

## ИСКУССТВЕННЫЕ НЕЙРОСЕТЕВЫЕ МОДЕЛИ В АКУСТИЧЕСКОЙ ДИАГНОСТИКЕ ПРЯМОЗУБЫХ ЗУБЧАТЫХ КОЛЕС В СОСТАВЕ МНОГОВАЛЬНЫХ ПРИВОДОВ

А. Н. Парфиевич<sup>1</sup>, Ю. Н. Саливончик<sup>2</sup>, М. В. Селивоник<sup>3</sup>

<sup>1</sup> К. т. н., заведующий кафедрой прикладной механики

Брестского государственного технического университета, Брест, Беларусь, e-mail: mts7247021@yandex.by

<sup>2</sup> Старший преподаватель кафедры машиностроения и эксплуатации автомобилей

Брестского государственного технического университета, Брест, Беларусь, e-mail: ynsalivonchik@rambler.ru

<sup>3</sup> Преподаватель-стажер кафедры машиностроения и эксплуатации автомобилей

Брестского государственного технического университета, Брест, Беларусь, e-mail: smvpsych@gmail.com.

### Реферат

В статье рассмотрен нейросетевой подход при мониторинге технического состояния зубчатых колес в составе многовального привода, основанный на синтезе спектрального анализа акустического сигнала и алгоритмов обработки информации искусственными нейросетевыми моделями. Приведены различные варианты классических архитектур нейронных сетей, применяемых для решения задач классификации. Показана достаточно высокая эффективность и точность выявления локального дефекта зубчатого колеса многовального привода при проведении безразборной диагностики.

**Ключевые слова:** зубчатое колесо, дефект, диагностика, искусственная нейронная сеть, архитектура.

### ARTIFICIAL NEURAL NETWORK MODELS IN ACOUSTIC DIAGNOSTICS OF STRAIGHT-TOOTHED GEARS AS PART OF MULTI-SHAFT DRIVES

A. N. Parfievich, Yu. N. Salivonchik, M. V. Selivonik

### Abstract

The article considers a neural network approach for monitoring of the technical condition of gears as part of a multi-shaft drive, based on the synthesis of spectral analysis of an acoustic signal and algorithms for processing information by artificial neural network models. Various variants of classical architectures of neural networks used to solve classification problems are presented. Sufficiently high efficiency and accuracy of detecting a local defect in a gear wheel of a multi-shaft drive during CIP diagnostics is shown.

**Keywords:** gear wheel, defect, diagnostics, artificial neural network, architecture.

### Введение


Одной из основных задач при диагностировании многовальных зубчатых приводов в условиях эксплуатации является выделение из общего сигнала информативных составляющих, характеризующих состояние каждого элемента. Необходимость конкретизирования видов неисправностей требует использования более чувствительных характеристик акустических процессов [1]. Один из наиболее простых путей этого вопроса – применение спектрального анализа, математическая основа которого достаточно широко изучена и реализована в системах виброакустического контроля механизмов [2].

Не только зубчатые колеса формируют итоговый анализируемый сигнал, но другие элементы привода, что приводит к получению чрезмерно насыщенных информативными частотами узкополосных спектров. В результате их анализ становится трудноразрешимой проблемой. Исходя из этого, необходимость использования надежных признаков изменения технического состояния элементов зубчатых передач в составе многовального привода является весьма актуальной задачей.

### Постановка задачи

Эффективность диагностики и мониторинга текущего состояния исследуемого объекта зависит от числа составляющих анализируемого сигнала, доступных для его измерения и анализа с представлением в виде спектра посредством преобразования Фурье [3]. В наиболее часто применяемых анализаторах разрешение спектра составляет 4000–8000 линий, что приводит к потере некоторых составляющих, которые могут нести важную информацию о техническом состоянии исследуемого объекта. В экспериментальных исследованиях использовался аппаратно-программный комплекс, который позволяет получать спектральные характеристики с количеством линий до 524000 (рисунок 1). Это дает возможность добиться разрешения по оси частот не более 0,1 Гц в частотном диапазоне до 20 кГц. Благодаря высокому динамическому диапазону применяемого оборудования, составляющему более 90 дБ, реально зафик-

сировать мельчайшие по амплитуде частотные составляющие во всех частотных диапазонах.



а – фрагмент спектра акустического сигнала многовального зубчатого привода при использовании окна Ханна и числа линий спектра 524000;

б – фрагмент спектра акустического сигнала многовального зубчатого привода при использовании окна Ханна и числа линий спектра 8000

**Рисунок 1** – Фрагменты спектров акустического сигнала многовального зубчатого привода

Если для обработки искусственной нейросетевой модели подать всю информацию, содержащуюся в спектре акустического сигнала, то для нахождения в нем условных связей необходимы мощная вычислительная машина и продолжительный промежуток времени согласно применяемому алгоритму ее обучения. Чтобы избежать этого, предлагаем вычлнить из анализируемого сигнала искомые данные тех составляющих, которые являются следствием работы интересующих элементов диагностируемого привода – зубчатых колес конкретного вала. Как показывают результаты исследований [4, 5, 6], структура колебательного сигнала, фиксируемого с зубчатого привода, всегда имеет определенные компоненты, обусловленные спецификой работы зубчатых передач:

- низкочастотные составляющие, кратные частоте вращения элементов привода  $f_o$ :

$$f_{обг} = \frac{k \cdot n_i}{60}, \quad (1)$$

$$n_i = n_{i-1} \frac{z_{i-1}}{z_i}, \quad (2)$$

где  $n_i$  – частота вращения  $i$ -го вала;

$z_{i-1}, z_i$  – количество зубьев ведущего колеса предыдущего вала и ведомого колеса  $i$ -го вала;

$k$  – коэффициент, равный 1, 2, 3 и т. д.;

- высокочастотные составляющие с частотами пересопряжения зубьев всех зубчатых пар  $f_z$ , а также кратные им частоты:

$$f_z = n \cdot f_{обг} \cdot z_j, \quad (3)$$

где  $n$  – коэффициент, равный 1, 2, 3 и т. д.;

- составляющие колебаний с комбинированными частотами:

$$f_k = m \cdot f_z \pm k \cdot f_o \quad (4)$$

для каждого исследуемого колеса привода, возникающие вследствие различного рода модуляций сигнала ( $m, k = 1; 1,5; 2$  и т. д.);

- составляющие колебаний, генерируемые подшипниками качения, на частотах:

- а) перекатывания тел качения по внешней обойме:

$$F_H = f_o \cdot (N_{mk} / 2 - 1,2); \quad (5)$$

- б) перекатывания тел качения по внутренней обойме:

$$F_e = f_o \cdot (N_{mk} / 2 + 1,2); \quad (6)$$

- в) сепаратора:

$$F_c = f_o \cdot (1 - 1,2 / N_{mk}); \quad (7)$$

- модулированные составляющие, проявляющиеся на комбинированных частотах:

$$k \cdot F_e \pm m \cdot f_o \text{ и } k \cdot F_H \pm m \cdot f_o, \quad (8)$$

где  $N_{mk}$  – количество тел качения в одном ряду подшипника;

$f_o$  – оборотная частота вращения ротора;

$D_{mk}$  – диаметр тела качения;

$D_c$  – средний диаметр сепаратора;

- шумовые компоненты во всем диапазоне частот.

Из приведенной выше информации следует, что для характеристики состояния зубчатого колеса необходимо проанализировать зубцовые частоты  $f_z$ , кратные им гармоники  $m \cdot f_z$  и комбинированные частоты  $m \cdot f_z \pm k \cdot f_o$  в окрестности частоты пересопряжения

зубьев, как наиболее чувствительные к появлению локального дефекта на поверхности зуба.

### Объект исследования

В качестве объекта исследования использовался цилиндрический двухступенчатый редуктор (рисунок 2). В качестве диагностического средства использовался аппаратно-программный комплекс, технико-метрологические характеристики которого приведены в [7]. На одном из колес редуктора моделировался локальный дефект рабочей поверхности зуба (рисунок 3). Для создания числового образа каждого состояния (25 %, 50 %, 75 % отсутствия длины зуба и без зуба) проводилось 25 замеров. Результаты, которые были получены при использовании всех серийных колес, были приняты как эталонные.




Рисунок 2 – Кинематическая схема цилиндрического двухступенчатого редуктора




Рисунок 3 – Общий вид диагностируемого локального повреждения зуба зубчатого колеса в составе многовального привода

**Основная часть**

Поскольку искусственные нейронные сети в процессе обучения способны устанавливать сложные зависимости между входными и выходными данными, которые отсутствовали в обучающей выборке, и способны корректно классифицировать образы, полученные с объектов с высокой степенью виброакустической активности всех элементов исследуемой механической системы на основе зубчатых колес, они являются привлекательным инструментом для решения сложных и разнообразных задач классификации.

Представим нейронную сеть для классификации в виде черного ящика, который имеет  $n$  входов и  $m$  выходов (рисунок 4).



**Рисунок 4** – Условное обозначение искусственной нейронной сети для классификации исследуемого состояния зуба

Количество входов нейросетевого классификатора напрямую зависит от анализируемых данных и равняется размеру скользящего окна, а количество выходов – от количества классов анализируемых данных. В рассматриваемой задаче данные были разбиты на 5 классов в зависимости от состояния зуба (таблица 1).

**Таблица 1** – Классификация состояния зуба экспериментальной шестерни  $Z = 43$

№ класса	Состояние зуба
1	Без дефектов
2	25 % длины зуба повреждено
3	50 % длины зуба повреждено
4	75 % длины зуба повреждено
5	Скол зуба

Соответственно, количество выходов нейросетевого классификатора равняется 5. Таким образом, пространство выходных значений классификатора можно представить в следующем виде (таблица 2).

**Таблица 2** – Пространство выходных значений классификатора

$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$	Класс
1	0	0	0	0	Без дефектов
0	1	0	0	0	25 % длины зуба повреждено
0	0	1	0	0	50 % длины зуба повреждено
0	0	0	1	0	75 % длины зуба повреждено
0	0	0	0	1	Скол зуба

Существует большое количество разнообразных классических архитектур нейронных сетей, применяемых для решения тех или иных сложных инженерных задач:

- многослойные перцептроны (Multi-Layer Perceptron – MLP) [8, 9, 10] характеризуются прямым распространением входного сигнала от слоя к слою и состоят из множества входных нейронных элементов, из одного или нескольких скрытых слоев нейронных элементов и выходного слоя. Среди главных преимуществ таких сетей назовем возможность решать трудно формализуемые задачи или задачи, для которых алгоритмическое решение неизвестно, но для которых возможно составить репрезентативный набор примеров с известными решениями. MLP при обучении, за счет своего внутреннего строения, устанавливают корреляцию между входными и выходными образами и тем самым обобщают полученный на обучающей выборке опыт;

- нейронные сети с радиально-базисной функцией активации (Radial Basis Function networks – RBF) [8, 9, 10] применяются для решения задач прогнозирования, аппроксимации функций, распознавания образов и т. д.;
- нейронные сети Кохонена позволяют в результате обучения осуществлять типологически непрерывное отображение  $n$ -мерного пространства в выходное  $m$ -мерное пространство. Структура такой нейронной сети представляет собой сеть с прямым распространением сигнала. В качестве метода обучения для нее используется конкурентное обучение. По мере поступления входных образов на такую сеть при обучении происходит разбиение  $n$ -мерного входного пространства на различные области решений, каждой из которых соответствует отдельный нейрон;
- нейронная сеть векторного квантования (Learning Vector Quantization – LVQ) [8, 9, 10] является расширением сети Кохонена и содержит, кроме конкурентного слоя, линейный слой, который осуществляет классификацию кластеров, выделенных слоем Кохонена.

К предлагаемой системе классификации предъявляется ряд жестких требований, одним из которых является функционирование в режиме реального времени. В результате необходимо минимизировать временные затраты, связанные с обучением нейронной сети, а также с ее функционированием. Еще одним немаловажным требованием является размер обучающей выборки. Специфика анализируемых данных не позволяет получить достаточно их большой объем; следовательно, необходимо выбрать такую архитектуру нейронной сети, которая характеризовалась бы малым размером обучающей выборки и, соответственно, минимальным временем обучения.

MLP обучаются при помощи алгоритма обратного распространения ошибки (back-propagation algorithm) [8, 9, 10, 11] и успешно применяются для решения многих сложных задач классификации, распознавания и др. В [8, 9, 10, 11] отмечается, что на способность нейронной сети к корректному обобщению влияют размер обучающей выборки и архитектура нейронной сети.

Для корректного обучения нейронной сети достаточно, чтобы размер обучающей выборки  $L$  удовлетворял следующему соотношению [8, 9, 10, 11]:

$$L = O \cdot \left(\frac{W}{\epsilon}\right), \tag{9}$$

где  $W$  – общее количество настраиваемых параметров (весовых коэффициентов и пороговых значений);

$\epsilon$  – допустимая точность ошибки классификации;

$O(\dots)$  – порядок величины, т. е., например, для ошибки в 5 % количество примеров обучения должно в 5 раз превосходить количество свободных параметров сети  $W$ .

Общее количество настраиваемых параметров вычисляется согласно следующему выражению [8, 9, 10, 11]:

$$W = n \cdot m + m \cdot k + m + k, \tag{10}$$

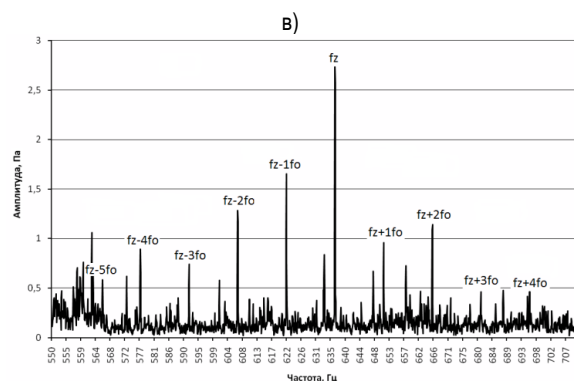


где  $n$  – количество входных нейронов;

$m$  – количество скрытых нейронов;

$k$  – количество выходных нейронов.

Рассчитаем размер обучающей выборки для MLP, RBF и LVQ соответственно (при аналогичных параметрах структуры нейронной сети):

1. Количество входных нейронов должно равняться размеру скользящего окна, сформированного на основе функции аппаратно-программного комплекса «Анализ гармоник», – в нашем случае  $n = 60$  (рисунок 5).



г)

i	Амплитуды гармоник, мкм											
	оборотной частоты $f_{oi}$	зубочвой частоты $f_{zi}$	модулированных боковых полос $f_{z \pm j f_{oi}}$									
			k=-5	k=-4	k=-3	k=-2	k=-1	k=1	k=2	k=3	k=4	k=5
1	0,067	2,73	1,06	0,89	0,74	1,28	1,65	0,96	1,14	0,46	0,46	0,15
2	0,032	0,78	0,58	0,48	1,33	0,88	1,03	0,55	0,14	0,48	0,25	0,07
3	0,017	0,67	0,84	0,13	0,16	0,41	0,22	0,15	0,17	0,72	0,20	0,44
4	0,023	0,06	0,05	0,06	0,06	0,03	0,04	0,03	0,04	0,05	0,06	0,09
5	0,028	0,03	0,03	0,04	0,04	0,05	0,05	0,11	0,03	0,02	0,02	0,03

а – фрагмент спектра акустического сигнала исследуемого объекта; б – фрагмент спектра акустического сигнала в области оборотных частот исследуемой шестерни; в – фрагмент спектра акустического сигнала в области частот  $(f_z - k \cdot f_o) - (f_z + k \cdot f_o)$  исследуемой шестерни; г – экспериментальные данные, полученные с помощью функции комплекса «Анализ гармоник» для исследуемой шестерни

**Рисунок 5** – Спектр акустического сигнала многозубчатого зубчатого привода и результат его обработки программными средствами комплекса «ВИКМА»

2. Количество скрытых нейронов  $m = 30$ .
3. Количество выходных нейронов  $k = 5$ , т. е. каждый из выходных нейронов отображает тот или иной класс входного образа согласно таблице 2.

Исходя из этого, в случае применения MLP в качестве классификации, обучающая выборка для обучения нейронной сети с допустимой ошибкой классификации  $\epsilon = 0,1$  должна состоять, согласно выражениям (9) и (10), из 19850 образов.

Нейронные сети на основе радиальных базисных функций также являются многослойными нейронными сетями [8, 9, 10, 11]. Первый их слой является входным и обеспечивает связь сети с внешней средой. Второй слой – скрытый, он выполняет нелинейное преобразование входного пространства образов в скрытое пространство, зачастую имеющее существенно более высокую размерность, чем входное. Третий слой – выходной, он состоит из линейных нейронов. В [8, 9, 10] выявлено, что для размерности обучающей выборки  $L$  оптимальное количество скрытых нейронных элементов для обеспечения минимальной ошибки обобщения должно быть следующим:

$$m \approx L^{1/3} \quad (11)$$

Соответственно, размерность обучающей выборки равняется

$$L \approx m^3 \quad (12)$$

При  $m = 30$   $L \approx 27000$ , что не подходит для обучения нейросетевого классификатора.

Рассмотрим обучающийся векторный квантователь (LVQ) [8, 9, 10] с идентичным количеством нейронов в каждом из слоев. В скрытом слое такой сети будем использовать нейронные элементы Кохонена [8, 9, 10, 12]. Для обучения такой сети достаточно, чтобы размер обучающей выборки был равным согласно следующему выражению [8, 9]:

$$L > 2 \cdot m \quad (13)$$

Таким образом, для обучения сети LVQ с нейронами Кохонена в скрытом слое необходимо иметь обучающую выборку с размерностью больше 60 образов.

В результате, основываясь на выдвинутых ранее требованиях к системе классификации, выберем в качестве основы нейросетевого классификатора нейронную сеть векторного квантования LVQ с нейронами Кохонена, которая характеризуется малым объемом обучающейся выборки, что позволит обучить нейросетевой классификатор на ограниченном объеме обучающей выборки.

Рассмотрим структуру предлагаемой нейронной сети для классификации (рисунок 6):

1. Первый слой нейронных элементов предназначен для распределения входных сигналов на нейроны Кохонена скрытого слоя. Размерность входного слоя (количество нейронов во входном слое) определяется размерностью анализируемых данных и равна 60, сформированные на основе функции аппаратно-программного комплекса «Анализ гармоник» (рисунок 5г).
2. Второй слой искусственной нейронной сети состоит из нейронов Кохонена, размерной которого определена экспериментально и в нашем случае равняется 30. Для обучения слоя Кохонена используется конкурентный метод обучения с одним победителем [8, 9, 10].
3. Третий слой состоит из 5 линейных нейронных элементов и осуществляет отображение кластеров, сформированных слоем Кохонена, в 5 классов соответственно.

Из представленных ниже результатов видно, что общая точность классификации разработанного нейросетевого классификатора составляет 92,2 %. Причем точность классификации 1-го класса составила 88,9 %, 2-го, 3-го и 4-го классов – 100 %, а точность классификации 5-го класса – 72,7 % (рисунок 7).

Относительно невысокая точность классификации пятого класса связана со средней квадратичной ошибкой обучения нейронной сети, которая составила 0,00533, т. е. нейронная сеть не смогла обучиться полностью (идеальным является значение средней квадратичной ошибки, равное нулю). Как видно из рисунка 8, в процессе обучения нейронная сеть не смогла корректно научиться классифицировать образы из 5-го класса, где она показала точность классификации, равной 93,3 %, что и отразилось на группировании тестового набора данных. Путем изменения количества нейронов в скрытом слое или увеличением размерности обучающей выборки можно устранить данный недостаток.

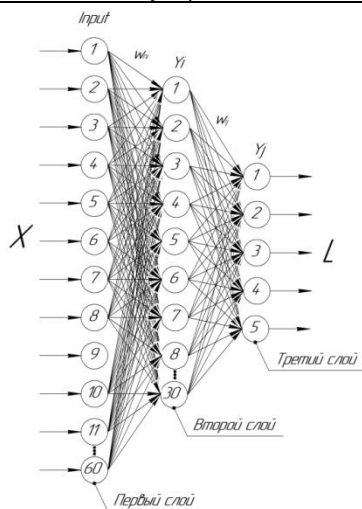


Рисунок 6 – Условное отображение структуры нейронной сети для классификации

Confusion Matrix

	1	2	3	4	5	
1	8 15.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
2	1 2.0%	10 19.6%	0 0.0%	0 0.0%	3 5.9%	71.4%
3	0 0.0%	0 0.0%	11 21.6%	0 0.0%	0 0.0%	100%
4	0 0.0%	0 0.0%	0 0.0%	10 19.6%	0 0.0%	100%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 15.7%	100%
	88.9%	100%	100%	100%	72.7%	92.2%
	11.1%	0.0%	0.0%	0.0%	27.3%	7.8%
	1	2	3	4	5	

Рисунок 7 – Результаты решения задачи классификации

Training Confusion Matrix

	1	2	3	4	5	
1	15 20.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
2	0 0.0%	15 20.0%	0 0.0%	0 0.0%	1 1.3%	93.8%
3	0 0.0%	0 0.0%	15 20.0%	0 0.0%	0 0.0%	100%
4	0 0.0%	0 0.0%	0 0.0%	15 20.0%	0 0.0%	100%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	14 18.7%	100%
	100%	100%	100%	100%	93.3%	98.7%
	0.0%	0.0%	0.0%	0.0%	6.7%	1.3%
	1	2	3	4	5	

Рисунок 8 – Результаты обучения нейросетевого классификатора

**Заключение**

Нейросетевой подход в диагностике многовалентных зубчатых приводов позволяет сформулировать методику их диагностирования, состоящую из следующих этапов:

- выделение информативных частот и оценка их значимости;
- создание вектора диагностических признаков;
- оценка технического состояния исследуемого объекта на основе применения теории распознавания образов.

Это позволяет минимизировать участие человека в процедуре диагностирования, что позволяет повысить объективность полученных результатов. Несмотря на то, что данный метод требует дополнительных действий, не связанных непосредственно с процессом диагностики: большого объема предварительных исследований, обучения сети на определенных диагностических признаках, определения технологии подготовки данных, – подготовив искусственную нейронную сеть по определенным критериям, ее можно в дальнейшем использовать для

постановки диагноза на других аналогичных объектах, имеющих схожую природу формирования анализируемого сигнала.

**Список цитированных источников**

1. Генкин, М. Д. Виброакустическая диагностика машин и механизмов / М. Д. Генкин, А. Г. Соколова. – М. : Машиностроение, 1987. – 288 с.
2. Русов, В. А. Диагностика дефектов вращающегося оборудования по вибрационным сигналам / В. А. Русов. – Пермь, 2012. – 252 с.
3. Барков, А. В. Мониторинг и диагностика роторных машин по вибрации [Электронный ресурс] / А. В. Барков, Н. А. Баркова, А. Ю. Азовцев. – Санкт-Петербург : 2014. – Режим доступа: <http://www.vibrotek.com/russian/articles/book/index.htm>.
4. Неразрушающий контроль и диагностика : справочник : в 7 т. / под общ. ред. В. В. Клюева. – М. : Машиностроение, 2003. – 656 с.
5. Иванов, В. И. Неразрушающий контроль : справочник : в 7 т. / В. И. Иванов, И. Э. Власов ; под общ. ред. В. В. Клюева. – Т. 7 : Кн. 1 : Метод акустической эмиссии. – М. : Машиностроение, 2005. – С. 12–341.
6. Неразрушающий контроль : справочник : в 7 т. / Ф. Я. Балицкий [и др.] ; под общ. ред. В. В. Клюева. – М. : Машиностроение, 2005. – Т. 7, кн. 2: Вибродиагностика. – С. 341–820.
7. Новые аппаратно-программные средства для исследования и диагностики механических систем / А. В. Драган [и др.] // Вестник Брестского государственного технического университета. – 2006. – № 4. – С. 17–26.
8. Головки, В. А. Нейросетевые технологии обработки данных : учебное пособие / В. А. Головки, В. В. Краснопрошин. – Минск : БГУ, 2017. – 263 с.
9. Искусственные нейронные сети и искусственные иммунные системы для обнаружения вторжений : моногр. / М. П. Комар [и др.]. – Тернополь : ТНЭУ, 2018. – 192 с.
10. Уоссерман, Ф. Нейрокомпьютерная техника. Теория и практика / Ф. Уоссерман. – М. : Мир, 1992. – 236 с.
11. Хайкин, С. Нейронные сети / С. Хайкин. – М. : Вильямс, 2006. – 1103 с.
12. Kohonen, T. The self organizing map / T. Kohonen // Proceedings of the Institute of Electrical and Electronics Engineers. – 1990. – Vo1. 78. – P. 1464–1480.

**References**

1. Genkin, M. D. Vibroakusticheskaya diagnostika mashin i mekhanizmov / M. D. Genkin, A. G. Sokolova. – M. : Mashinostroenie, 1987. – 288 s.
2. Rusov, V. A. Diagnostika defektov vrashchayushchegosya oborudovaniya po vibratsionnym signalam / V. A. Rusov. – Perm', 2012. – 252 s.
3. Barkov, A. V. Monitoring i diagnostika rotornykh mashin po vibratsii [Elektronnyj resurs] / A. V. Barkov, N. A. Barkova, A. Yu. Azovcev. – Sankt-Peterburg : 2014. – Rezhim dostupa: <http://www.vibrotek.com/russian/articles/book/index.htm>.
4. Nerazrushayushchij kontrol' i diagnostika : spravochnik : v 7 t. / pod obshch. red. V. V. Klyueva. – M. : Mashinostroenie, 2003. – 656 s.
5. Ivanov, V. I. Nerazrushayushchij kontrol' : spravochnik : v 7 t. / V. I. Ivanov, I. E. Vlasov ; pod obshch. red. V. V. Klyueva. – T. 7 : Kn. 1 : Metod akusticheskoy emissii. – M. : Mashinostroenie, 2005. – S. 12–341.
6. Nerazrushayushchij kontrol' : spravochnik : v 7 t. / F. YA. Balickij [i dr.] ; pod obshch. red. V. V. Klyueva. – M. : Mashinostroenie, 2005. – T. 7, kn. 2: Vibrodiagnostika. – С. 341–820.
7. Novye apparatno-programmnye sredstva dlya issledovaniya i diagnostiki mekhanicheskikh sistem / A. V. Dragan [i dr.] // Vestnik Brestskogo gosudarstvennogo tekhnicheskogo universiteta. – 2006. – № 4. – S. 17–26.
8. Golovko, V. A. Nejrosetevye tekhnologii obrabotki dannyh : uchebnoe posobie / V. A. Golovko, V. V. Krasnoproschin. – Minsk : BGU, 2017. – 263 s.
9. Iskusstvennyye nejronnyye seti i iskusstvennyye immunnyye sistemy dlya obnaruzheniya vtorzhenij : monogr. / M. P. Komar [i dr.]. – Ternopol' : TNEU, 2018. – 192 s.
10. Uosserman, F. Nejrokompyuternaya tekhnika. Teoriya i praktika / F. Uosserman. – M. : Mir, 1992. – 236 s.
11. Hajkin, S. Nejronnyye seti / S. Hajkin. – M. : Vil'yams, 2006. – 1103 s.
12. Kohonen, T. The self organizing map / T. Kohonen // Proceedings of the Institute of Electrical and Electronics Engineers. – 1990. – Vo1. 78. – P. 1464–1480.

Материал поступил в редакцию 01.06.2022