

УДК 620.179.18

**ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕВОГО ДЕТЕКТОРА  
ПРИ АКУСТИЧЕСКОЙ ДИАГНОСТИКЕ  
МНОГОВАЛЬНЫХ ЗУБЧАТЫХ ПРИВОДОВ**  
*USE OF THE NEURAL NETWORK DETECTOR FOR ACOUSTIC  
DIAGNOSTICS OF MULTI-SHAFT GEAR DRIVES*

Парфиевич А.Н., Драган А.В., Безобразов С.В.  
*Parfievich A.N., Dragan A.V., Bezobrazov S.V.*

В статье рассмотрена возможность диагностики многовальной зубчатой механической системы на основе анализа акустического сигнала с применением нейросетевого детектора на примере коробки скоростей токарного станка SN-501. Показана достаточно высокая эффективность и точность выявления локального дефекта зубчатого колеса в условиях высокой акустической активности всех составляющих привода при проведении мониторинга его состояния.

*The article considers the possibility of diagnosing a multi-shaft toothed mechanical system based on the analysis of an acoustic signal using a neural network detector using the example of the lathe speed box SN-501. A sufficiently high efficiency and accuracy of detecting the local defect of the gear wheel in conditions of high acoustic activity of all components of the drive during monitoring of its condition is shown.*

**Введение.** В настоящее время перед специалистами-диагностами, занимающимися исследованиями различного рода механизмов на основе зубчатых передач, стоит непростая задача, связанная с формализацией процедуры мониторинга, но при этом важно не потерять в процессе упрощения тот объем информации, который несет в себе сведения об изменениях в диагностируемом объекте. Для достижения поставленной цели все чаще прибегают к совместному использованию известных способов представления колебательных процессов, сопровождающих работу устройства, и современных математических средств.

Одним из наиболее распространенных методов представления колебательного сигнала является спектральный анализ, математическая основа которого достаточно хорошо изучена и реализована практически на всех современных контрольно-диагностических средствах. Для диагностирования периодических колебательных процессов с использованием амплитудно-частотного анализа наиболее часто

применяется процедура преобразования Фурье. Данный способ представления акустического сигнала позволяет оценить его состав и амплитуду характерных частот, генерируемых каждым элементом механического привода, а также проследить за их изменениями, обусловленными изменением состояния зубчатых колес.

**Объект и предмет исследований.** В качестве объекта исследования была выбрана сложная механическая система – коробка скоростей привода главного движения токарного станка мод. SN-501. При работе привода находятся в движении как зубчатые передачи кинематической цепи передачи вращения на выходной вал, так и другие его элементы, не влияющие на вращение шпинделя (приводы гитары сменных колес, реверса, тормозного механизма и паразитные шестерни), но оказывающие влияние на формирование итогового акустического сигнала работы привода. Это приводит к возникновению на спектре большого количества дополнительных составляющих, затрудняющих выявление и анализ гармоник на интересующих частотах.

В качестве источника информации использовался акустический сигнал, сформированный аппаратно-программным комплексом ВИКМА на основе данных, полученных с измерительного микрофона с капсулом M101, установленного на расстоянии 300 мм от корпуса коробки скоростей в горизонтальной плоскости [1]. Измерение акустических сигналов производилось на частотах вращения входного вала, соответствующих эксплуатационным как под нагрузкой, так и без нее.

Одновременное применение преобразователей угловых перемещений на входном и выходном валах привода дало возможность с высокой точностью определять частоты вращения входного и выходного вала, а также частоты характерных составляющих на спектре анализируемого сигнала.

На шестерне  $Z=43$  вала II, входящей в исследуемую кинематическую цепь коробки скоростей, моделировался эксплуатационный локальный дефект рабочей части зуба различной величины (25%, 50%, 75% длины по вершине зуба и без зуба) (Рис. 1). Замеры проводились для каждого состояния зуба многократно для накопления необходимого объема данных для статистической обработки. Результаты, полученные при использовании серийных колес, приняты эталонными.




Рис. 1. Экспериментальная шестерня  $Z=43$  с эксплуатационным местным дефектом зуба


Полученные в ходе эксперимента спектральные характеристики акустического сигнала свидетельствуют о том, что каждый из элементов привода вносит свой вклад в его формирование. Но при большом количестве источников акустической активности необходим высококвалифицированный специалист-диагност для выявления характеристик каждого элемента объекта и последующей постановки соответствующего диагноза, поэтому спектральный анализ имеет ограничения при диагностировании сложных механических систем на основе зубчатых передач и требует формализации и автоматизации обработки поступающих для анализа данных.

Анализируя полученные спектры акустической активности исследуемого объекта, можно отметить проблему его чрезмерной насыщенности различными составляющими от работающих элементов привода, но в то же время уменьшение разрешения спектра может привести к утрате данных, которые могут нести в себе диагностическую информацию.

Как известно из целого ряда литературных источников [2, 3 и др.], наибольшую диагностическую ценность имеет следующий ряд частотных составляющих, изменение амплитуд которых несет значимые сведения о состоянии исследуемого элемента объекта:

- в области низких частот – оборотные  $f_0$  и кратные им составляющие всех зубчатых колес кинематической цепи;
- в области пересопряжения зубьев – зубцовые  $f_z$ , кратные им составляющие зубчатых колес, а также другие частотные составляющие на комбинированных частотах  $lf_z \pm nf_0$ , возникающие вследствие различного рода модуляций сигнала ( $l, n=0,5; 1; 1,5; 2$  и т.д.).

Принимая во внимание очень большое количество подлежащих анализу характерных частотных составляющих для каждого зубчатого колеса, определение их характеристик «вручную» представляет собой очень кропотливый процесс. Для его автоматизации в программной части комплекса разработана и реализована новая функция «Анализ гармоник», позволяющая автоматически получать значения частот и амплитуд оборотных и зубцовых составляющих спектров, их кратных гармоник, а также комбинированных составляющих, формируемых при работе каждого зубчатого колеса и формирующих набор наиболее информативных частотных составляющих при выявлении дефектов и погрешностей зубчатых колес (рис. 2).



б)

i	Амплитуды гармоник							
	оборотной частоты $f_{oi}$	зубцовой частоты $f_{zi}$	модулированных боковых полос $f_{zi \pm i f_{oi}}$					
			j=-3	j=-2	j=-1	j=1	j=2	j=3
1	0,237	6,018	0,2877	0,2203	2,0718	2,2243	1,5597	1,1467
2	0,0632	1,473	1,1489	0,9026	0,3780	2,037	0,2023	0,1939
3	0,0205	0,355	0,3953	0,1080	0,3725	0,1903	0,1491	0,1451
4	0,0405	0,073	0,0465	0,0588	0,0535	0,0524	0,0304	0,0312
5	0,0290	0,022	0,0814	0,0513	0,0295	0,0251	0,0349	0,0369




Рис. 2. Спектр акустического сигнала многовального зубчатого привода и результат его обработки программными средствами комплекса ВИКМА:  
 а) фрагмент спектра акустического сигнала исследуемого объекта;  
 б) экспериментальные данные, полученные с помощью функции комплекса «Анализ гармоник» для исследуемой шестерни; в) фрагмент спектра акустического сигнала в области частот  $(f_z - 5f_o) - (f_z + 5f_o)$  исследуемой шестерни;  
 г) фрагмент спектра акустического сигнала в области оборотных частот исследуемой шестерни

Разработанная методика автоматической обработки спектральных характеристик позволяет упростить процедуру анализа параметров акустического шума. Это дает возможность сузить набор анализируемых данных для постановки диагноза и совершить шаги к формализации процедуры диагностирования за счет применения мощных современных математических средств, в качестве которых предлагается использовать возможности искусственных нейронных сетей.

**Нейросетевой метод диагностики.** Полученный объем экспериментальных данных об акустической активности привода был разбит на 5 классов в зависимости от состояния зуба (табл. 1) и применен при решении задачи классификации. В качестве обучающей выборки было сформировано 25 образов каждого из анализируемых состояний, 5 из которых было предоставлено сети для тестирования.

Описание каждого образа осуществлялось амплитудами гармоник акустического сигнала, полученными из спектров высокого разрешения программными средствами комплекса с помощью функции «Анализ гармоник». В качестве их принимались для каждого зубчатого колеса амплитуды не менее 5 гармоник оборотной  $f_0$  и зубцовой  $f_z$  частоты и 6 амплитуд модулированных боковых полос  $f_z \pm if_0, i = -3 \dots 3$ .

Таблица 1. Классификация состояния экспериментальной шестерни  $Z=43$

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

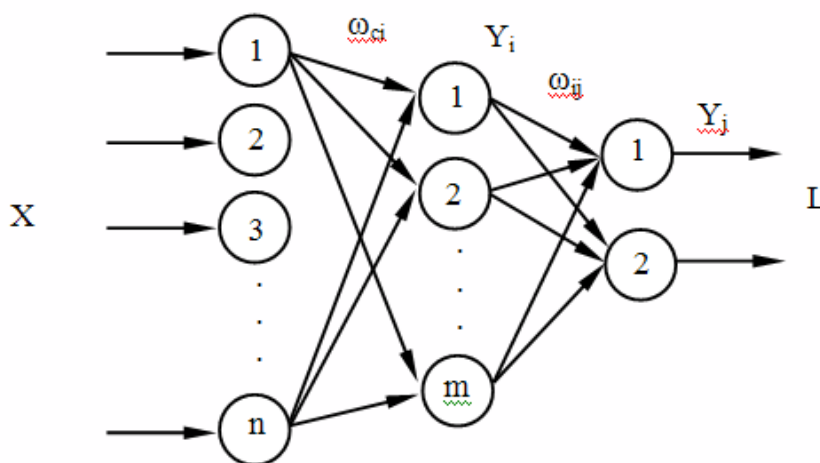


Рис. 3. Структура нейросетевого классификатора на основе нейронов Кохонена.

В качестве классификатора была выбрана многослойная нейронная сеть с одним скрытым слоем, состоящим из нейронов Кохонена [4], структура которой приведена на рисунке 3.

Выбор данной структуры искусственной нейронной сети обусловлен ограниченным набором анализируемых данных. Так, при использовании многослойного персептрона в качестве классификатора необходим следующий размер обучающей выборки [5]:

$$L \approx \frac{V}{\varepsilon} \quad (1)$$

где  $\varepsilon$  - допустимая точность классификации;

$V$  - общее количество настраиваемых параметров (весовых коэффициентов и пороговых значений) вычисляется по формуле:

$$V = m \cdot (n + 3) + k \quad (2)$$

где  $m$  - количество нейронов скрытого слоя;

$n$  - количество нейронов распределительного (входного) слоя;

$k$  - количество нейронов выходного слоя.

Допустим,  $n = 60$ ,  $m = 30$ ,  $k = 5$  и  $\varepsilon = 0,1$ . Тогда  $L \approx 18950$ .

Аналогичный результат можно получить для мультирекуррентных нейронных сетей [6], а также для глубоких нейронных сетей (deep learning neural networks) [7].

Для выбранной структуры нейросетевого классификатора нет жестких требований к размерности обучающей выборки. Достаточно, чтобы размер обучающей выборки был следующим:

$$L \geq 2 \cdot m \quad (3)$$

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. В нашем случае используются данные размерностью равной 60, следовательно, количество нейронов распределительного слоя равно  $n=60$ . Входными сигналами являются параметры, сформированные на основе функции аппаратно-программного комплекса «Анализ гармоник» (рис. 2, г).

Второй, скрытый слой искусственной нейронной сети состоит из нейронов Кохонена. Слой Кохонена играет ключевую роль в классификации данных и осуществляет кластеризацию входного простран-

ства образов, в результате чего образуются кластеры различных образов, каждому из которых соответствует свой нейронный элемент. Оптимальное количество нейронов в скрытом слое Кохонена определяется экспериментально, и может отличаться в зависимости от разновидности задач, структуры данных и т.д. В рассматриваемом случае эксперименты показали хорошие результаты при количестве нейронов в скрытом слое равном  $m = 30$ .

Для обучения слоя Кохонена используется конкурентный метод обучения [4, 5]. Суть данного метода обучения заключается в том, что в процессе обучения происходит конкуренция между нейронными элементами, в результате чего определяется нейронный элемент-победитель, который характеризует класс анализируемых данных. Для определения нейрона-победителя используется Евклидово расстояние между входным и весовым векторами, определяемое как:

$$D_i = |X - \omega_i| = \sqrt{(X_1 - \omega_{1i})^2 + (X_2 - \omega_{2i})^2 + \dots + (X_c - \omega_{ci})^2}, \quad (4)$$

где  $\omega_{ci}$  – весовой коэффициент между  $c$ -м нейроном распределительного слоя и  $i$ -м нейроном слоя Кохонена;

$X = [X_1, X_2 \dots X_n]$  – входной образ.

В процессе обучения синаптические связи для нейрона-победителя усиливаются, а для остальных нейронов не изменяются. Таким образом, после обучения искусственной нейронной сети, при подаче входного образа активность нейрона-победителя принимается равной единице, а остальные нейроны «сбрасываются» в ноль [4–6]. Такое правило обучения известно под названием «победитель берет все» (winner-take-all) [4, 5].

Третий слой состоит из пяти линейных нейронных элементов и осуществляет отображение кластеров, сформированных слоем Кохонена, в 5 классов соответственно. Активность выходного нейрона, когда его значение равно единице, характеризует тот или иной класс. В этом случае все остальные выходные нейроны имеют активность равную нулю.

**Алгоритм обучения нейронной сети** можно представить в виде следующей последовательности шагов (рис. 4):

1. Случайная инициализация весовых коэффициентов  $\omega_{ci}$  нейронов  $Y_i$  слоя.
2. Распределение входного образа из обучающей выборки на нейронную сеть и вычисление следующих параметров:



а) определяется Евклидово расстояние между входным образом и весовыми векторами нейронных элементов слоя  $Y_i$ :

$$D_i = |X - \omega_i| = \sqrt{(X_1 - \omega_{1i})^2 + (X_2 - \omega_{2i})^2 + (X_n - \omega_{ni})^2}, \quad (5)$$

где  $i = \overline{1, m}$ .

б) нейронный элемент-победитель с номером  $k$ :

$$D_k = \min_j D_j. \quad (6)$$

в) выходное значение нейрона-победителя устанавливается «1», а остальных нейронных элементов – «0»:

$$Y_i = \begin{cases} 1, & i = k \\ 0, & \text{иначе} \end{cases} \quad (7)$$

г) производится модификация весовых коэффициентов нейрона-победителя в соответствии со следующим выражением:

$$\omega_{ck}(t+1) = \omega_{ck}(t) + \gamma (X_c - \omega_{ck}(t)), \quad (8)$$

е) если нейроном-победителем является нейрон, соответствующий представленному образу (так при количестве нейронов в слое  $Y_i$  равным 5, при подаче на вход сети образа, соответствующего целой шестерни, нейрон-победитель должен быть с индексом 1; при подаче образа, соответствующего 25% повреждения, нейрон-победитель должен быть под индексом 2 и т.д.). В противном случае:

$$\omega_{ck}(t+1) = \omega_{ck}(t) - \gamma (X_c - \omega_{ck}(t)). \quad (9)$$

Процесс повторяется, начиная с пункта 2 для всех входных образов.

3. Обучение производится до желаемой степени согласования между входными и весовыми векторами.

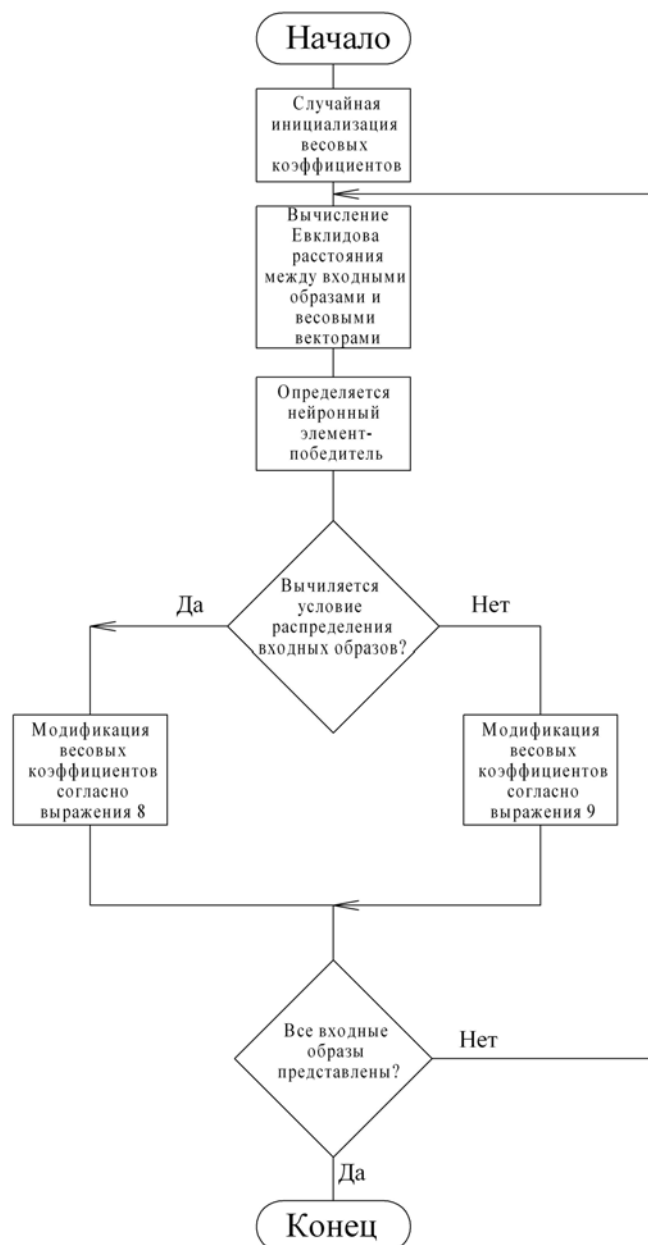


Рис.4. Схема алгоритма обучения нейросетевого классификатора

Величина достоверности распознавания в ходе обучения нейронной сети составила 93,3%, ошибочно распознанные образы соответствовали соседним классам.

**Тестирование нейронной сети.** На первоначальном этапе в качестве тестируемых объектов выступили шестерни  $z=24$  вала III и  $z=27$  вала IV коробки скоростей токарного станка SN-501 в технически исправном состоянии. Точность постановки диагноза обученной нейронной сетью составила 100%.

Для проверки адекватности предлагаемого метода акустической диагностики, кроме коробки скоростей привода главного движения

токарного станка SN-501 как базового объекта, тестировались элементы таких зубчатых приводов как горизонтальный редуктор с цилиндрическими прямозубыми колесами модели РМ-250 и коробка скоростей радиально-сверлильного станка мод. 2К52.

На шестерне  $z=40$  горизонтального редуктора с цилиндрическими прямозубыми колесами РМ-250 были смоделированы аналогичные локальные дефекты в виде повреждения зуба, как и в коробке скоростей токарного станка (25%, 50% и 75% длины зуба и без зуба).

При диагностировании коробки скоростей радиально-сверлильного станка 2К52 объектом исследования являлась технически исправная шестерня  $z=42$  кинематической цепи. На этапе сбора данных моделировались различные ситуации: работа коробки скоростей на холостом ходу и работа под нагрузкой (в ходе использования станка при механической обработке).

Результаты применения нейронной сети для выявления зубчатых колес с поврежденными зубьями приведены в таблице 2.

Таблица 2. Достоверность выявления повреждений зубьев многовальных приводов по акустическим данным с применением искусственной нейронной сети

Классы диагностируемых параметров зубчатого колеса	Точность постановки диагноза, %				
	Целый зуб	25% длины зуба	50% длины зуба	75% длины зуба	Без зуба
1	2	3	4	5	6
<b>Исправные шестерни <math>z=24</math> и <math>z=27</math> коробки скоростей токарного станка SN-501</b>					
Целый зуб	100%	-	-	-	-
25% ширины зуба	-	-	-	-	-
50% ширины зуба	-	-	-	-	-
75% ширины зуба	-	-	-	-	-
Без зуба	-	-	-	-	-
1	2	3	4	5	6
<b>Шестерня <math>Z=40</math> редуктора РМ-250 со сколом целого зуба</b>					
Целый зуб	-	-	-	-	-
25% ширины зуба	-	-	-	-	-
50% ширины зуба	-	-	-	-	-
75% ширины зуба	-	-	-	13,3%	-
Без зуба	-	-	-	-	86,7%
<b>Шестерня <math>Z=40</math> редуктора РМ-250 с повреждением 75% длины зуба</b>					
Целый зуб	-	-	-	-	-
25% ширины зуба	-	-	-	-	-
50% ширины зуба	-	-	3,3%	-	-
75% ширины зуба	-	-	-	96,7%	-
Без зуба	-	-	-	-	-

Продолжение табл. 2

1	2	3	4	5	6
<b>Шестерня Z=40 редуктора РМ-250 с повреждением 50% длины зуба</b>					
Целый зуб	-	-	-	-	-
25% ширины зуба	-	-	-	-	-
50% ширины зуба	-	-	<b>100%</b>	-	-
75% ширины зуба	-	-	-	-	-
Без зуба	-	-	-	-	-
<b>Шестерня Z=40 редуктора РМ-250 с повреждением 25% длины зуба</b>					
Целый зуб	<b>13,3%</b>	-	-	-	-
25% ширины зуба	-	<b>83,3%</b>	-	-	-
50% ширины зуба	-	-	<b>3,3%</b>	-	-
75% ширины зуба	-	-	-	-	-
Без зуба	-	-	-	-	-
<b>Исправная шестерня Z=40 редуктора РМ-250</b>					
Целый зуб	<b>100%</b>	-	-	-	-
25% ширины зуба	-	-	-	-	-
50% ширины зуба	-	-	-	-	-
75% ширины зуба	-	-	-	-	-
Без зуба	-	-	-	-	-
<b>Исправная шестерня z=42 коробки скоростей радиально-сверлильного станка 2К52</b>					
Целый зуб	<b>100%</b>	-	-	-	-
25% ширины зуба	-	-	-	-	-
50% ширины зуба	-	-	-	-	-
75% ширины зуба	-	-	-	-	-
Без зуба	-	-	-	-	-

Точность постановки диагноза обученной на одном объекте искусственной нейронной сети при ее использовании на других зубчатых приводах составила не менее 83%, поскольку диагностические признаки, описывающие классы состояния зубчатых колес, для сходных объектов аналогичны. Причем во всех случаях ошибочные результаты соответствовали соседнему классу состояния зуба, а колеса с неповрежденными зубьями оценивались исправными безошибочно. Очевидно, что выбранный набор параметров акустического сигнала для описания состояния поврежденных колес является достаточным для адекватной работы нейросетевого анализатора.

**Заключение.** Таким образом, разработанная в ходе экспериментальных исследований методика диагностики элементов многовальных рядных зубчатых приводов с использованием нейросетевых моделей показала достаточно высокую эффективность и точность. Предложенная структура нейросетевого детектора для классифика-

ции предлагаемых состояний зуба шестерни характеризуется малым объемом обучающей выборки и отличается высоким уровнем точности кластеризации при анализе акустического сигнала, являющимся «продуктом» активности всех элементов кинематической цепочки коробки скоростей токарного станка SN-501. Данный подход в исследовании многовальных зубчатых приводов предполагает минимизировать участие человека непосредственно при процедуре диагностирования, что, в свою очередь, призвано повысить ее объективность. Несмотря на то, что данный метод требует дополнительных действий, не связанных непосредственно с процессом диагностики (обучения сети на теоретически и практически обоснованных диагностических признаках, определения технологии подготовки данных), подготовленная искусственная нейронная сеть может в дальнейшем использоваться для постановки диагноза на других аналогичных объектах, имеющих схожую природу формирования анализируемого сигнала.

### Список цитируемых источников

1. Драган А.В., Стецко И.П., Ромашко Д.А., Левкович Н.В. Новые аппаратно-программные средства для исследования и диагностики механических систем // Вестник Брестского государственного технического университета. – 2006. – №4. – С. 17–26.
2. Мониторинг и диагностика роторных машин по вибрации [Электронный ресурс] / А.В. Барков, Н.А. Баркова, А.Ю. Азовцев: <http://www.vibrotek.com/russian/articles/book/index.htm>.
3. Anil Jacob and Dr. Y. I. Sharaf-Eldeen Диагностирование зубчатой передачи с помощью нового метода контроля состояния роторного оборудования: Перевод с англ. [Электронный ресурс]. – Режим доступа: [http://www.vibration.ru/d\\_zub\\_peredach.shtml](http://www.vibration.ru/d_zub_peredach.shtml).
4. Kohonen, T. Self-organized formation of topologically correct feature maps / T. Kohonen // Biological Cybernetics. – 1982. – N43. – P. 59-69.
5. Головкин, В.А. Нейронные сети: обучение, организация, применение / В.А. Головкин // Нейрокомпьютеры и их применение : учеб. пособие / В.А. Головкин. – М., 2001 – 256 с.
6. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. – М.: Вильямс, 2006. – 1104 с.
7. Bengio, Y. Learning Deep Architectures for AI / Y. Bengio. – Now Publishers Inc, 2009. – 114 pp.

*Статья поступила в редакцию 20.06.17*