

## АКУСТИЧЕСКАЯ ДИАГНОСТИКА ЛОКАЛЬНЫХ ПОВРЕЖДЕНИЙ ПРЯМОЗУБЫХ ЦИЛИНДРИЧЕСКИХ КОЛЁС В СОСТАВЕ МНОГОВАЛЬНОГО ПРИВОДА С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ

© 2020

- А. Н. Парфиевич** старший преподаватель кафедры «Машиностроение и эксплуатация автомобилей»;  
Брестский государственный технический университет,  
г. Брест, Республика Беларусь;  
[parfievichand@gmail.com](mailto:parfievichand@gmail.com)
- А. В. Драган** кандидат технических наук, доцент, доцент кафедры «Машиностроение и эксплуатация автомобилей»;  
Брестский государственный технический университет,  
г. Брест, Республика Беларусь;  
[draganav@mail.ru](mailto:draganav@mail.ru)
- В. А. Сокол** старший преподаватель кафедры «Машиностроение и эксплуатация автомобилей»;  
Брестский государственный технический университет,  
г. Брест, Республика Беларусь;  
[sokolva@mail.ru](mailto:sokolva@mail.ru)

В ходе акустической диагностики многовальных приводов на основе цилиндрических прямозубых колёс специалист-диагност сталкивается с проблемой чрезмерной насыщенности анализируемого сигнала различного рода частотными составляющими. Сокращение объёма анализируемых данных может привести к потере важной диагностической информации. Поэтому для того, чтобы снизить нагрузку на диагноста и при этом сохранить точность диагностики локального повреждения зуба зубчатого колеса, необходимо выявить перечень информативных частотных составляющих. Они должны реагировать на появление данного дефекта в зоне зубозацепления и иметь достаточно хорошо изученную математическую основу, что даст возможность использовать методы их автоматического определения. Полученный цифровой образ позволит применить для его обработки искусственные нейросетевые модели.

*Эвольвентные цилиндрические прямозубые колёса; локальный дефект; акустический сигнал; нейросетевая модель.*

---

**Цитирование:** Парфиевич А.Н., Драган А.В., Сокол В.А. Акустическая диагностика локальных повреждений прямозубых цилиндрических колёс в составе многовального привода с использованием нейросетевых моделей // Вестник Самарского университета. Аэрокосмическая техника, технологии и машиностроение. 2020. Т. 19, № 2. С. 99-106. DOI: 10.18287/2541-7533-2020-19-2-99-106

### Введение

В процессе эксплуатации многовальных приводов на основе цилиндрических прямозубых передач при безработных методах диагностики специалист-диагност сталкивается с большим объёмом информации, которую необходимо проанализировать. При этом каждый элемент диагностируемого привода вносит свой вклад в формирование итогового акустического сигнала. Скорость постановки диагноза будет зависеть при этом от функциональных возможностей используемого анализатора и опытности специалиста-диагноста. Сократить объём анализируемой информации сложно, т.к. это может привести к утрате важной диагностической информации. Но в рамках анализируемого акустического сигнала представляется возможным определить перечень информативных частотных составляющих, проследив за изменением которых можно выявить дефектное зубчатое колесо. Для повышения объективности процедуры диагностирования возможно рассмотреть синтез одного из классических методов обработки

акустического сигнала и одного из современных методов математической обработки поступающей информации.

### Постановка задачи

В любом техническом состоянии прямозубое зубчатое колесо в составе многовального привода всегда генерирует различного рода колебания, связанные чаще всего с динамическими явлениями непосредственно в самом зубчатом зацеплении, а также погрешностями изготовления и монтажа применяемых зубчатых колёс [1 – 4].

Исходя из этого, в спектре акустического сигнала можно выделить определённый перечень информативных частотных составляющих:

– частотные составляющие, кратные частоте вращения элементов привода  $f_{ep}$ :

$$f_{epi} = k \frac{n_i}{60}, \quad n_i = n_{i-1} \frac{z_{i-1}}{z_i}, \quad (1)$$

где  $n_i$  – частота вращения  $i$ -го вала;  $z_{i-1}$ ,  $z_i$  – числа зубьев ведущего колеса предыдущего вала и ведомого колеса  $i$ -го вала;  $k$  – коэффициент, принимаемый равным 1, 2, 3 и т.д.;

– частотные составляющие, соответствующие частоте пересопряжения зубьев всех зубчатых пар  $f_z$ , а также на кратных им частотах:

$$f_z = z_1 f_{1ep} = z_2 f_{2ep}, \quad (2)$$

где  $z_1, z_2$  – числа зубьев;  $f_{1ep}, f_{2ep}$  – частоты вращения сопряжённых колёс;

– частотные составляющие, соответствующие колебаниям с комбинированными частотами  $mf_z \pm nf_o$ , возникающими вследствие различного рода модуляций сигнала ( $m, n = 0, 5; 1; 1, 5; 2$  и т.д.). Как правило, они появляются в окрестности  $f_{1z}$  и кратным ей гармоникам  $k f_{1z}$ , расположены симметрично относительно них и отстоят друг от друга на величину  $f_{ep}$ .

Математический аппарат получения данного перечня информативных частотных составляющих достаточно изучен и поэтому вычисление их было автоматизировано и реализовано в рамках используемого диагностического комплекса. Это позволило сократить время обработки поступающего объёма информации с диагностируемого привода и снизить нагрузку на специалиста-диагноста.

Эффективность диагностики и мониторинга текущего состояния исследуемого объекта зависит от числа составляющих анализируемого сигнала, доступных для измерения и его анализа с представлением в виде спектра посредством преобразования Фурье. 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 (рис. 1). Однако оценивая результаты собственных экспериментальных исследований и представленную в литературных источниках информацию, можно сделать вывод о недостаточности такого разрешения по частоте. В связи с этим в Брестском государственном техническом университете совместно со специалистами Белорусского государственного университета создан и используется в экспериментальных исследованиях аппаратно-программный комплекс, который позволяет получать спектральные характеристики с

количеством линий до 524000. Это даёт 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, можно зафиксировать мельчайшие по амплитуде частотные составляющие во всех частотных диапазонах. Аппаратно-программный комплекс позволяет с высокой степенью точности производить снятие информации об акустических процессах, возникающих в процессе эксплуатации многозубчатых зубчатых приводов [5].

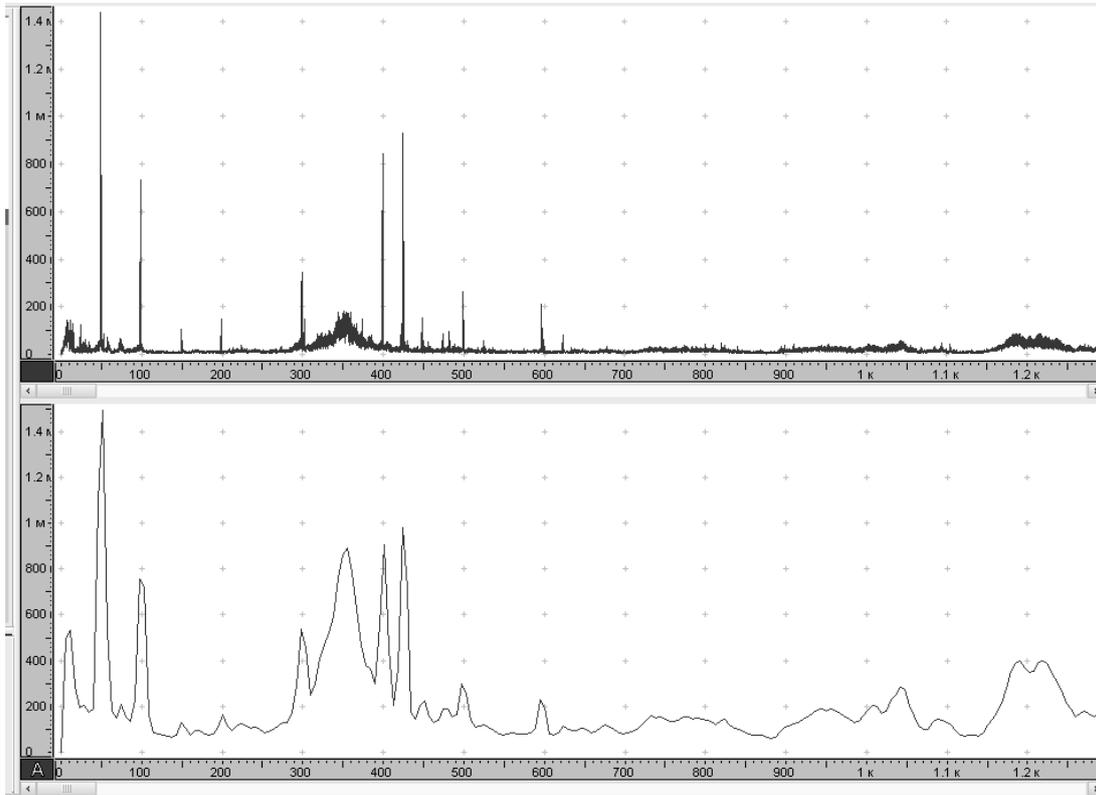


Рис. 1. Фрагменты спектров акустического сигнала многозубчатого зубчатого привода при использовании окна Ханна и числа линий спектра 524000 (сверху) и 8000 (снизу)

### Объект экспериментальных исследований

Одним из объектов экспериментальных исследований, в ходе которых был предложен синтез классического метода обработки акустического сигнала и одного из современных методов математической обработки поступающей информации, стал трёхосный горизонтальный редуктор с цилиндрическими прямозубыми колёсами. На зубчатом колесе  $Z = 40$  моделировался локальный дефект в виде отсутствия части зуба по его длине.

В качестве источника информации использовался акустический сигнал, сформированный аппаратно-программным комплексом на основе данных, полученных с измерительного микрофона с капсулом M101, установленного на расстоянии 200 мм от корпуса коробки скоростей в горизонтальной плоскости.

Одновременное применение преобразователей угловых перемещений на входном и выходном валах привода даёт возможность с высокой точностью определять частоты вращения входного и выходного вала и частоты характерных составляющих на спектре анализируемого сигнала. Испытания проводились как без нагрузки, так и под нагрузкой.

### Результаты измерений и обработки данных

Принимая во внимание большое число анализируемых компонентов в акустическом сигнале, посредством функции автоматического их определения был сформирован числовой образ (30 по каждому из состояний) каждого из классов состояний зуба эвольвентного прямозубого колеса, входящего в состав диагностируемого привода (таблица).

Таблица. Классификация состояния зуба экспериментальной шестерни  $Z = 40$

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

После проведения анализа классических архитектур искусственных нейронных сетей для решения поставленной задачи было выявлено, что наиболее подходящей является нейросетевая модель векторного квантования на основе нейронов Кохонена. Она характеризуется малым объёмом обучающейся выборки, что позволит обучить её на ограниченном объёме данных для рассматриваемого случая.

Предлагаемая структура нейросетевой модели состоит из трёх слоёв (рис. 2):

- первый слой формируется на основе данных, получаемых посредством функции автоматического определения информативных частотных составляющих, и предназначен для распределения входных сигналов на нейроны Кохонена скрытого слоя;
- второй слой 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;
- третий слой осуществляет отображение количества диагностируемых классов (таблица).

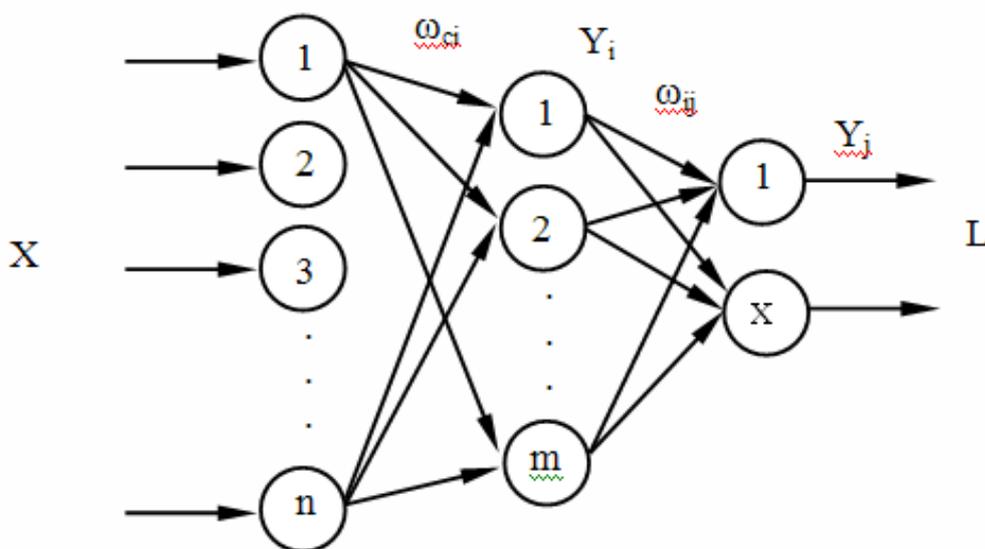


Рис. 2. Условное отображение структуры нейросетевой модели, построенной на нейронах Кохонена

Для использования нейросетевого классификатора производилось его обучение на основе сформированных данных, проводимое с помощью «учителя» [6 – 8]. Это необходимо для того, чтобы в процессе обучения можно было жёстко «связать» каждый входной набор данных с целевым набором, представляющим собой требуемый выход.

Результат обучения может быть представлен в виде матрицы неточностей – это матрица размера  $N$  на  $N$ , где  $N$  – это количество классов (рис. 3). Столбцы этой матрицы резервируются за экспертными решениями, а строки – за решениями классификатора. Когда классифицируются данные из тестовой выборки, им инкрементируется число, стоящее на пересечении строки класса, который вернул классификатор, и столбца класса, к которому действительно относится образ.

Классы выходных данных	1	24 20.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	20 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	4 3.3%	24 20.0%	0 0.0%	0 0.0%	85.7% 14.3%
	4	0 0.0%	0 0.0%	0 0.0%	24 20.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	24 20.0%	100% 0.0%
		100% 0.0%	33.3% 16.7%	100% 0.0%	100% 0.0%	100% 0.0%	96.7% 3.3%
	1	2	3	4	5	Классы классифицируемых данных	

Рис. 3. Матрица неточностей обучения нейросетевой модели векторного квантования

Из представленных выше результатов видно, что общая точность классификации разработанной нейросетевой модели векторного квантования составляет 96,7%. Причём точность классификации 1-го, 3-го, 4-го и 5-го классов составила 20%, а точность классификации 2-го класса – 16,7% (рис. 3). Относительно невысокая точность классификации второго класса связана со средней квадратичной ошибкой обучения нейронной сети, которая составила 0,0133, т.е. нейронная сеть не смогла обучиться полностью (идеальным является значение средней квадратичной ошибки равное нулю). Как видно из рис. 3, в процессе обучения нейронная сеть не смогла корректно научиться классифицировать образы из 2-го класса, где она показала точность классификации равной 96,7%, что и отразилось на группировании тестового набора данных (рис. 4). Данный недостаток может быть устранён изменением количества нейронов в скрытом слое или увеличением размерности обучающей выборки.

Классы выходных данных	1	6 20.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	5 16.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	1 3.3%	6 20.0%	0 0.0%	0 0.0%	85.7% 14.3%
	4	0 0.0%	0 0.0%	0 0.0%	6 20.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	6 20.0%	100% 0.0%
			100% 0.0%	83.3% 16.7%	100% 0.0%	100% 0.0%	100% 0.0%
		1	2	3	4	5	
		Классы классифицируемых данных					

Рис. 4. Матрица неточностей обработки нейросетевой моделью векторного квантования тестируемой выборки

После определения структуры нейросетевой модели и метода обучения алгоритм её работы можно представить в следующем виде:

1. Ссылка на сформированный блок данных, согласно которому происходит классификация рассматриваемых состояний анализируемого колеса.
2. Нормализация всех входных данных.
3. Разбивка каждого блока, характеризующего состояние анализируемого колеса, на обучающую и тестируемую выборку.
4. Описание структуры используемой нейросетевой модели: количество входных нейронов, количество скрытых нейронов (определяется экспериментально и зависит от типа решаемой задачи), количество выходных нейронов.
5. Определение на основе экспериментальных данных минимального значения ошибки обучения, дающего максимальный результат при классификации тестируемой выборки.
6. Предварительная проверка обученной нейросетевой модели на выбранной тестируемой выборке.

### Заключение

Таким образом, использование в качестве инструмента анализа поступающей информации искусственных нейронных сетей при диагностировании локальных повреждений зуба в виде частичной потери его рабочей поверхности показало свою достаточно высокую эффективность и точность. Предложенная структура нейросетевого классификатора характеризуется малым объемом обучающей выборки и отличается высоким уровнем точности кластеризации при анализе акустического сигнала, что позволяет использовать её для такого класса объектов как зубчатые приводы.

### Библиографический список

1. Генкин М.Д. Вопросы акустической диагностики // В кн.: «Методы виброизоляции машин и присоединенных конструкций». М.: Наука, 1975. С. 67-91.
2. Попков В.И., Мышинский Э.Л., Попков О.И. Виброакустическая диагностика в судостроении. Л.: Судостроение, 1989. 256 с.
3. Русов В.А. Диагностика дефектов вращающегося оборудования по вибрационным сигналам. Пермь: Вибро-Центр, 2012. 252 с.
4. Ширман А.Р., Соловьев А.Б. Практическая вибродиагностика и мониторинг состояния механического оборудования. М.: Наука, 1996. 276 с.
5. 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.
6. Головкин В.А. Нейрокомпьютеры и их применение. Кн. 4. Нейронные сети: обучение, организация, применение. М.: ИПРЖР, 2001. 256 с.
7. Комашинский В.И., Смирнов Д.А. Нейронные сети и их применение в системах управления и связи. М.: Горячая линия-Телеком, 2003. 94 с.
8. Kohonen T. Self-organized formation of topologically correct feature maps // Biological Cybernetics. 1982. V. 43, Iss. 1. P. 59-69. DOI: 10.1007/bf00337288

## ACOUSTIC DIAGNOSTICS OF LOCAL DAMAGES OF SPUR WHEELS IN MULTI-SHAFT DRIVE USING NEURAL NETWORK MODELS

© 2020

- A. N. Parfiyevich** Senior Lecturer of the Department “Mechanical Engineering and Car Operation”; Brest State Technical University, Brest, Republic of Belarus;  
[parfiyevichand@gmail.com](mailto:parfiyevichand@gmail.com)
- A. V. Dragan** Candidate of Science (Engineering), Associate Professor, Associate Professor of the Department “Mechanical Engineering and Car Operation”; Brest State Technical University, Brest, Republic of Belarus;  
[draganav@mail.ru](mailto:draganav@mail.ru)
- V. A. Sokol** Senior Lecturer of the Department “Mechanical Engineering and Car Operation”; Brest State Technical University, Brest, Republic of Belarus;  
[sokolva@mail.ru](mailto:sokolva@mail.ru)

In the course of acoustic diagnosis of multi-shaft drives on the basis of spur wheels, the diagnostician is faced with the problem of excessive saturation of the analyzed signal with various kinds of frequency components. Reducing the amount of data analyzed may result in the loss of important diagnostic information. Therefore, in order to make the diagnostician's work easier and at the same time maintain the accuracy of the diagnosed local damage to the gear tooth it is necessary to identify the list of informative frequency components. They should respond to the occurrence of this defect in the tooth-contact zone and have a sufficiently thoroughly studied mathematical framework that will make it possible to use methods of their automatic determination. The obtained digital image will allow using artificial neural network models for its processing.

*Involute spur wheels; local defect; acoustic signal; neural network model.*

---

*Citation:* Parfiyevich A.N., Dragan A.V., Sokol V.A. Acoustic diagnostics of local damages of spur wheels in multi-shaft drive using neural network models. *Vestnik of Samara University. Aerospace and Mechanical Engineering*. 2020. V. 19, no. 2. P. 99-106. DOI: 10.18287/2541-7533-2020-19-2-99-106

## References

1. Genkin M.D. Voprosy akusticheskoy diagnostiki. *V kn.: «Metody vibroizolyatsii mashin i prisoedinennykh konstruktsiy»*. Moscow: Nauka Publ., 1975. P. 67-91.
2. Popkov V.I., Myshinskiy E.L., Popkov O.I. *Vibroakusticheskaya diagnostika v sudostroenii* [Vibroacoustic diagnostics in shipbuilding]. Leningrad: Sudostroenie Publ., 1989. 256 p.
3. Rusov V.A. *Diagnostika defektov vrashchayushchegosya oborudovaniya po vibratsionnym signalam* [Diagnostics of defects of rotating equipment by vibration signals]. Perm: Vibro-Tsentr Publ., 2012. 252 p.
4. Shirman A.R., Solov'ev A.B. *Prakticheskaya vibrodiagnostika i monitoring sostoyaniya mekhanicheskogo oborudovaniya* [Practical vibration-based diagnostics and monitoring of the condition of mechanical equipment]. Moscow: Nauka Publ., 1996. 276 p.
5. Dragan A.V., Stetsko I.P., Romashko D.A., Levkovich N.V. New hardware and software tools for research and diagnostics of mechanical systems. *Vestnik Brestskogo Gosudarstvennogo Tekhnicheskogo Universiteta*. 2006. No. 4. P. 17-26. (In Russ.)
6. Golovko V.A. *Neyrokompyutery i ikh primeneniye. Kn. 4. Neyronnye seti: obucheniye, organizatsiya, primeneniye* [Neural networks: training, organization, application]. Moscow: IPRZhR Publ., 2001. 256 p.
7. Komashinskiy V.I., Smirnov D.A. *Neyronnye seti i ikh primeneniye v sistemakh upravleniya i svyazi* [Neural networks and their application in control and communication systems]. Moscow: Goryachaya Liniya-Telekom Publ., 2003. 94 p.
8. Kohonen T. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*. 1982. V. 43, Iss. 1. P. 59-69. DOI: 10.1007/bf00337288