭС
Подготовка данных к обучению	Сокращение количества входов	-
Количество слоев	4	3
Количество входных нейронов	Около 4900	Около 200
Количество нейронов в скрытых слоях	30, 5	3000
Количество нейронов в выходном слое	1	1
Критерий ошибки	$E(o_i) = \frac{1}{m} \sum_{k=1}^m [-y_k \log(x_k) - (1-y_k) \log(1-x_k)],$ <p>где m – количество векторов в контрольном наборе, y_k – ожидаемое значение для k-го вектора в контрольном наборе, x_k – значение, выданное МНС для k-го вектора в контрольном наборе.</p>	$E(y, y_{\text{target}}) = \frac{1}{T} \sum_{n=1}^T (y(n) - y_{\text{target}})^2,$ <p>где $y(n) \in R^{N_y}$ – получаемый сигнал, $y^{\text{target}}(n) \in R^{N_y}$ – выходной целевой сигнал</p>
Процент правильного прогноза в случае возникновения неисправности	65%	78%
Процент правильного прогноза в случае отсутствия неисправности	83%	70%

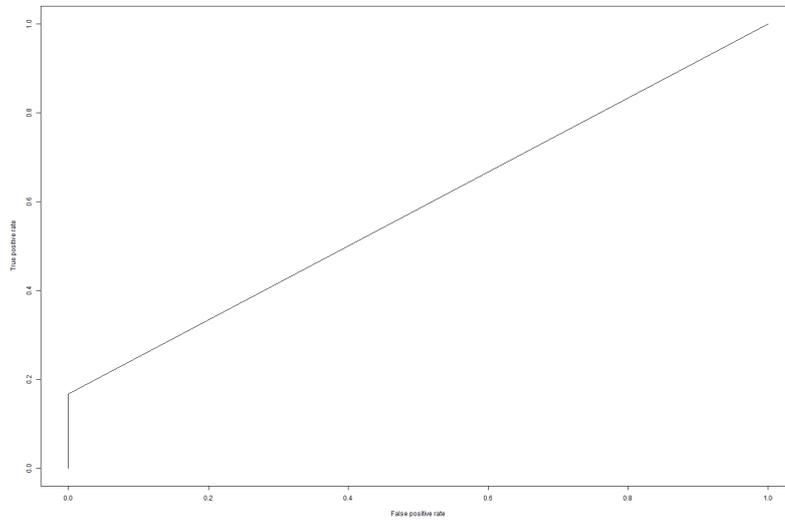


Рис. 5: ROC-кривая, построенная на основании результатов прогнозирования неисправности COND_0002 с помощью МНС

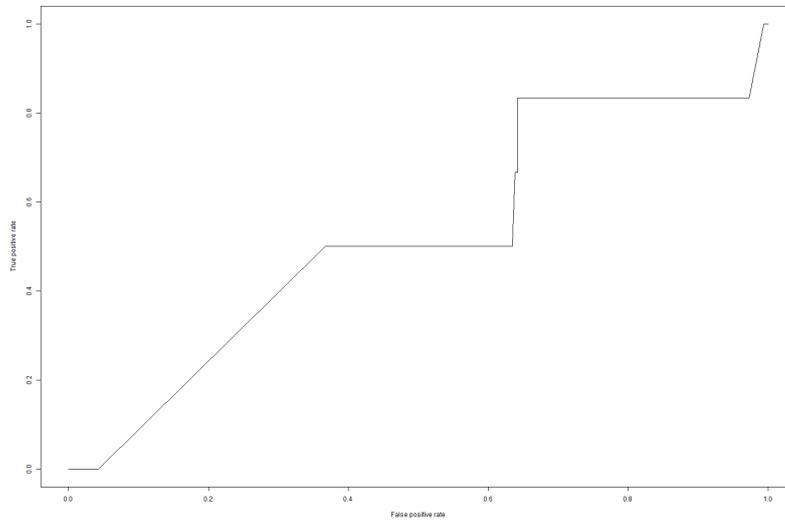


Рис. 6: ROC-кривая, построенная на основании результатов прогнозирования неисправности COND_0002 с помощью НЭС

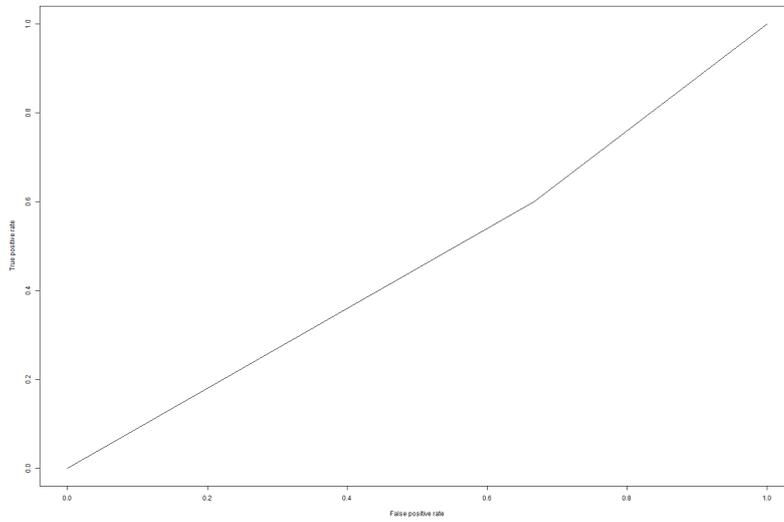


Рис. 7: ROC-кривая, построенная на основании результатов прогнозирования неисправности HEATEQ_17221 с помощью МНС

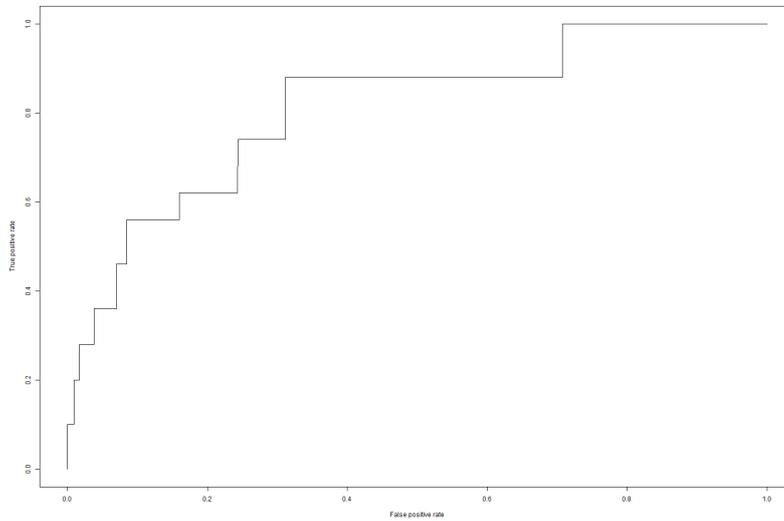


Рис. 8: ROC-кривая, построенная на основании результатов прогнозирования неисправности HEATEQ_17221 с помощью НЭС

Таблица 2: Значения показателей AUC для моделей прогнозирования неисправностей на основе МНС и НЭС

	Прогнозирование неисправности COND_0002	Прогнозирование неисправности HEATEQ_17221
Значение показателя AUC для модели прогнозирования, основанной на МНС	0.580103	0.460028
Значение показателя AUC для модели прогнозирования, основанной на НЭС	0.560514	0.811942

Таблица 3

Интервал AUC	Качество модели
0.9-1.0	Отличное
0.8-0.9	Очень хорошее
0.7-0.8	Хорошее
0.6-0.7	Среднее
0.5-0.6	Неудовлетворительное

Очевидно, что показатели AUC результатов прогнозирования неисправности COND_0002 в обоих случаях неудовлетворительные, однако показатель AUC результатов прогнозирования неисправности HEATEQ_17221 в случае использования НЭС дает в несколько раз лучшие показатели качества построенного прогноза по сравнению с использованием МНС.

Также следует отметить, что НЭС сочетает в себе большой объем динамической памяти (резервуар), а также высоко адаптируемые вычислительные возможности [5]. Основная особенность НЭС – это настраиваемые веса выходного слоя при константных весах скрытого слоя. Веса скрытого слоя задаются один раз при инициализации сети. При подаче на вход НЭС сигнал фиксируется во входном слое, а затем производится стабилизация выходных сигналов после некоторого количества итераций в скрытом слое сети. Стабилизация представляет собой ослабленные по амплитуде образы предыдущих состояний сети.

Еще одно преимущество НЭС – это более высокая скорость работы по сравнению с МНС, которая достигается за счет отсутствия необходимости создания большого количества нейронов во входном слое. Количество нейронов входного слоя равно количеству анализируемых параметров КУЭВ, в то время как при использовании МНС приходится иметь дело с векторами, построенными из некоторого множества срезов, то есть количество входных нейронов больше в несколько сотен раз даже после использования генетического алгоритма.

Заключение

В статье описаны две нейросетевые модели прогнозирования: на основе использования МНС совместно с генетическим алгоритмом, а также на основе использования НЭС. Также рассмотрена работа моделей на реальных данных и произведено сравнение результатов.

В плане дальнейших исследований предполагается распространить полученные методы на решение задачи прогнозирования по нескольким устройствам. Также планируется исследование влияния использования генетического алгоритма при обучении НЭС. Предполагается, что генетический алгоритм позволит повысить скорость работы НЭС. Планируется дальнейшее исследование алгоритмов резервуарного вычисления, в частности НЭС, а также машин неустойчивых состояний (Liquid State Machines)[6].

Также планируется исследование методов прогнозирования, основанных на моделях временных рядов.

Список литературы

- [1] Дубровин В.И., Субботин С.А. Оценка значимости признаков с фиксацией значений // Нейронные сети и модели в прикладных задачах науки и техники: Труды международной конференции КЛИН-2002. Ульяновск, 2002. Т. 3. С. 101–102.
- [2] Иванова Е.И., Гордеев Р.Н., Михайлов В.В., Северов А.В., Язенин А.В. Модель централизованной интеллектуальной информационной системы для решения задач диагностики и прогнозирования неисправностей вагонного оборудования и управления им на железнодорожном транспорте // Нечеткие системы и мягкие вычисления. 2012. Т. 7, № 2. С. 51–72.
- [3] Иванова Е.И., Сорокин С.В. Оптимизация базы данных и построение модели прогнозирования неисправностей вагонного оборудования на основе нейросетевых технологий и методов эволюционного программирования для информационной системы управления железнодорожным транспортом // Нечеткие системы и мягкие вычисления. 2012. Т. 7, № 2. С. 89–98.
- [4] Иванова Е.И., Сорокин С.В. Использование искусственных нейронных эхосетей в системе прогнозирования неисправностей вагонного электрооборудования на железнодорожном транспорте // Нечеткие системы и мягкие вычисления. 2013. Т. 8, № 1. С. 45–57.
- [5] Mantas Lukosevicius. A Practical Guide to Applying Echo State Networks [Electronic resource]. URL: www.organic.elis.ugent.be/sites/organic.elis.ugent.be/files/PracticalESN.pdf
- [6] Liquid State Machine [Электронный ресурс] // Wikipedia. URL: http://www.en.wikipedia.org/wiki/Liquid_state_machine
- [7] MachineLearning, ROC-кривая [Электронный ресурс]. URL: <http://www.machinelearning.ru/wiki/index.php?title=ROC-%D0%BA%D1%80%D0%B8%D0%B2%D0%B0%D1%8F>

Библиографическая ссылка

Иванова Е.И. Методы прогнозирования неисправностей вагонного оборудования пассажирских железнодорожных подвижных составов на основе многослойной нейронной сети с использованием генетического алгоритма, а также нейронных эхо-сетей: сравнительный анализ // Вестник ТвГУ. Серия: Прикладная математика. 2014. № 2. С. 67–79.

Сведения об авторах**1. Иванова Екатерина Игоревна**

аспирант кафедры информационных технологий Тверского государственного университета.

Россия, 170100, г. Тверь, ул. Желябова, д. 33, ТвГУ.

**METHODS FOR PREDICTING WAGON EQUIPMENT
MALFUNCTIONS BASED ON MULTI-LAYER NEURAL NETWORK
WITH GENETIC ALGORITHM AND NEURAL ECHO-NETWORK:
A COMPARATIVE ANALYSIS**

Ivanova Ekaterina Igorevna

Postgraduate student of Information Technology chair, Tver State University
Russia, 170100, Tver, 33 Zhelyabova str., TSU.

Received 22.03.2014, revised 24.04.2014.

In the article the main scientific results of a rolling stock carriage equipment faults of rail transport forecast research based on multilayer neural network with genetic algorithm and on echo state networks are presented. The results and comparative analysis of using this methods on real data are described.

Keywords: information system, rail transport, diagnostics, forecast, decision making, soft computing, genetic algorithm, neural network, multilayer neural network, echo state network.

Bibliographic citation

Ivanova E.I. Methods for predicting wagon equipment malfunctions based on multi-layer neural network with genetic algorithm and neural echo-network: a comparative analysis. *Vestnik TvGU. Seriya: Prikladnaya matematika* [Herald of Tver State University. Series: Applied Mathematics], 2014, no. 2, pp. 67–79. (in Russian)