

Парфиевич А.Н., Драган А.В., Безобразов С.В.

## АКУСТИЧЕСКАЯ ДИАГНОСТИКА МНГОВАЛЬНЫХ ЗУБЧАТЫХ ПРИВОДОВ НА ОСНОВЕ ИСПОЛЬЗОВАНИЯ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Искусственная нейронная сеть является математической либо программной, или аппаратной моделью, моделирующей принципы организации и функционирования биологических нейронных сетей, и состоит из соединенных и взаимодействующих между собой вычислительных элементов – нейронов. Теория искусственных нейронных сетей возникла на стыке наук и имеет целью моделирование биологической нейронной сети для достижения таких свойств систем, как способность к обучению, самоорганизации и адаптации. На сегодняшний день существует довольно-таки много архитектур искусственных нейронных сетей, которые, благодаря своим особенностям, например в процессе обучения выявлять сложные зависимости в наборе данных, с успехом применяют при решении таких сложных инженерных задач, как распознавание образов, классификация, прогнозирование, системы контроля и т. д. Более того, нейронные сети обладают рядом достоинств и преимуществ в сравнении с традиционными решениями. Вот только некоторые из них: высокая степень параллелизма обработки информации; способность к обобщению, адаптация к изменениям окружающей среды; распознавание зашумленных образов; низкий уровень ресурсоемкости и т. д. Задачи классификации – традиционно сильная сторона искусственных нейронных сетей, что и повлияло на выбор инструмента при диагностировании зубчатых приводов на наличие повреждений с их помощью. В ходе проводимых исследований производилась попытка применения искусственных нейронных сетей в целях диагностики многовальных приводов на основе зубчатых передач.

Одним из объектов исследования был выбран горизонтальный редуктор с цилиндрическими прямозубыми колесами (рис. 1). Источником информации о его текущем состоянии послужил акустический шум, сформированный аппаратно-программным комплексом [1] на основе данных, полученных с измерительного микрофона с капсулем M101. Для определения частот вращения входного и выходного валов и частот характерных составляющих анализируемого сигнала применялись одновременно преобразователи угловых перемещений. На одном из колес редуктора моделировался эксплуатационный локальный дефект в виде скола зуба (рис. 2). Замеры проводились для каждого состояния (25%, 50%, 75% длины зуба и без зуба) в количестве 25 раз для накопления необходимого объема данных. Результаты, полученные при использовании серийных колес, приняты эталонными.

Спектр акустического сигнала при всей его информативности несет в себе большое количество значащих частотных составляющих от всех элементов исследуемого объекта, и сокращение их количества может привести к потере необходимой информации при диагностировании. Исходя из анализа ряда литературных источников [2, 3], наиболее важные данные об изменяющемся состоянии исследуемого объекта несут амплитуды следующих частотных составляющих анализируемого сигнала (рис. 3, а-б):

- низкочастотные составляющие, кратные частоте вращения элементов привода  $f_0$ ;
- высокочастотные составляющие с частотами пересопределения зубьев всех зубчатых пар  $f_z$ , а также на кратных им частотах;

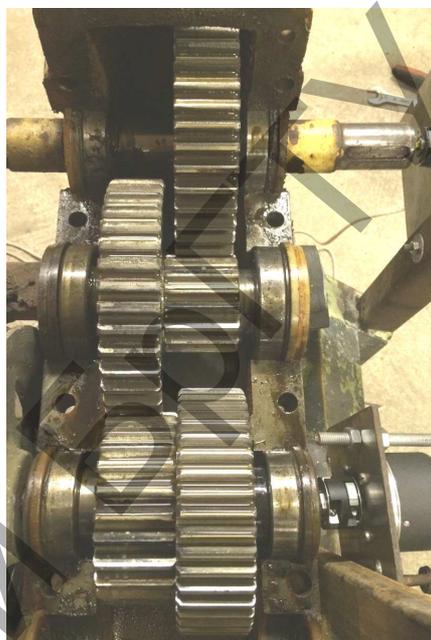


Рисунок 1 – Общий вид объекта исследования



Рисунок 2 – Общий вид исследуемой шестерни с локальным дефектом в виде скола зуба

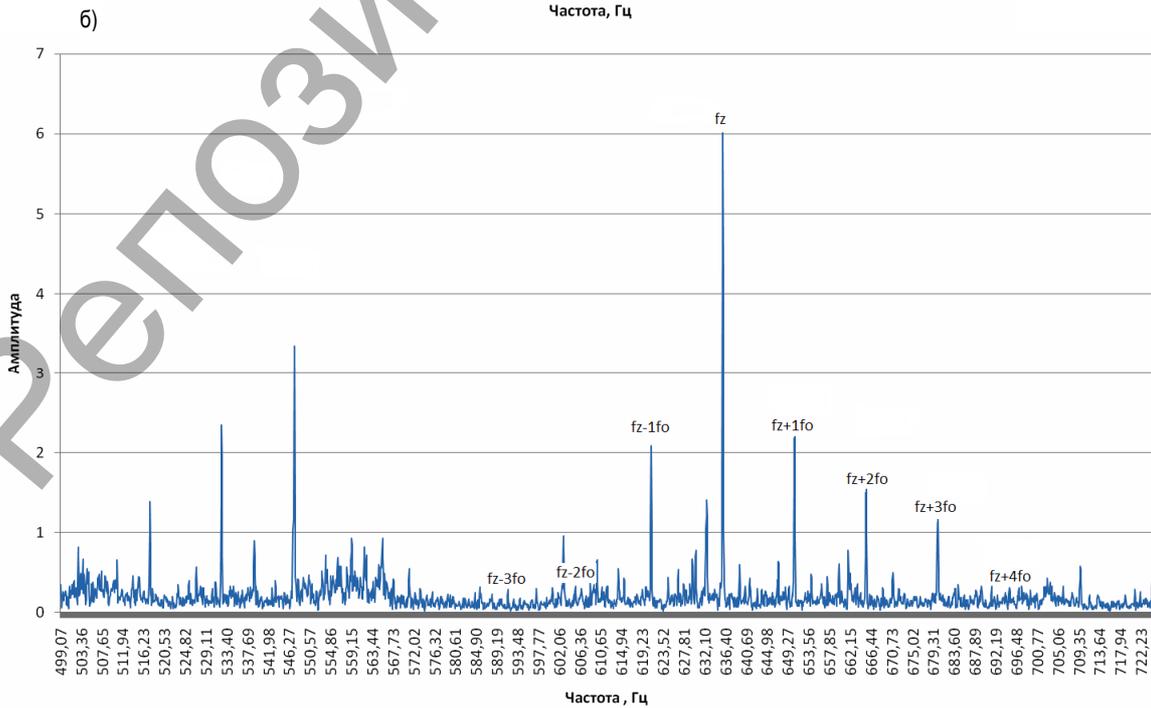
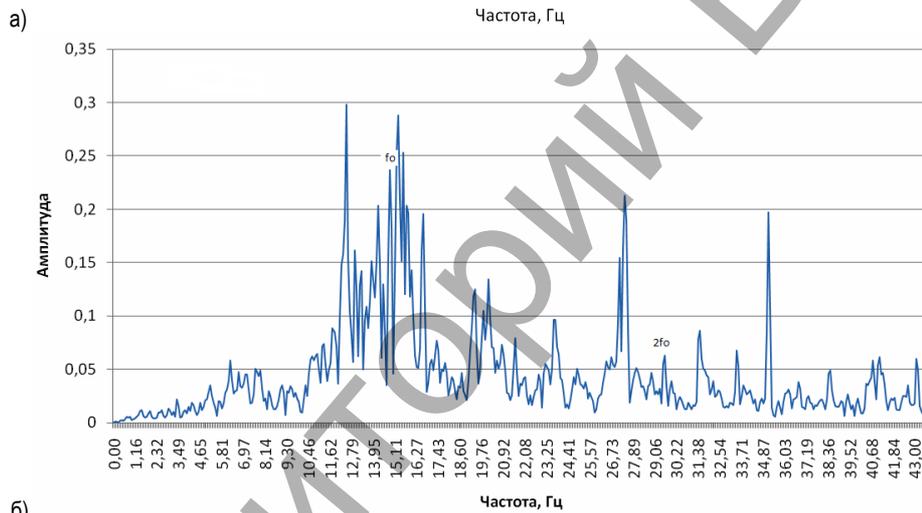
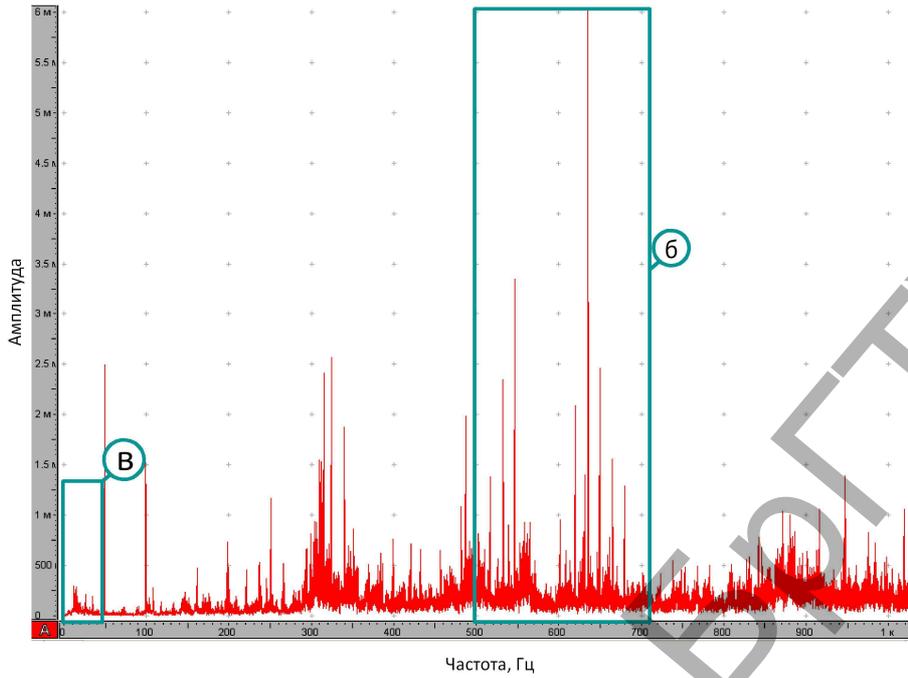
- составляющие колебаний с комбинированными частотами  $lf_z \pm nf_0$ , возникающими вследствие различного рода модуляций сигнала ( $l, n=0,5;1;1,5;2$  и т. д.).

Парфиевич Андрей Николаевич, м.т.н., аспирант кафедры технологии машиностроения Брестского государственного технического университета.

Драган Александр Вячеславович, к.т.н., декан машиностроительного факультета Брестского государственного технического университета.

Безобразов Сергей Валерьевич, к.т.н., доцент кафедры интеллектуальных информационных технологий Брестского государственного технического университета.

Беларусь, БрГТУ, 224017, г. Брест, ул. Московская, 267.



в)

i	Амплитуда гармоники на частоте											
	A(Foi)	A(Fzi)	A(Fzi + Foj)									
			j=-5	j=-4	j=-3	j=-2	j=-1	j=1	j=2	j=3	j=4	j=5
1	0,0485413	4,59366	8,43025	0,58346	0,39587	0,86169	1,23648	0,64686	0,68463	0,70603	0,39312	0,14736
2	0,06448099	1,13217	0,56403	0,28078	1,04942	0,43014	0,16943	0,9339	0,42863	0,30509	0,20358	0,57827
3	0,0116445	1,18538	1,14407	0,39607	0,48134	0,87824	0,48556	0,78388	0,75491	0,71907	0,50613	0,48093
4	0,02188766	0,28538	0,39918	0,17298	0,07535	0,16843	0,20025	0,14391	0,08442	0,13988	0,11881	0,07561
5	0,02194362	0,05892	0,08506	0,0525	0,05612	0,07108	0,04804	0,04921	0,03665	0,04362	0,02845	0,05261
г) Итого	0,16849806	7,25551	10,6226	1,48579	2,05809	2,40958	2,13975	2,55776	1,98925	1,9137	1,25009	1,33478

а) фрагмент спектра акустического сигнала исследуемого объекта; б) фрагмент спектра акустического сигнала в области оборотных частот  $f_0$  для вала II; в) фрагмент спектра акустического сигнала в области частот  $(f_z - 5f_0) - (f_z + 5f_0)$  шестерни  $Z_2$ ; г) экспериментальные данные, полученные с помощью функции комплекса «Анализ гармоник»

Рисунок 3 – Результат обработки спектра акустического сигнала с помощью функции аппаратно-программного комплекса «Анализ гармоник»

Определение этих компонентов «вручную» из чрезмерно насыщенного спектра акустического сигнала очень трудоемко, что привело к разработке и реализации в программной части комплекса новой функции «Анализ гармоник», позволяющей автоматически получать значения всех составляющих, формирующих диагностические признаки (рис. 3, г).

Полученный объем экспериментальных данных был разбит на 5 классов в зависимости от состояния зуба и применен при решении задачи классификации. В качестве классификатора была выбрана многослойная нейронная сеть с одним скрытым слоем, состоящим из нейронов Кохонена [4]. Структура нейронной сети приведена на рис. 4.

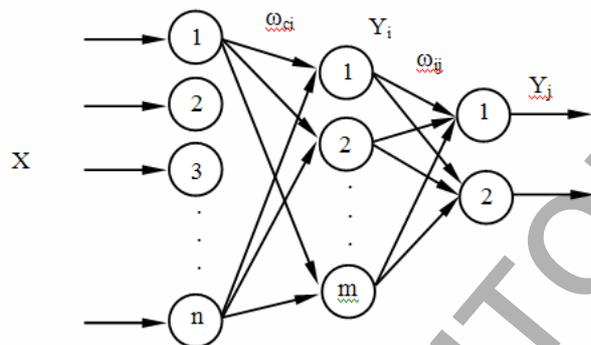


Рисунок 4 – Структура нейронной сети

Произведем детализацию предлагаемого классификатора. 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. 3, г).

Второй, скрытый, слой искусственной нейронной сети состоит из нейронов Кохонена. Слой Кохонена играет ключевую роль в классификации данных и осуществляет кластеризацию входного пространства 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 могут отличаться от разновидности задач, структуры данных и т. д. В нашем случае эксперименты показали хорошие результаты при количестве нейронов в скрытом слое равным  $m = 30$ . 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 исполь-

зуется Евклидово расстояние между входным и весовым векторами, определяемое следующим образом:

$$D_i = |X - \omega_i| = \sqrt{(X_1 - \omega_{i1})^2 + (X_2 - \omega_{i2})^2 + \dots + (X_c - \omega_{ic})^2}, \quad (1)$$

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 ИНС, при подаче входного образа активность нейрона-победителя принимается равной единице, а остальные нейроны «сбрасываются» в нуль [4–6]. Такое правило обучения известно под названием «победитель берет все» (winner-take-all) [4, 5].

Алгоритм обучения слоя Кохонена можно представить в виде следующей последовательности шагов:

1. Случайная инициализация весовых коэффициентов  $\omega_{ci}$  нейронов  $Y_i$  слоя Кохонена.
2. Распределение входного образа из обучающей выборки на нейронную сеть и вычисление следующих параметров:
  - вычисляется Евклидово расстояние между входным образом и весовыми векторами нейронных элементов слоя Кохонена:

$$D_i = |X - \omega_i| = \sqrt{(X_1 - \omega_{i1})^2 + (X_2 - \omega_{i2})^2 + \dots + (X_c - \omega_{ic})^2}; \quad (2)$$

- определяется нейронный элемент победитель с номером  $k$ :

$$D_k = \min_j D_j; \quad (4)$$

- производится модификация весовых коэффициентов нейрона-победителя в соответствии со следующими выражениями:

$$\omega_{ck}(t+1) = \omega_{ck}(t) + \gamma(X_c - \omega_{ck}(t)), \quad (5)$$

если активность выходного нейрона соответствует классу подаваемых на входной слой данных. В противном случае:

$$\omega_{ck}(t+1) = \omega_{ck}(t) - \gamma(X_c - \omega_{ck}(t)). \quad (6)$$

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

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

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

Выходные данные по итогам обучения и классификации представляются в виде матрицы размером  $5 \times 5$ , каждый столбец и строка которой соответствуют определенному состоянию исследуемого зубчатого колеса: 1-й класс – эталонная исследуемая шестерня с целым зубом, 2-й класс – исследуемая шестерня с локальным дефектом в виде 25% скола зуба, 3-й класс – исследуемая шестерня с локальным

дефектом в виде 50% скола зуба, 4-й класс – исследуемая шестерня с локальным дефектом в виде 75% скола зуба, 5-й класс – исследуемая шестерня с локальным дефектом в виде отсутствия зуба.

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% (рис. 5).

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 равно нулю). Как видно из рис. 6, 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. Данный недостаток может быть устранен изменением количества нейронов в скрытом слое или увеличением размерности обучающей выборки.

Output Class	1	2	3	4	5	Accuracy
1	8 15.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	1 2.0%	10 19.6%	0 0.0%	0 0.0%	3 5.9%	71.4% 28.6%
3	0 0.0%	0 0.0%	11 21.6%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	10 19.6%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 15.7%	100% 0.0%
	88.9% 11.1%	100% 0.0%	100% 0.0%	100% 0.0%	72.7% 27.3%	92.2% 7.8%
Target Class	1	2	3	4	5	

Рисунок 5 – Результаты решения задачи классификации

Таким образом, разработанная методика диагностики элементов исследуемого объекта с использованием нейросетевых моделей показала свою достаточно высокую эффективность и точность. Данный подход в исследовании многоскоростных зубчатых приводов позволит сформулировать методику их диагностирования, состоящую из следующих этапов: выделение информативных частот и оценка их значимости, создание вектора диагностических признаков и оценка технического состояния исследуемого объекта на основе применения теории распознавания образов. Это даст возможность мини-

мизировать участие человека непосредственно при процедуре диагностирования, что в свою очередь повысит ее объективность. 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.

Output Class	1	2	3	4	5	Accuracy
1	15 20.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	15 20.0%	0 0.0%	0 0.0%	1 1.3%	93.8% 6.3%
3	0 0.0%	0 0.0%	15 20.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	15 20.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	14 18.7%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	93.3% 6.7%	98.7% 1.3%
Target Class	1	2	3	4	5	

Рисунок 6 – Результаты обучения нейросетевого классификатора

#### СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Драган, А.В. Новые аппаратно-программные средства для исследования и диагностики механических систем / А.В. Драган, И.П. Стецко, Д.А. Ромашко, Н.В. Левкович // Вестник Брестского государственного технического университета. – 2006. – № 4. – С. 17–26.
2. Мониторинг и диагностика роторных машин по вибрации / А.В. Барков, Н.А. Баркова, А.Ю. Азовцев. – [Электронный ресурс]. – Режим доступа: <http://www.vibrotek.com/russian/articles/book/index.htm>.
3. Anil, Jacob Диагностирование зубчатой передачи с помощью нового метода контроля состояния роторного оборудования; перевод с англ. / Jacob Anil, Dr. Y. I. Sharaf-Eldeen. – [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. – N 43. – 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.

Материал поступил в редакцию 14.12.2016

#### PARFIYEVICH A.N., DRAGAN A.V., BEZOBRAZOV S.V. Acoustic diagnostics of multishaft gear drives on the basis of use of artificial neural networks

The article describes the experience of using the developed technique based on the use of artificial neural networks and monitoring the technical condition of the gears on the informative frequency component of the acoustic signal as an example of horizontal gear unit with spur gear. It is shown that a sufficiently high detection efficiency and accuracy of the local multi-shaft defect gear drive during CIP diagnosis.