

# Оценка виброакустики буксовых узлов



Игорь МАРТЫНОВ  
Igor E. MARTYNOV

Василий ПАВЛЮК  
Vassily G. RAVLUK



Сергей МИХАЛКИВ  
Sergey V. MINALKIV

*Мартынов Игорь Эрнстович – доктор технических наук, профессор, заведующий кафедрой вагонов Украинской государственной академии железнодорожного транспорта (УкрГАЗТ). Павлюк Василий Григорьевич – старший преподаватель УкрГАЗТ. Михалкив Сергей Васильевич – кандидат технических наук, доцент УкрГАЗТ, Харьков, Украина.*

**В статье представлены возможности использования аппарата вероятностных нейронных сетей для классификации технического состояния элементов подшипников качения подвижного состава путем анализа виброакустической информации, полученной с помощью современных диагностических комплексов. Показаны особенности функционирования и конструкции искусственной нейронной сети, позволяющей иметь результат распознавания на уровне до 99,6%.**

*Ключевые слова:* железная дорога, подвижной состав, буксовые узлы, подшипник качения, искусственные нейронные сети, математический аппарат, вибродиагностика, информация, классификация, системы автоматизированного диагностирования, образ, состояние.

Одной из главных составляющих активной части основных производственных фондов железнодорожного транспорта является подвижной состав. От уровня его технического совершенства и состояния, условий эксплуатации, системы ремонта и обслуживания зависят результаты перевозочной деятельности, экономики отрасли. Анализ возрастных характеристик эксплуатационного парка указывает на его критическое положение. В ближайшей перспективе с неизбежностью в числе первоочередных задач железных дорог остается поэтому обновление локомотивной и вагонной базы, что может осуществляться за счет как приобретения новой техники, так и модернизации существующей, а также предупреждающей риски диагностики узлов подвижного состава [1].

Совершенствование технического диагностирования буксовых узлов подвижного состава может рассматриваться при этом как часть общей проблемы – распознавания образов. В основе теории распознавания образов лежит анализ признаков определенного объекта, который разрешает определить одно или большее количество наиболее важных, но недоступных для

наблюдения характеристик. При решении такой задачи приходится идентифицировать значащие характеристики объектов на основании косвенных данных и признаков текущего образа — состояния, которое отвечает этим признакам [2].

Традиционный и самый распространенный подход к решению задач параметрического диагностирования заключается в том, что выбирают некоторую совокупность параметров, проводят их измерение, полученные значения сравнивают со значениями границ области трудоспособности. При выполнении условий принадлежности каждого из параметров к определенным классам состояния следует вынести решение о степени трудоспособности узла, который диагностируется.

Во время решения диагностических задач возникают значительные трудности в определении дефектов, поскольку последние, во-первых, могут маскироваться под нормальное состояние; во-вторых, одинаковые дефекты способны проявляться по-разному, а разные по своей значимости, наоборот, представлять одинаковые признаки. Все это усложняет в первую очередь автоматизацию постановки достоверного диагноза. А отсюда, собственно, и отношение к ситуации: степень вероятности ошибочной регистрации или пропуска дефекта в системах, к которым относятся буксовые узлы, не удовлетворяет современным требованиям [2, 3].

### **ВЫБОР АППАРАТА ДЛЯ КЛАССИФИКАЦИИ СОСТОЯНИЯ**

Тенденция общих усилий в реализации систем диагностики — формализация, упрощение и автоматизация процесса постановки диагноза. Что касается диагностирования подшипников качения, то оно связано со сложностью определения сроков полного разрушения их элементов. Наиболее же простым и информативным параметром для комплексной оценки технического состояния подшипника качения является вибрация. Существует много разных методов, зависящих от степени сложности обработки результатов, которым присуща определенная случайность [4–6]. Но надежностью среди них выделяются прежде всего искусственные нейрон-

ные сети (ИНС), которые относятся к статистическим математическим методам, позволяющим ставить диагноз при значительных случайных составляющих сигнала. То есть для оценки результатов диагностирования буксового узла с подшипниками качения целесообразно строить экспертную систему на основе математического аппарата ИНС [3].

В наше время в вибродиагностике сформированы таблицы «характерных частот», на которых проявляются известные дефекты. Эти таблицы могут быть использованы как базовые при создании системы автоматизированного диагностирования (САД). Однако реализация и эффективность их применения могут сильно отличаться в разных системах.

Построение ИНС следует осуществлять таким образом, чтобы на вход сети подавались нормированные значения амплитуд виброскорости и виброускорения на соответствующих частотах. При этом стоит придерживаться идеи использования одной архитектуры сети и разных ее характеристик для получения диагнозов состояния подшипников качения. Сеть отличается присущими ей коэффициентами весов. Путем их отбора и систематизации возможно составление списка характеристик сети относительно тех или иных типоразмеров подшипников.

Обучение ИНС — процесс получения весов под определенные типы подшипника. Для этих процедур предлагается использовать математическую модель, а именно вибрационный спектр некоторого виртуального подшипника (т. е. последовательность частот и амплитуд вибраций, отвечающих данным частотам), изменения характеристик которого полностью контролируются. При обучении задается пара: вибрационный спектр и диагноз. Диагноз отображает техническое состояние, которому соответствует спектр. Таким способом происходит «обучение с учителем» [2, 6].

Итогом создания САД подшипников должна быть единая архитектура ИНС. К ней прибавляется список характеристик (весов) относительно типоразмеров подшипников. В процессе эксплуатации не исключено дополнительное обучение сети диагностическими данными, которые накапливаются.



Для классификации результатов диагностирования технического состояния подшипников качения рассматривают бездефектный подшипник и подшипник, который имеет дефект на внешнем кольце. Одним из вариантов решения такой задачи является применение вероятностной ИНС типа PNN (Probabilistic Neural Network), построенной определенным образом. В процессе ее моделирования определяется необходимое количество элементов сети, а также весовые коэффициенты и сдвиг сети [3, 6].

### БАЙЕСОВСКИЙ ПОДХОД

Сети PNN предназначены для решения задач байесовской классификации (распознавания образов) [6–10], в основе которой лежит знаменитая формула Байеса

$$P(x|y) = \frac{P(x|y)P(x)}{P(y)}. \quad (1)$$

Смысл этого выражения состоит в том, что для события  $x$  с известной вероятностью  $P(x)$  условная вероятность  $P(x|y)$  может быть вычислена с помощью так называемой *апостериорной* вероятности  $P(y|x)$  и вероятностей событий  $P(x)$  и  $P(y)$ . С позиции задачи классификации здесь  $y$  интерпретируется как возможный класс, в который может попасть классифицируемый образ, а  $x$  рассматривается как собственно входной вектор-образ.

Идея байесовской классификации предполагает, что для любого входного образа можно принять решение за счет выбора наиболее вероятного класса из тех, к которым мог бы принадлежать образ. Это решение, однако, требует оценки функции плотности вероятностей каждого класса, причем делается она на основе анализа данных из обучающей выборки, которая, в свою очередь, должна быть задана заранее. Подобное обстоятельство ограничивает процесс обучения вероятностных сетей только пакетным режимом.

Формальным признаком классификации является то, что класс с наиболее плотным распределением в области нового предъявленного образа  $x(k)$  будет иметь

преимущество по сравнению с другими классами. Точно так же получит преимущество и класс с высокой априорной вероятностью или высокой ценой ошибки классификации [2, 7]. Допустим, для двух возможных классов  $A$  и  $B$  в соответствии с байесовским правилом выбирается класс  $A$ , если [9]

$$P_A C_A P_A(x) > P_B C_B P_B(x), \quad (2)$$

где  $P$  – априорная вероятность;

$C$  – цена ошибки классификации;

$p(x)$  – функция плотности вероятностей.

Оценки стоимости ошибок классификации  $C_A$  и  $C_B$  определяются конкретной задачей [7, 9], в связи с чем чаще всего они выбираются одинаковыми для всех классов. Априорные вероятности  $P_A$  и  $P_B$ , тоже в общем случае неизвестные, обычно заменяются частотой появления образов в обучающей выборке, а вот с оценкой плотностей  $p_A(x)$  и  $p_B(x)$  возникают свои проблемы.

Для восстановления этих функций наибольшее распространение получили оценки Парзена [8], использующие весовые функции (потенциальные функции [6], ядра [11]), имеющие центр в точках, соответствующих образам с известной классификацией из обучающей выборки.

И хотя байесовские методы классификации существуют достаточно давно, их параллельная нейросетевая реализация позволила обеспечить более высокое быстродействие процессам обработки информации, связанным с распознаванием образов, диагностикой и т. п.

### СТРУКТУРА ВЕРОЯТНОСТНОЙ НЕЙРОННОЙ СЕТИ

На рис. 1 приведена схема вероятностной нейронной сети PNN, предназначенной для разбиения предъявляемых  $n$ -мерных векторов-образов на два класса  $A$  и  $B$ .

Такая сеть состоит из *входного слоя*, первого *скрытого*, именуемого *слоем образов*, второго *скрытого*, называемого *слоем суммирования*, и *выходного слоя*, образованного в данном случае одним нейроном-компаратором.

Исходной информацией для синтеза сети служит обучающая выборка образов, образованная «пакетом»  $n$ -мерных векторов  $x(1), x(2), \dots, x(N)$  с известной классификацией, причем место конкретного образа в пакете значения не имеет. Предполагается также, что  $N_A$  векторов относятся к классу  $A$ ,  $N_B$  – к классу  $B$ , то есть  $N_A + N_B = N$ . (3)

Количество нейронов в слое образов равно  $N$  (по одному нейрону на каждый обучающий образ), а их синаптические веса определяются значениями компонентов этих образов так, что  $w_{ji} = x_i(j)$ ,  $i = 1, 2, \dots, n$ ;  $j = 1, 2, \dots, N$ , (4)

или в векторной форме  $w_j = x_j(j)$ ,  $(x_1(j), x_2(j), \dots, x_n(j))^T$ . (5)

Очевидно, что обучение в этом случае сводится к одноразовой установке весов, и это делает его чрезвычайно простым.

Каждый из нейронов слоя образов вычисляет взвешенную сумму входных сигналов и преобразует ее с помощью нелинейной активационной функции так, что на выходе нейронов первого скрытого слоя появляется сигнал

$$o_j^{[1]}(k) = \Phi(\|x(k) - w_j\|, \sigma), \quad (6)$$

чаще всего в форме

$$o_j^{[1]}(k) = \exp\left(-\frac{\|x(k) - w_j\|^2}{\sigma^2}\right), \quad (7)$$

где параметр  $\sigma$  задает ширину,

$$j = 1(A), 2(A), \dots,$$

$$N_A(A), (N_A + 1)(B), \dots, N_B$$

Заметим, кроме того, что для упрощения численной реализации входные векторы рекомендуется предварительно нормировать, а вместо колоколообразной функции активации использовать более простое преобразование [12]

$$o_j^{[1]}(k) = \exp\left(2 \frac{w_j^T x(k) - 1}{\sigma^2}\right). \quad (8)$$

Слой суммирования создается двумя элементарными сумматорами (в общем случае по одному на каждый класс), которые суммируют выходы нейронов слоя образов

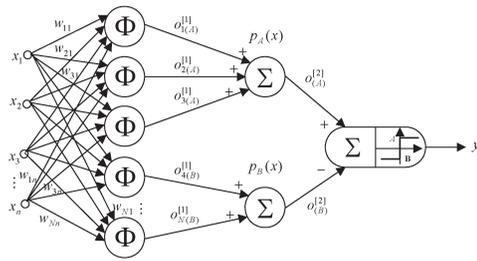


Рис. 1. Архитектура ИНС типа PNN.

$$\begin{cases} o_A^2(k) = \sum_{j=1(A)}^{N_{A(A)}} o_j^{[1]}(k), \\ o_B^2(k) = \sum_{j=(N_A+1)(B)}^{N_{B(B)}} o_j^{[1]}(k). \end{cases} \quad (9)$$

Суммы (9) и являются парзеновскими оценками неизвестных плотностей вероятностей  $p_A(x)$  и  $p_B(x)$ .

В выходном нейроне сети PNN, реализующем, по сути, элементарную операцию сравнения вычисленных значений  $p_A(x(k))$  и  $p_B(x(k))$ , определяется принадлежность предъявляемого образа  $x(k)$  классу  $A$  или  $B$ .

После того как сеть построена, остается найти значение параметра ширины  $\sigma$ , которое для нормированных входов выбирается произвольно в интервале от нуля до единицы [12], а затем можно приступить к собственно решению задачи классификации, предъявляя ИНС образы  $x(k)$ ,  $k > N$  с неизвестной принадлежностью.

Главным достоинством вероятностных нейросетей является простота проектирования и обучения.

В таблице 1 приведены результаты распознавания технического состояния подшипников качения ИНС типа PNN с разными длинами трещин внешних колец.

Согласно таблице, для идентификации трещины внешнего кольца наилучшим образом подходит ИНС типа PNN 16:20–22–8:1 со значением 99,6%. В то же время ИНС типа PNN 14:16–20–6:1 демонстрирует наиболее плохие результаты – 97,06%.

На рис. 2 даны результаты идентификации технического состояния ИНС типа PNN.





## Идентификация повреждений ИНС типа PNN

Длина трещины, мм	21,9	28,2	31,3	34,8	37,9
Выбранная частота, Гц	76,6				
Процент правильно идентифицированных длин трещин внешнего кольца					
PNN 14:16-20-6:1	99,0	96,4	94,2	97,6	98,1
PNN 14:18-20-6:1	98,8	99,7	100,0	95,5	96,6
PNN 16:20-22-8:1	100,0	100,0	100,0	98,0	100,0

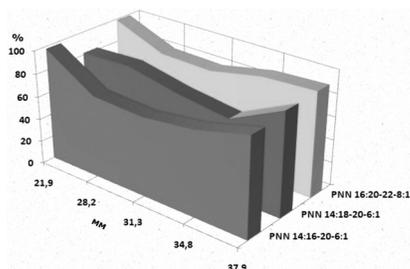


Рис. 2. Результаты идентификации технического состояния внешнего кольца подшипников качения ИНС типа PNN.

## ВЫВОДЫ

Исследованиями установлено, что с целью эффективного распознавания технического состояния подшипников качения буксовых узлов подвижного состава следует привлекать математический аппарат искусственных нейронных сетей как наиболее действенное средство обработки и классификации большого количества диагностической информации, которая предоставляется современными вибродиагностическими комплексами. Особенности процедуры функционирования и конструкции ИНС типа PNN позволяют обеспечить наилучший результат распознавания (99,6%), что значительно превышает возможности оператора по скорости и точности.

## ЛИТЕРАТУРА

1. Данько Н. И., Тартаковский Э. Д., Ломотько Д. В., Фалендиш А. П., Калабухин Ю. Е. Обновление подвижного состава с учетом жизненного цикла // Железнодорожный транспорт. – 2011. – № 12. – С. 42–44.
2. Мартинов І. Е., Равлюк В. Г. Вибродіагностування підшипників кочення рухомого складу методом обвідної // Зб. наук. праць ДонІЗТ. – Донецьк, 2010. – Вип. 23. – С. 127–134.
3. Михалків С. В., Равлюк В. Г. Апарат для класифікації технічного стану підшипників кочення буксових вузлів рухомого складу // Зб. наук. праць. – Харків: НТУ «ХПІ», 2012. – Вип. 19. – С. 105–112.
4. Кветный Р. Н., Кабачий В. В., Чумаченко О. О. Вероятностные нейронные сети в задачах идентификации временных рядов// Наукові праці Вісника національного технічного університету. – 2010. – № 3. – С. 7–15.
5. Руденко О. Г. Штучні нейронні мережі. – Харків: Компанія СМІТ, 2006. – 404 с.
6. Бодянский Е. В., Руденко О. Г. Искусственные нейронные сети: архитектуры, обучение, применения. – Харьков: Телетех, 2004. – 371 с.
7. Биргер И. А. Техническая диагностика. – М.: Машиностроение, 1978. – 240 с.
8. Фукунага К. Введение в статистическую теорию распознавания образов. – М.: Наука, 1979. – 368 с.
9. Цыпкин Я. З. Основы теории обучающихся систем. – М.: Наука, 1970. – 252 с.
10. Саркисян Р. Е., Стадниченко С. Ю., Масалида А. В. Алгоритмическое обеспечение системы диагностики: от байесовских правил до аналитических сетей//Мир транспорта. –2013. –№ 1. – С.6–11.
11. Haykin S. Neural Networks. A Comprehensive Foundation. – Upper Saddle River, N.J.: Prentice Hall, Inc., 1999. – 842 p.
12. Tsoukalas L. H., Uhrig R. E. Fuzzy and Neural Approaches in Engineering. – N.Y.: John Wiley & Sons, Inc., 1997. – 587 p.

## VIBRATION MONITORING OF JOURNAL-BOXES

**Martynov, Igor E.** – D. Sc. (Tech), professor, head of the department of the wagons of Ukrainian State Academy of Railways, Kharkov, Ukraine.

**Ravluk, Vassily G.** – senior lecturer of Ukrainian State Academy of Railways, Kharkov, Ukraine.

**Mihalkiv, Sergey V.** – Ph.D. (Tech), associate professor, head of the research department of Ukrainian State Academy of Railways, Kharkov, Ukraine.

The article describes possibilities to use instruments of probabilistic neural networks to classify technical conditions of the elements of frictionless bearings of rail rolling stock, analyzing vibration acoustics

information, collected with the help of modern troubleshooting units. The authors show the features of operation and design of artificial neural network that results in identification of problems at 99,6% cases.

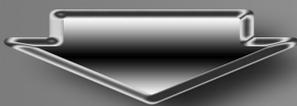
**Key words:** railway, rolling stock, frictionless bearing, axle-box, journal-box, artificial neural network, mathematical apparatus, vibration troubleshooting, monitoring, information, classification, systems of automatic troubleshooting, image, condition, state.

## REFERENCES

1. Danko N. I., Tartakovskiy E. D., Lomotko D. V., Falendish A. P., Kalabuhin Yu. E. Renewal of rolling stock subject to life cycle [Обновление подвижного состава с учетом жизненного цикла]. *Zheleznodorozhnyy transport*, 2011, No 12, pp. 42–44.
2. Martynov I. E., Ravluk V. G. Vibral troubleshooting of frictionless bearings of rolling stock by envelope method [Vibrodiagnostovannya pidshipnikiv kochennyya ruhomogo skladu metodom obvidnoi]. *Zb. nauk. prats' DonIZT [Proceedings of Donetsk institute of railways]*, Donetsk, 2010, Iss. 23, pp. 127–134.
3. Mihalkiv S. V., Ravluk V. G. Apparatus for classification of technical conditions of frictionless bearings of axle-boxes of rolling stock [Aparat dlya klasifikatsii tehničnogo stanu pidshipnikiv kochennyya bukovih vuzliv ruhomogo skladu]. *Zb. nauk. prats, Kharkov, NTU «HPI»*, 2012, Iss.19, pp. 105–112.
4. Kvetnyj R. N., Kabachiy V. V., Chumachenko O. O. Probabilistic neural networks in the problems of identification of time series [Veroyatnostnye neyronnye seti v zadachah identifikatsii vremennyh ryadov]. *Naukovi pratsi Visnika natsional'nogo tehničnogo universitetu [Proceedings of National technical university]*, 2010, No № 3, pp. 7–15.
5. Rudenko O. G. Artificial neural networks [Shtuchni neyronni merezhi]. *Kharkov, Kompaniya SMIT*, 2006. 404 p.
6. Bodyanskiy E. V., Rudenko O. G. Artificial neural networks: architecture, training, use [Iskusstvennye neyronnye seti: arhitektury, obuchenie, primeneniya]. *Kharkov, Teleteh*, 2004, 371 p.
7. Birger I. A. Technical troubleshooting [Tehnicheskaya diagnostika]. *Moscow, Mashinostroenie publ.*, 1978, 240 p.
8. Fukunaga K. Introduction to Statistical Pattern Recognition [Russian title: Vvedenie v statisticheskuyu teoriyu raspoznavaniya obrazov]. *Moscow, Nauka publ.*, 1979, 368 p.
9. Tsyppin Ya. Z. Fundamentals of the theory of learning systems [Osnovy teorii obuchayuschihya sistem]. *Moscow, Nauka publ.*, 1970, 252 p.
10. Sarkisyan R. E., Stadnichenko S. Yu., Masalida A. V. Knoware of Troubleshooting System: from Bayes Rules to Analytic Networks. *Mir transporta [World of Transport and Transportation Journal]*, 2013, Vol. 44, Iss.1, pp.6–11.
11. Haykin S. *Neural Networks. A Comprehensive Foundation*. Upper Saddle River, N.J.: Prentice Hall, Inc., 1999, 842 p.
12. Tsoukalas L. H., Uhrig R. E. *Fuzzy and Neural Approaches in Engineering*. N.Y.: John Wiley & Sons, Inc., 1997, 587 p.

Координаты авторов (contact information): Мартынов И. Э. (Martynov I. E.) – martinov.hiit@rambler.ru, Равлюк В. Г. (Ravluk V. G.) – ravvg@mail.ru, Михалкив С. В. (Mihalkiv S. V.) – roulez@rambler.ru.

Статья поступила в редакцию / article received 17.01.2013  
Принята к публикации / article accepted 12.03.2013



## ЭКСПРЕСС-ИНФОРМАЦИЯ

# ПРОЕКТ СКОРОСТНОГО ТРАМВАЯ

**Идет работа над проектом линии скоростного трамвая, которая свяжет восток столицы с подмосковной Балашихой.**

Согласно проекту, трамваи должны стартовать каждые 3–4 минуты от станции метро «Шоссе Энтузиастов», где появится транспортно-пересадочный узел, совмещенный с остановочным пунктом на Малом кольце Московской железной дороги. Общая протяженность маршрута составит около 21,3 км, из которых 15,7 км трамваи будут двигаться по специальным эстакадам, развивая при этом скорость до 75 км/ч. Время в пути 11 минут по московскому участку трассы и 35–40 минут по всему маршруту.

На территории Балашихи возможны два варианта прохождения трассы. Первый – вдоль Горьковского шоссе (автотрасса М7 «Волга»), второй – вдоль Балашихинской ветки Горьковского направления Московской железной дороги.

Строительство линии скоростного трамвая призвано облегчить сообщение



с центром столицы для жителей районов Ивановское (где сейчас нет станций метрополитена) и Перово, снизить загрузку шоссе Энтузиастов и Горьковского шоссе, а также разгрузить станции метро «Новогиреево» и «Перово», на которых сейчас в часы пик буквально яблоку негде упасть, тогда как у станции метро «Шоссе Энтузиастов» имеется резерв пропускной способности.

Фото ИТАР-ТАСС

