

# ДИАГНОСТИКА НЕИСПРАВНОСТЕЙ ПОДШИПНИКОВ КАЧЕНИЯ С ИСПОЛЬЗОВАНИЕМ ПИКОВ СПЕКТРА И НЕЙРОННЫХ СЕТЕЙ

© 2022 О.Л. Ибряева, М.Н. Мохаммад

*Южно-Уральский государственный университет*

*(454080 Челябинск, пр. им. В.И. Ленина, д. 76)*

*E-mail: ibriaevaol@susu.ru, mohnoufl@gmail.com*

Поступила в редакцию: 20.04.2022

Важнейшими составляющими деталей машин являются подшипники качения, контроль за состоянием которых необходим, так как возможные дефекты в их конструкции могут привести к неправильной работе или общему выходу машин из строя. Современные решения по диагностике неисправностей подшипников обычно используют сложные процессы извлечения признаков, например, построение их изображений спектра Гильберта и дальнейшую мощную нейронную сеть для их классификации. В этой статье мы предлагаем простой, но, тем не менее, эффективный алгоритм решения данной задачи. Для выделения признаков из сигнала мы делим спектр сигнала на равные подинтервалы и находим максимум амплитуды и соответствующее значение частоты в каждом из них. В статье, на основе метода t-SNE, показано, что выделенные таким образом признаки, несмотря на свой небольшой размер, хорошо представляют разного типа сигналы. На втором этапе выделенные признаки поступают на вход простой нейронной сети классификатора. Предложенный метод обладает простотой в вычислительном отношении, как на этапе выделения признаков, так и на этапе обучения нейронной сети. Несмотря на это, метод дает 100% точность для всех типов сигналов на коротких данных из набора данных IMS.

*Ключевые слова: диагностика неисправностей, подшипник качения, спектр сигнала, нейронные сети, t-SNE.*

## ОБРАЗЕЦ ЦИТИРОВАНИЯ

Ибряева О.Л., Мохаммад М.Н. Диагностика неисправностей подшипников качения с использованием пиков спектра и нейронных сетей // Вестник ЮУрГУ. Серия: Вычислительная математика и информатика. 2022. Т. 11, № 2. С. 59–71. DOI: 10.14529/cmse220205.

## Введение

Подшипники качения играют ключевую роль практически в любой системе с механизмом вращения, такой как корабли, станы холодной прокатки и многие другие [1]. Ввиду чрезвычайной важности обнаружения неисправностей подшипников в области машиностроения к настоящему времени существует множество подходов к их диагностике. В погоне за большей точностью современные подходы часто используют вычислительно затратные методы, например, получают признаки с помощью построения спектральных изображений, на которых затем обучают мощную сверточную нейронную сеть [2, 3].

Целью настоящей статьи явилась разработка вычислительно простого, но эффективного метода диагностики подшипников качения, который основан на применении быстрого преобразования Фурье (БПФ) к вибрационным сигналам подшипника. Извлеченные из спектра сигнала признаки используются далее в качестве входных данных нейронной сети для определения типа неисправности. Репрезентативность выделенных признаков показана с помощью метода t-Distributed Stochastic Neighbor (t-SNE) [4]. Предложенный метод протестирован на эталонном наборе данных IMS [5] для диагностики подшипников и по-

казал высокую эффективность. Дополнительные преимущества нашего нового метода заключаются в простой процедуре выделения признаков, их небольшом количестве и простой архитектуре нейронной сети.

Основные ключевые моменты данной статьи:

- Разработан новый подход к выделению признаков из вибрационных сигналов подшипника.
- Отличительной особенностью нового метода является простота процесса извлечения признаков.
- Новый метод использует небольшое количество признаков и простую нейронную сеть по сравнению с другими современными подходами.
- Эксперименты, проведенные на наборе данных IMS, доказывают высокую эффективность метода.

Структура данной работы такова. Раздел 1 содержит обзор аналогичных работ. В разделе 2 описана экспериментальная установка и набор данных IMS. Раздел 3 содержит описание процесса извлечения признаков из вибрационных сигналов подшипника и структуры нейронной сети. Экспериментальные исследования представлены в разделе 4. Последний раздел содержит заключение и выводы исследования.

## 1. Обзор аналогов

По сути, диагностику неисправностей подшипников качения можно рассматривать как проблему распознавания образов, связанную с состоянием вращающегося оборудования. Обычно метод диагностики неисправностей состоит из двух ключевых этапов: извлечение признаков и классификация неисправностей.

Обработка сигналов на основе вибрации является одним из наиболее часто используемых методов на первом этапе, обычно с использованием анализа во временной области, частотной области или частотно-временной области. Анализ в частотной области обычно производится с помощью быстрого преобразования Фурье (БПФ), а также методов на основе БПФ, методов спектрального анализа [6] и т. д. Анализ во временной области рассчитывает статистические параметры, такие как среднеквадратичное значение виброускорения, эксцесс, ударные импульсы [7] и т. д. Частотно-временной анализ используется для расширения возможностей анализа в частотной области на нестационарные вибрационные сигналы. и включает в себя такие методы, как краткосрочное преобразование Фурье [8], вейвлет-преобразование [9], разложение по эмпирическим модам преобразования Гильберта—Хуанга [10] и т. д.

На втором этапе извлеченные признаки используются в качестве входных данных для методов машинного обучения с целью распознавания ошибок. Среди этих методов есть метод k-NN, метод опорных векторов и методы на основе дерева решений, но, конечно, преобладают нейронные сети, особенно сверточные и рекуррентные нейронные сети [11–13]. Например, Лю в [14] предложил систему диагностики неисправностей подшипников качения с рекуррентной нейронной сетью (RNN) и автоматическим кодировщиком. В работе [15] представлен метод, использующий разложение по вариационным модам на английском языке — Variational Mode Decomposition (VMD) и глубокие сверточные нейронные сети для выполнения классификации неисправностей подшипников качения в ветряных турбинах.

В целом, в диагностике неисправностей подшипников наблюдается тенденция к более сложным и глубоким моделям машинного обучения. Но глубокое обучение обнажает про-

блемы большого размера выборки и длительного времени обучения, а в реальных условиях работы количество доступных данных с помеченными ошибками относительно невелико, поэтому модель сложной архитектуры с хорошей обобщающей способностью и высокой точностью трудно обучить. Некоторые исследователи уже говорят о необходимости других, более простых и прикладных методов [16–18].

## 2. Описание набора данных

Для проверки работоспособности предлагаемого метода в данной статье используются экспериментальные данные IMS (Intelligent Maintenance Systems) [5], представленные Центром интеллектуальных сервисных систем Университета Цинциннати. Экспериментальная установка представлена на рис. 1. На валу были установлены четыре двухрядных подшипника Rexnord ZA-2115 с двумя акселерометрами PCB 353B33 на каждом. Скорость вращения вала поддерживалась постоянной на уровне 2000 оборотов в минуту. Он приводился в движение двигателем переменного тока, который был соединен с валом фрикционными ремнями. К подшипникам и валу с помощью пружинного механизма добавлялась нагрузка в 6000 фунтов. Частота дискретизации была установлена равной 20480 Гц. После вращения более чем на 100 миллионов оборотов в системе проявились такие неисправности подшипников, как дефект внутреннего кольца, внешнего кольца и шарика.

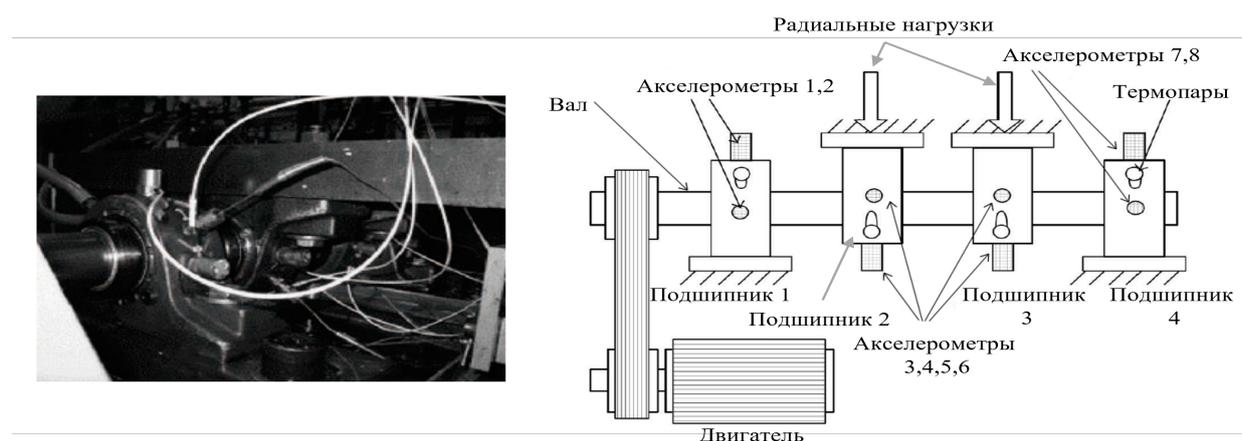
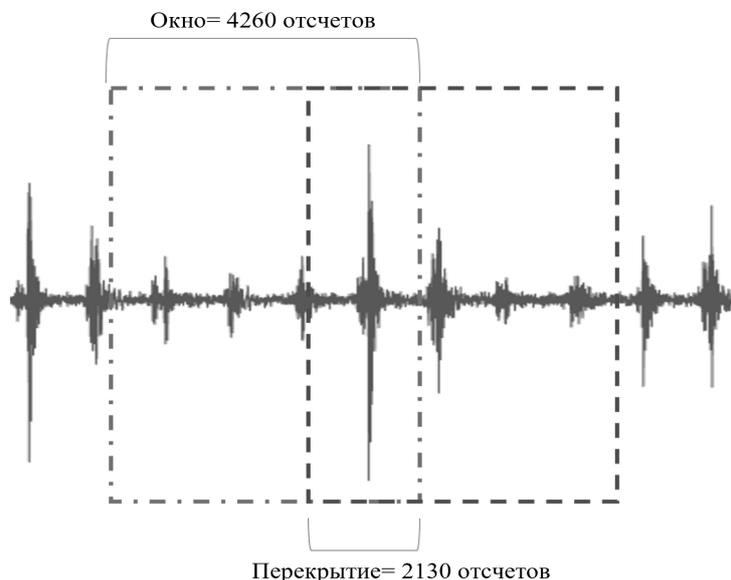


Рис. 1. Тестовая платформа IMS

IMS содержит наборы вибрационных сигналов подшипника с появившимися дефектами. Каждый набор содержит все записи от состояния исправного подшипника до его поломки. Мы рассмотрели сигналы каждого типа продолжительностью 20 секунд, как это было сделано в работе [19]. Для сигналов, отвечающих нормальному состоянию подшипника, мы взяли первые 20 секунд из набора данных для подшипника 1, когда он (как и все подшипники) был еще исправен. Последние 20 секунд записи для того же подшипника уже соответствуют его дефекту внутреннего кольца. Для сигнала с дефектом шарика были выбраны последние 20 секунд записи для подшипника 4. Наконец, запись с 2004-04-17 21:52:55 до 2004-04-18 01:02:55 с подшипника 3 содержит данные с дефектом внешнего кольца.

Использование всего 20 секунд данных каждого типа сигналов усложняет задачу их классификации, но является важным для практики, т.к. в реальных условиях, как правило, у нас очень мало образцов дефектных сигналов.

Для расширения данных сигналы вибрации были сегментированы на перекрывающиеся кадры по 4260 отсчетов, что эквивалентно  $(4260)/20480 = 0.208$  секунды, с процентом перекрытия 50%, т. е. 2130 отсчетов, как показано на рис. 2. В табл. 1 представлены классы сигналов набора данных IMS и количество образцов в каждом.



**Рис. 2.** Сегментация сигнала

**Таблица 1.** Классы набора данных IMS

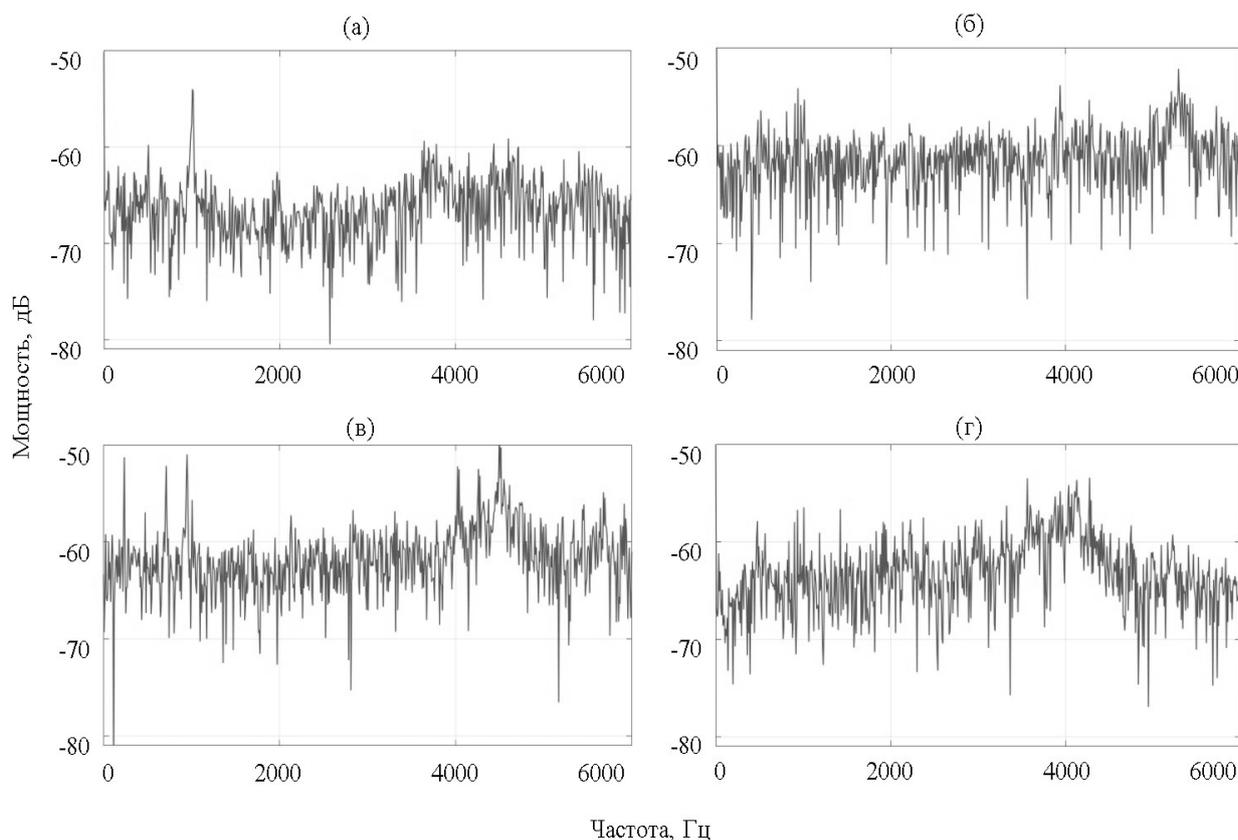
Класс	Тип дефекта	Число образцов в обучающей выборке	Число образцов в тестовой выборке
1	нет	134	56
2	дефект внутреннего кольца	134	56
3	дефект внешнего кольца	134	56
4	дефект шарика	134	56

### 3. Предлагаемый метод

Предлагаемое решение для классификации типов дефектов подшипников качения основано на нахождении пиков спектра сигнала и дальнейшем использовании выделенных признаков на входе нейронной сети. В этом разделе мы опишем оба этих этапа.

### 3.1. Извлечение признаков

На рис. 3 приведены примеры спектров сигналов разного типа. Можно видеть, что сигналы разного типа имеют существенно разные спектральные формы. Преобладающие спектральные компоненты каждого типа сигнала расположены в разных частотных диапазонах.



**Рис. 3.** Спектр различных сигналов; а) нормальный; б) дефект внутреннего кольца; в) дефект внешнего кольца; г) дефект шарика

Наш метод выделения признаков основан на этой особенности сигналов. Мы разделяем ось частот на равные интервалы и внутри каждого ищем частоту с максимальным значением амплитуды. Спектр сигнала при этом предварительно сглажен.

Извлекаемые признаки представляют собой два вектора: первый содержит значения частот с максимальной амплитудой в каждом частичном интервале, второй вектор содержит значения этих амплитуд, другими словами, признаки представляют собой пары  $(x, y) \in R^{N \times 2}$ , где  $N$  — количество интервалов.

Мы поделили весь интервал частот в спектре от 0 до 10240 Гц (половина частоты дискретизации) на  $N = 106$  равных интервалов, каждый из которых имеет длину примерно 100 Гц (рис. 4). Таким образом, каждому образцу сигнала из табл. 1 мы поставили в соответствие два 106 мерных вектора (значений частот и амплитуд), вычисленные по его спектру.

Чтобы проверить, что извлеченные признаки адекватно представляют объекты различных классов, мы использовали метод t-SNE [4], который позволяет нам отобразить точки из многомерного пространства в трехмерное и посмотреть на их расположение в пространстве.

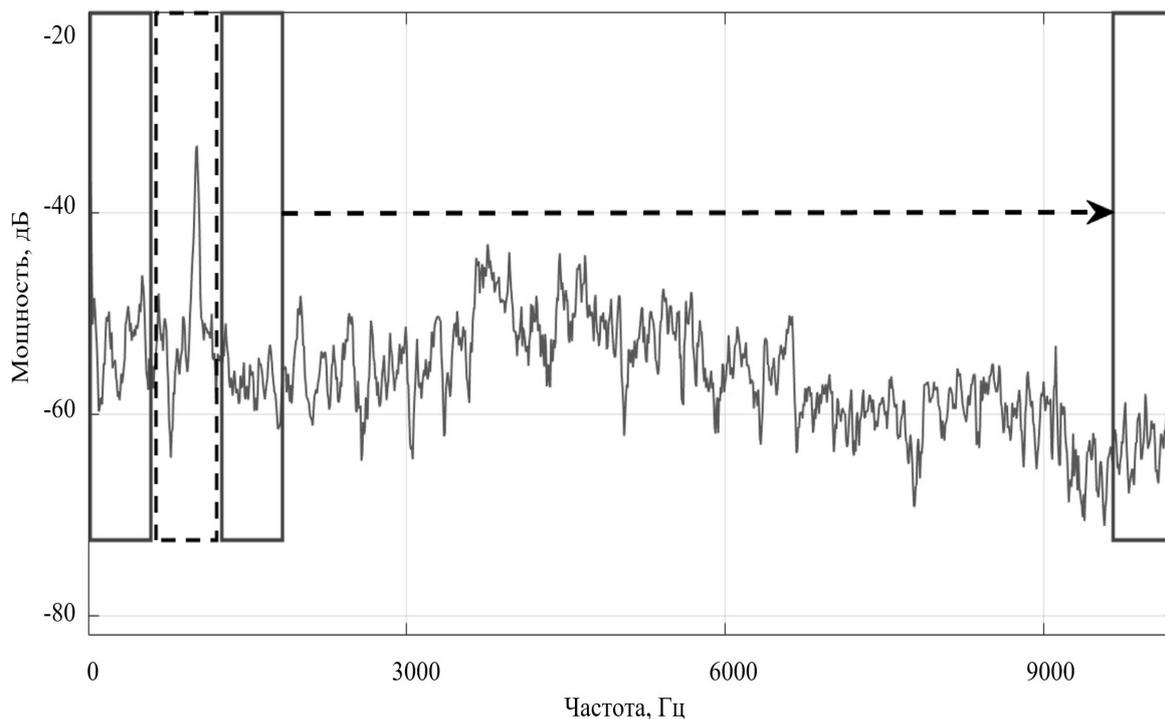


Рис. 4. Разбиение спектра на интервалы и нахождение максимальных значений каждого интервала

На рис. 5 построено такое представление для значений  $x$  пар  $(x, y)$ , полученное с помощью официального сайта TensorFlow (<https://projector.tensorflow.org/>). Можно видеть, что 4 типа сигналов сгруппированы в 4 отдельных кластера, что указывает на хорошее качество выделенных признаков и на то, что их можно успешно использовать для решения задачи классификации.

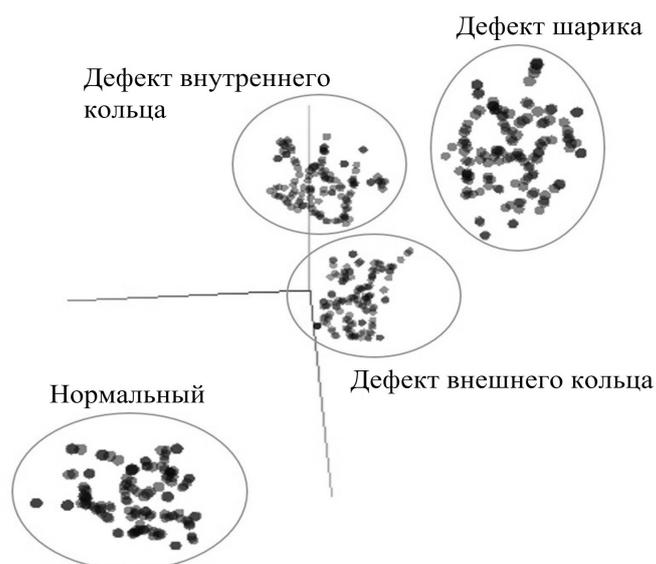


Рис. 5. Трехмерная визуализация извлеченных признаков с использованием t-SNE всех типов сигналов IMS

### 3.2. Модель нейронной сети

В качестве классификатора, который принимает на вход признаки, извлеченные методом описанным в прошлом разделе, мы использовали нейронную сеть простой архитектуры. Сеть состоит из двух отдельных модулей, обрабатывающих значения максимальных частот и их амплитуд, соответственно. За входным слоем каждого модуля следуют два скрытых слоя, после чего модули объединяются. Далее следуют еще два скрытых слоя и, наконец, выходной слой из 4 нейронов (по количеству классов), как показано на рис. 6.

При обучении мы традиционно использовали категориальную кросс-энтропию в качестве функции потерь и оптимизатор Адам. Первоначально количество эпох обучения было установлено на 2000, но мы использовали коллбэки Keras: EarlyStopping и ModelCheckpoint, которые на практике уменьшили это число эпох. Эти коллбэки сохраняют лучшую нейронную сеть (с наименьшим значением функции потерь на валидационном наборе). При отсутствии улучшения (уменьшения функции потерь) в течение patience эпох, они останавливают обучение и берут ранее сохраненную лучшую модель. Параметр patience («терпение») был установлен равным 100 эпох.

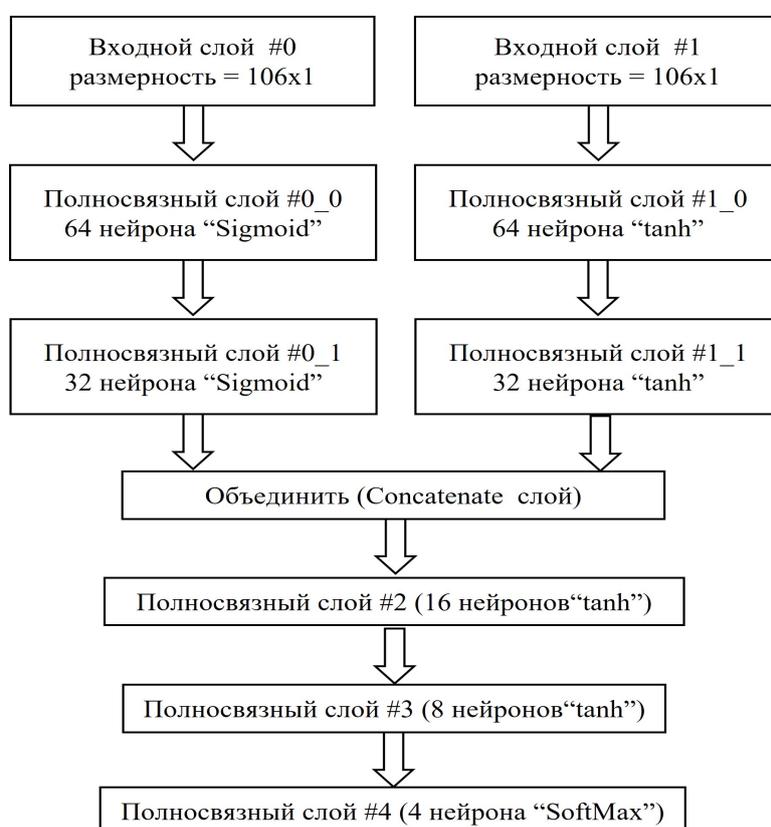


Рис. 6. Схема используемой нейронной сети

## 4. Результаты экспериментов

Используем новый предложенный метод для классификации сигналов из набора данных IMS и, чтобы иметь возможность сравнить с уже существующим результатом в [19], проведем эксперимент в похожих условиях. Мы также, как и авторы статьи [19], взяли небольшие отрезки данных (20 секунд) и разделили выборку на обучающие выборки (70%) и тестовые выборки (30%) набора.

Для оценки нашей модели используется метрика Accuracy. Accuracy вычисляется по следующей формуле:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} ,$$

где TP — истинно положительные образцы (true positive), TN — истинно отрицательные образцы (true negative), FP — ложно положительные образцы (false positive), и FN — ложно отрицательные образцы (false negative).

Авторы статьи [19] решали данную задачу классификации на основе глубокой нейронной сети и, как показал их эксперимент (табл. 2), наилучшие результаты показала сеть с 5 слоями со средней точностью 94.4% на тестовых данных. В табл. 2 приведен также результат, полученный нашим методом, он дает точность 100% для всех типов сигналов.

Итак, предложенный метод обеспечивает высокую точность классификации неисправностей, несмотря на его простоту.

**Таблица 2.** Сравнение результатов предложенного решения с [19]

Класс	Глубокие нейронные сети, учитывающие временную когерентность								Наш метод	
	3-х слойная модель		4-х слойная модель		5-х слойная модель		6-х слойная модель		проверка, %	тест, %
	проверка, %	тест, %	проверка, %	тест, %	проверка, %	тест, %	проверка, %	тест, %		
1	98.9	98.2	99.3	98.2	98.2	98.9	97.8	98.9	100	100
2	92.3	92.6	91.9	91.5	93.8	91.5	90.1	90.8	100	100
3	100	100	100	100	100	100	100	100	100	100
4	93.0	84.9	90.8	85.7	91.9	87.1	87.9	83.5	100	100
среднее	<b>96.6</b>	93.9	95.5	93.8	<b>96.0</b>	<b>94.4</b>	93.9	93.3	<b>100</b>	<b>100</b>

## Заключение

В данной работе был разработан новый метод для обработки вибрационных сигналов подшипников качения с целью классификации их неисправностей.

Основная идея предложенного решения заключается в определении новых признаков, которые могут эффективно характеризовать особенности спектров сигналов, отвечающих различным состояниям подшипников качения. Для извлечения признаков мы разделили ось частот на равные интервалы и внутри каждого нашли частоту с максимальным значением амплитуды. Извлеченные признаки представляют собой два вектора: первый содержит значения частот с максимальной амплитудой в каждом частичном интервале, второй вектор содержит значения этих амплитуд. Как показано в работе, данные признаки являются информативными и позволяют хорошо различить сигналы с подшипников разного типа.

В качестве классификатора, который принимает на вход извлеченные признаки, мы использовали нейронную сеть простой архитектуры. Сеть состоит из двух отдельных модулей: первый обрабатывает значения максимальных амплитуд спектра, а второй — значения соответствующих им частот. За входным слоем каждого модуля следуют два скрытых слоя, после чего модули объединяются. Далее следуют еще два скрытых слоя и, наконец, выходной слой из 4 нейронов.

Достоинствами предложенного подхода являются вычислительная простота, небольшое количество признаков, легкость в возможной реализации на микропроцессоре. Несмотря на простоту, метод показывает высокую эффективность на коротких наборах данных IMS, превосходящую современные аналоги.

В дальнейшем мы планируем применить предложенный метод к другому набору данных, который является более сложным и содержит данные с подшипников с разным уровнем нагрузки и степенью дефекта.

## Литература

1. Yu X., Dong F., Ding E., *et al.* Rolling Bearing Fault Diagnosis Using Modified LFDA and EMD With Sensitive Feature Selection // IEEE Access. 2018. Vol. 6. P. 3715–3730. DOI: 10.1109/ACCESS.2017.2773460.
2. Xu Y., Li Z., Wang S., *et al.* A hybrid deep-learning model for fault diagnosis of rolling bearings // Measurement. 2021. Vol. 169. P. 108502. DOI: 10.1016/j.measurement.2020.108502.
3. Han H., Wang H., Liu Z., Wang J. Intelligent vibration signal denoising method based on non-local fully convolutional neural network for rolling bearings // ISA Transactions. 2022. Vol. 122. P. 13–23. DOI: 10.1016/j.isatra.2021.04.022.
4. Hamad R., Jarpe E., Lundstrom J. Stability Analysis of the t-SNE Algorithm for Human Activity Pattern Data // Proceedings - 2018 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2018. 2019. P. 1839–1845. DOI: 10.1109/SMC.2018.00318.
5. Prognostics Center of Excellence - Data Repository. URL: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/#bearing> (accessed: 21.01.2022).
6. Wang W., Ismail F., *et al.* An enhanced bispectrum technique with auxiliary frequency injection for induction motor health condition monitoring // IEEE Transactions on Instrumentation and Measurement. 2015. Vol. 64, no. 10. P. 2679–2687. DOI: 10.1109/TIM.2015.2419031.
7. Zhen L., Zhengjia H., Yanyang Z., Xuefeng C. Bearing condition monitoring based on shock pulse method and improved redundant lifting scheme // Mathematics and Computers in Simulation. 2008. Vol. 79, no. 3. P. 318–338. DOI: 10.1016/j.matcom.2007.12.004.
8. Wang W., McFadden P. Early detection of gear failure by vibration analysis i. calculation of the time-frequency distribution // Mechanical Systems and Signal Processing. 1993. Vol. 7, no. 3. P. 193–203. DOI: 10.1006/mssp.1993.1008.
9. Luo G.Y., Osypiw D., Irle M. On-line vibration analysis with fast continuous wavelet algorithm for condition monitoring of bearing // Journal of vibration and control. 2003. Vol. 9, no. 8. P. 931–947.
10. Lei Y., Lin J., He Z., Zuo M.J. A review on empirical mode decomposition in fault diagnosis of rotating machinery // Mechanical Systems and Signal Processing. 2013. Vol. 35, no. 1-2. P. 108–126. DOI: 10.1016/j.ymsp.2012.09.015.
11. Yuan Z., Zhang L., Duan L., Li T. Intelligent fault diagnosis of rolling element bearings based on HHT and CNN // 2018 Prognostics and System Health Management Conference (PHM-Chongqing). IEEE, 2018. P. 292–296.

12. Liang P., Deng C., Wu J., *et al.* Intelligent Fault Diagnosis of Rolling Element Bearing Based on Convolutional Neural Network and Frequency Spectrograms // 2019 IEEE International Conference on Prognostics and Health Management (ICPHM). IEEE, 2019. P. 1–5. DOI: 10.1109/ICPHM.2019.8819444.
13. Shao H., Jiang H., Zhao H., Wang F. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis // Mechanical Systems and Signal Processing. 2017. Vol. C, no. 95. P. 187–204. DOI: 10.1016/J.YMSSP.2017.03.034.
14. Liu H., Zhou J., Zheng Y., *et al.* Fault diagnosis of rolling bearings with recurrent neural network-based autoencoders // ISA transactions. 2018. Vol. 77. P. 167–178. DOI: 10.1016/J.ISATRA.2018.04.005.
15. Xu Z., Li C., Yang Y. Fault diagnosis of rolling bearing of wind turbines based on the Variational Mode Decomposition and Deep Convolutional Neural Networks // Applied Soft Computing. 2020. Vol. 95. P. 106515. DOI: 10.1016/J.ASOC.2020.106515.
16. Chen Z., Cen J., Xiong J. Rolling Bearing Fault Diagnosis Using Time-Frequency Analysis and Deep Transfer Convolutional Neural Network // IEEE Access. 2020. Vol. 8. P. 150248–150261. DOI: 10.1109/ACCESS.2020.3016888.
17. Zhang W., Peng G., Li C., *et al.* A New Deep Learning Model for Fault Diagnosis with Good Anti-Noise and Domain Adaptation Ability on Raw Vibration Signals // Sensors. 2017. Vol. 17, no. 2. P. 425. DOI: 10.3390/s17020425.
18. Li X., Wang J., Zhang B. Fault diagnosis of rolling element bearing weak fault based on sparse decomposition and broad learning network // Transactions of the Institute of Measurement and Control. 2020. Vol. 42, no. 2. P. 169–179. DOI: 10.1177/0142331219864820.
19. Zhang R., Peng Z., Wu L., *et al.* Fault Diagnosis from Raw Sensor Data Using Deep Neural Networks Considering Temporal Coherence // Sensors. 2017. Vol. 17, no. 3. P. 549. DOI: 10.3390/S17030549.

Ибряева Ольга Леонидовна, к.ф.-м.н., доцент, кафедра системного программирования, Южно-Уральский государственный университет (национальный исследовательский университет) (Челябинск, Российская Федерация)

Мохаммад Мохаммад Науфол, студент, кафедра системного программирования, Южно-Уральский государственный университет (национальный исследовательский университет) (Челябинск, Российская Федерация)

# FAULT DIAGNOSIS OF ROLLING BEARINGS USING SPECTRAL PEAKS AND NEURAL NETWORKS

© 2022 O.L. Ibryaeva, M.N. Mohammad

*South Ural State University (pr. Lenina 76, Chelyabinsk, 454080 Russia)*

*E-mail: ibriaevaol@susu.ru, mohnoufi@gmail.com*

Received: 20.04.2022

The most important components of machine parts are rolling bearings, the condition of which is necessary to control, since possible defects in their design can lead to incorrect operation or general failure of machines. Modern solutions on fault diagnosis of bearings typically use complex feature extraction processes, such as their Hilbert spectrum imaging and a further powerful neural network to classify them. In this article, we propose a simple, but, nevertheless, an effective algorithm for solving this problem. To extract features from a signal, we divide the signal spectrum into equal subintervals and find the amplitude maximum and the corresponding frequency value in each of them. In the article, based on the t-SNE method, it is shown that the features selected in this way, despite their small size, represent different types of signals well. At the second stage, the selected features are fed to the input of a simple classifier neural network. The proposed method is computationally simple, both at the stage of feature extraction and at the stage of neural network training. Despite this, the method gives 100% accuracy for all types of signals on short data from the IMS dataset.

*Keywords: fault diagnosis, rolling bearing, signal spectrum, neural networks, t-SNE.*

## FOR CITATION

Ibryaeva O.L., Mohammad M.N. Fault Diagnosis of Rolling Bearings Using Spectral Peaks and Neural Networks. Bulletin of the South Ural State University. Series: Computational Mathematics and Software Engineering. 2022. Vol. 11, no. 2. P. 59–71. (in Russian) DOI: 10.14529/cmse220205.

*This paper is distributed under the terms of the Creative Commons Attribution-Non Commercial 4.0 License which permits non-commercial use, reproduction and distribution of the work without further permission provided the original work is properly cited.*

## References

1. Yu X., Dong F., Ding E., *et al.* Rolling Bearing Fault Diagnosis Using Modified LFDA and EMD With Sensitive Feature Selection. IEEE Access. 2018. Vol. 6. P. 3715–3730. DOI: 10.1109/ACCESS.2017.2773460.
2. Xu Y., Li Z., Wang S., *et al.* A hybrid deep-learning model for fault diagnosis of rolling bearings. Measurement. 2021. Vol. 169. P. 108502. DOI: 10.1016/j.measurement.2020.108502.
3. Han H., Wang H., Liu Z., Wang J. Intelligent vibration signal denoising method based on non-local fully convolutional neural network for rolling bearings. ISA Transactions. 2022. Vol. 122. P. 13–23. DOI: 10.1016/j.isatra.2021.04.022.
4. Hamad R., Jarpe E., Lundstrom J. Stability Analysis of the t-SNE Algorithm for Human Activity Pattern Data. Proceedings - 2018 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2018. 2019. P. 1839–1845. DOI: 10.1109/SMC.2018.00318.

5. Prognostics Center of Excellence - Data Repository. URL: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/#bearing> (accessed: 21.01.2022).
6. Wang W., Ismail F., *et al.* An enhanced bispectrum technique with auxiliary frequency injection for induction motor health condition monitoring. *IEEE Transactions on Instrumentation and Measurement*. 2015. Vol. 64, no. 10. P. 2679–2687. DOI: 10.1109/TIM.2015.2419031.
7. Zhen L., Zhengjia H., Yanyang Z., Xuefeng C. Bearing condition monitoring based on shock pulse method and improved redundant lifting scheme. *Mathematics and Computers in Simulation*. 2008. Vol. 79, no. 3. P. 318–338. DOI: 10.1016/j.matcom.2007.12.004.
8. Wang W., McFadden P. Early detection of gear failure by vibration analysis i. calculation of the time-frequency distribution. *Mechanical Systems and Signal Processing*. 1993. Vol. 7, no. 3. P. 193–203. DOI: 10.1006/mssp.1993.1008.
9. Luo G.Y., Osypiw D., Irle M. On-line vibration analysis with fast continuous wavelet algorithm for condition monitoring of bearing. *Journal of vibration and control*. 2003. Vol. 9, no. 8. P. 931–947.
10. Lei Y., Lin J., He Z., Zuo M.J. A review on empirical mode decomposition in fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*. 2013. Vol. 35, no. 1-2. P. 108–126. DOI: 10.1016/j.ymssp.2012.09.015.
11. Yuan Z., Zhang L., Duan L., Li T. Intelligent fault diagnosis of rolling element bearings based on HHT and CNN. 2018 Prognostics and System Health Management Conference (PHM-Chongqing). IEEE, 2018. P. 292–296.
12. Liang P., Deng C., Wu J., *et al.* Intelligent Fault Diagnosis of Rolling Element Bearing Based on Convolutional Neural Network and Frequency Spectrograms. 2019 IEEE International Conference on Prognostics and Health Management (ICPHM). IEEE, 2019. P. 1–5. DOI: 10.1109/ICPHM.2019.8819444.
13. Shao H., Jiang H., Zhao H., Wang F. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis. *Mechanical Systems and Signal Processing*. 2017. Vol. C, no. 95. P. 187–204. DOI: 10.1016/J.YMSSP.2017.03.034.
14. Liu H., Zhou J., Zheng Y., *et al.* Fault diagnosis of rolling bearings with recurrent neural network-based autoencoders. *ISA transactions*. 2018. Vol. 77. P. 167–178. DOI: 10.1016/J.ISATRA.2018.04.005.
15. Xu Z., Li C., Yang Y. Fault diagnosis of rolling bearing of wind turbines based on the Variational Mode Decomposition and Deep Convolutional Neural Networks. *Applied Soft Computing*. 2020. Vol. 95. P. 106515. DOI: 10.1016/J.ASOC.2020.106515.
16. Chen Z., Cen J., Xiong J. Rolling Bearing Fault Diagnosis Using Time-Frequency Analysis and Deep Transfer Convolutional Neural Network. *IEEE Access*. 2020. Vol. 8. P. 150248–150261. DOI: 10.1109/ACCESS.2020.3016888.
17. Zhang W., Peng G., Li C., *et al.* A New Deep Learning Model for Fault Diagnosis with Good Anti-Noise and Domain Adaptation Ability on Raw Vibration Signals. *Sensors*. 2017. Vol. 17, no. 2. P. 425. DOI: 10.3390/s17020425.

18. Li X., Wang J., Zhang B. Fault diagnosis of rolling element bearing weak fault based on sparse decomposition and broad learning network. Transactions of the Institute of Measurement and Control. 2020. Vol. 42, no. 2. P. 169–179. DOI: 10.1177/0142331219864820.
19. Zhang R., Peng Z., Wu L., *et al.* Fault Diagnosis from Raw Sensor Data Using Deep Neural Networks Considering Temporal Coherence. Sensors. 2017. Vol. 17, no. 3. P. 549. DOI: 10.3390/S17030549.