

## СЕКЦИЯ 3

# Системы и технологии искусственного интеллекта и больших данных

---

*О. Л. ИБРЯЕВА, М. МОХАММАД*

*Южно-Уральский государственный университет, г. Челябинск*

УДК 004.81

### **ДИАГНОСТИКА НЕИСПРАВНОСТЕЙ ПОДШИПНИКОВ КАЧЕНИЯ НА ОСНОВЕ СПЕКТРАЛЬНЫХ ПРИЗНАКОВ**

***Аннотация.** Подшипники качения являются основными элементами вращающегося оборудования, своевременное выявление дефектов которых очень важно. Мы предлагаем новый метод в этой области, основанный на разбиении спектра вибрационных сигналов подшипников на сегменты и дальнейшем выделении максимального и минимального значений в каждом сегменте. Отношения этих значений используются на входе нейронной сети — классификатора дефектов.*

***Ключевые слова:** обработка сигнала, подшипник качения, извлечение признаков, нейронные сети, диагностика.*

**Введение.** Подшипники качения имеют большое функциональное значение, и практически не существует механической системы, не содержащей таких элементов [1]. По этой причине обнаружение дефектов подшипников является важной задачей, ее решению посвящено множество работ, большинство из которых основаны на глубоком обучении [2].

Информацию о состоянии подшипника обычно получают по его вибрационному сигналу, характеристики которого для подшипника в нормальном состоянии, отличаются от характеристик сигнала с появившимися в корпусе подшипника дефектами. Выделить из вибрационных сигналов информативные признаки, которые будут чутко реагировать на изменения в его состоянии — важная задача, фактически определяющая точность обучаемого далее на этих признаках

классификатора. Таким образом, задача диагностики состояния подшипника делится на две части. Первая связана с извлечением признаков, способных корректно описать каждый из возможных случаев, вторая часть посвящена разработке классификатора с выделенными признаками на входе.

Наиболее часто на этапе выделения признаков используется частотный анализ сигнала, который обычно выполняется с помощью быстрого преобразования Фурье (БПФ) [3]. В последнее время стал популярен и частотно-временной анализ, особенно в случае нестационарных сигналов, и среди многих инструментов, используемых для этой цели, мы можем найти кратковременное преобразование Фурье (STFT) [4].

На втором этапе в качестве классификатора наиболее часто применяются нейронные сети [5]. Трансферное обучение и сверточные нейронные сети использованы в [6]. В статье [7] для классификации неисправностей подшипников качения в условиях шума был разработан автокодировщик на основе сверточных нейронных сетей (CDAE). В работе [8] авторы используют одномерную сверточную сеть.

**Постановка задачи.** В последнее время наметилась тенденция к использованию все более сложных, мощных и глубоких архитектур нейронных сетей. Исследователи работают над усовершенствованием моделей нейронных сетей и мало задумываются над выявлением более информативных признаков. Во многих работах авторы уже указывали на необходимость новых, применимых на практике, простых решений [9].

Отсюда вытекает следующая постановка задачи — разработать новый, простой в вычислительном отношении, метод диагностики состояний подшипников качения на основе их вибрационных сигналов. Этап выделения признаков должен давать вектор информативных признаков небольшого размера, который затем поступит на вход простого классификатора.

Предлагаемый в этой статье подход к решению данной задачи основан на анализе спектра вибрационных сигналов и подробнее описан в разделе 3. В качестве простого классификатора выступает нейронная сеть, описанная в том же разделе. Чтобы проверить правильность разработанного метода, мы использовали набор данных Intelligent Maintenance Systems (IMS) [10].

Преимущества данного исследования заключаются в следующем:

1. Совершенно новый метод классификации дефектов.
2. Информативный вектор признаков низкой размерности.
3. Простота используемого классификатора.
4. 100% точность на наборе данных IMS.

## Материалы и методы

### *Извлечение признаков*

Метод, представленный в этом исследовании, основан на расчете отношения максимального значения к минимальному значению в сегментах спектра сигнала.

Рассмотрим спектр вибрационных сигналов. На рис. 1 показана мощность спектра сигналов из набора данных IMS; каждый отвечает своему типу дефекта. Отметим, что предварительно мы нормализовали каждый сигнал так, чтобы их значения находились в диапазоне  $[-1, +1]$ . Мощность спектра сигналов также находится в приблизительно одном и том же диапазоне.




Рис. 1. Мощность спектра сигналов из набора данных IMS: а) нет дефектов; б) дефект шарика; в) дефект внутреннего кольца; г) дефект внешнего кольца

Можно заметить, что энергия сигнала для каждого типа дефекта сосредоточена в определенной области спектра и варьируется между собой. Кроме того, мы можем обнаружить, что спектральные максимальные пики и минимальные спектральные значения также сосредоточены в определенных спектральных областях в соответствии с типом присутствующего искажения, которое выражает сигнал.

Чтобы лучше объяснить предложенную идею, на рис. 2 показана конкретная область спектра сигналов — область между нулем и 240 Гц. Этот рисунок идеально объясняет суть предлагаемого решения. Из этого рисунка можно сделать вывод, что спектральные пики и минимальные значения спектра в этой области различаются в зависимости от дефекта в подшипнике качения, и поэтому расчет отношения максимального значения к минимальному значению также будет различаться в зависимости от характера искажения.

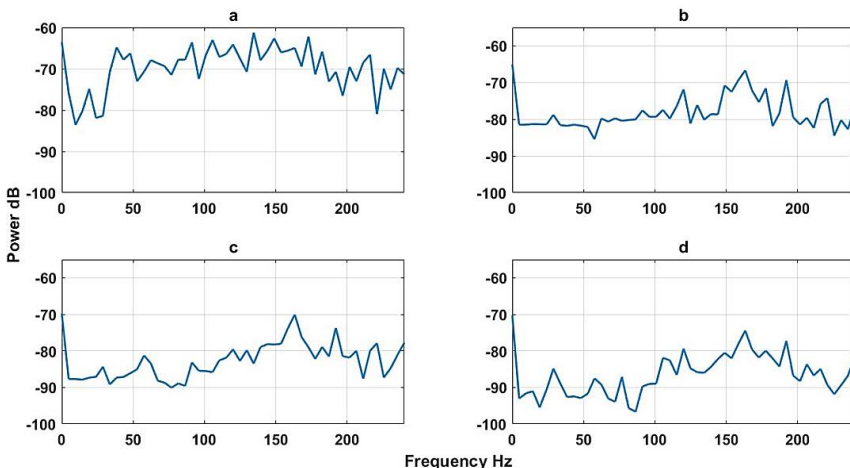


Рис. 2. Мощность спектра сигналов в интервале  $[0,240]$  Гц:  
 а) нет дефектов; б) дефект шарика; в) дефект внутреннего кольца;  
 г) дефект внешнего кольца

Алгоритма выделения признаков таков:

- рассчитать одностороннее БПФ сигнала;
- рассчитать мощность спектра;
- разделить спектр на 50 равных интервалов;

- рассчитать максимальное и минимальное значения и их отношение для каждого интервала;
- получить вектор признаков из 50 значений.

Чтобы проверить что выделенные признаки адекватно описывают состояния подшипников, мы нашли их для сигналов из набора данных IMS, который содержит данные для 4 различных состояний подшипников качения (табл. 1). Для выделенных признаков в 50-мерном пространстве мы использовали алгоритм главных компонент (РСА) для уменьшения размерности до 3, чтобы «посмотреть» на них в трехмерном пространстве.

Таблица 1

**Количество кадров для нескольких поднаборов данных**

<i>Класс</i>	<i>Дефект</i>	<i>Число образцов в обучающей выборке</i>	<i>Число образцов в обучающей выборке</i>
1	Нет	134	56
2	Дефект внутреннего кольца	134	56
3	Дефект внешнего кольца	134	56
4	Дефект шарика	133	56

На рис. 3 изображено, что сигналы из набора данных IMS разбиваются (по выделенным признакам) на 4 отдельных кластера, соответствующих 4 типам сигналов в этом наборе данных. Таким образом, каждый временной отрезок сигнала может быть представлен всего 50 признаками. Процедура их нахождения является простой, а сами признаки информативными.

Отметим, что большинство процедур извлечения признаков из сигналов вибрации требуют много времени, сложных и дорогостоящих в вычислительном отношении преобразований и генерируют большое количество признаков. Таким, например, является преобразование Гильберта в сочетании с эмпирическим модовым разложением, когда каждому сигналу в соответствие ставится изображение его спектра Гильберта. Даже если размер этой картинки будет 32×32 пикселя, то количество признаков уже составит 1024, процедура их получения довольно затратная, а далее такие признаки требуют использования мощной сверточной нейронной сети.

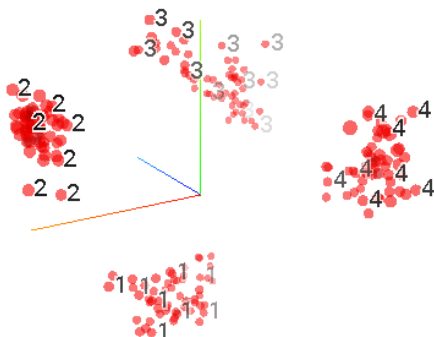


Рис. 3. Визуализация признаков с использованием метода понижения размерности PCA

В данной работе, используя 50 признаков, перейдем к этапу обучения классификатора, в качестве которой возьмем простую полносвязную нейронную сеть.

#### *Модель нейронной сети*

Поскольку выделенные признаки имеют небольшую размерность, нейронная сеть также имеет максимально простую структуру. Размер входного слоя составляет  $50 \times 1$ , что соответствует размеру признаков, извлеченных ранее. Далее следует выходной слой из 4 нейронов, использующий функцию активации SoftMax для расчета вероятности каждого из 4 возможных исходов.

На рис. 4 показана архитектура нейронной сети.

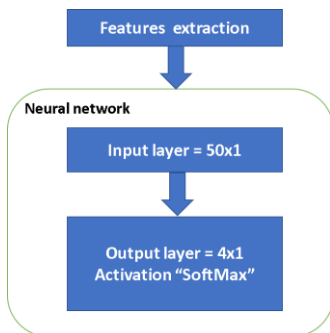



Рис. 4. Архитектура нейронной сети

Ясно, что ее нельзя упростить, сеть имеет только входной слой из 50 нейронов, каждый из которых соединен с 4 нейронами выходного слоя.

**Результаты.** Эксперименты проводились на наборе данных IMS, который содержит три поднабора данных. Экспериментальная установка показана на рис. 5. В начале всех записей все подшипники были исправны, данные записывались до их поломки. Набор данных № 1 содержит исправный сигнал, дефект внутреннего кольца и дефект шарика. Набор данных № 2 содержит исправный сигнал и дефект внешнего кольца. Набор данных № 3 содержит исправный сигнал и дефект внешнего кольца.



*Рис. 5.* Компоновка испытательного стенда IMS

Характеристики набора данных:

- скорость двигателя поддерживалась постоянной на уровне 2000 об./мин.;
- на вал и подшипник действует радиальная нагрузка в 6000 фунтов;
- каждый набор данных содержит сигнала с подшипника от его нормального состояния до появления дефекта и состоит из отдельных файлов, представляющих собой 1-секундные отрезки сигнала вибрации с частотой дискретизации 20480 Гц, записанные с определенными интервалами.

В этом эксперименте мы брали сигналы каждого типа дефекта длительностью 20 секунд, как это было сделано в статье [11].

Для нормальных условий были выбраны первые 20 файлов 1-го набора данных для подшипника № 1. Для сигнала с дефектом внутреннего кольца мы взяли последние 20 файлов 1-го набора данных для подшипника № 3. Для сигнала с дефектом шарика были взяты последние 20 файлов 1-го набора данных для подшипника № 4. Для сигнала с дефектом внешнего кольца были взяты 20 файлов (с 2004-04-17 21:52:55 до 2004-04-18 01:02:55) 3-го набора данных. Мы повторили метод сегментации сигнала, использованный в [12] [13], для набора данных CWRU, чтобы увеличить объем выборки.

Каждый сегмент сигнала содержит 4260 отсчетов, что эквивалентно  $4260/20480 = 0,208$  секунды, с процентом перекрытия 50%, т. е. 2130 отсчетов. Количество сегментов сигнала, полученных для каждого поднабора данных после процесса сегментации приведено в Таблица 1.

Методом, предложенным в этой статье, мы получили 100% точность в классификации дефектов подшипников. Отметим, что для создания обучающего набора в режиме скользящего окна с перекрытием мы использовали первые 70% временного ряда, а оставшиеся 30% были использованы для создания соответствующего тестового набора. При этом, тренировочный и тестовый наборы не содержат похожих образцов (отличающихся сдвигом друг от друга) и тестирование модели происходит «честно».

Отметим, что аналогичный эксперимент с этим набором данных был проведен в [11], где авторы также работали с 20-секундными данными. Наилучшая точность, полученная в [11], составляет 96%, а в данной работе мы достигли 100%.

**Заключение.** В статье разработан новый подход к диагностике подшипников качения, который основан на выделении признаков из спектра его вибрационных сигналов. Разделяя спектр на 50 равных интервалов, а затем вычисляя в каждом интервале отношение максимума к минимуму, мы получаем вектор признаков размером  $50 \times 1$ . Этот вектор отношений затем используется в качестве входного вектора для нейронной сети, которая предсказывает тип неисправности с высокой точностью. Преимущества нашего подхода заключаются



в реализации, которая очень простая, а также определении очень информативного признаков, что даже нейронной сети простейшей архитектуры достаточно для эффективного решения задачи классификации дефектов подшипника. Это особенно контрастирует со все более глубокими сверточными и рекуррентными нейронными сетями современных передовых методов аналогов.

## **СПИСОК ЛИТЕРАТУРЫ**

1. Yu X. Rolling Bearing Fault Diagnosis Using Modified LFDA and EMD With Sensitive Feature Selection / X. Yu, F. Dong, E. Ding [et al.] — DOI: 10.1109/ACCESS.2017.2773460. — Text : electronic // IEEE Access. IEEE. — 2018. — Vol. 6. — P. 3715-3730.
2. Han H. Intelligent vibration signal denoising method based on non-local fully convolutional neural network for rolling bearings / H. Han, H. Wang, Z. Liu [et al.] — DOI: 10.1016/j.isatra.2021.04.022. — Text : electronic // ISA Trans. Elsevier. — 2022. — Vol. 122. — P. 13-23.
3. Li D. Z. An Enhanced Bispectrum Technique With Auxiliary Frequency Injection for Induction Motor Health Condition Monitoring / D. Z. Li, W. Wang, F. Ismail. — DOI: 10.1109/TIM.2015.2419031. — Text : electronic // IEEE Trans. Instrum. Meas. IEEE. — 2015. — Vol. 64, № 10. — P. 2679-2687.
4. Wang W. J. Early detection of gear failure by vibration analysis i. calculation of the time-frequency distribution / W. J. Wang, P. D. McFadden. — DOI: 10.1006/mssp.1993.1008. — Text : electronic // Mech. Syst. Signal Process. Elsevier. — 1993. — Vol. 7, № 3. — P. 193-203.
5. Mukhopadhyay S. Condition Monitoring of Ball Bearings Based on Machine Learning with Synthetically Generated Data / S. Mukhopadhyay, N. Cennamo, M. J. Deen [et al.]. — DOI: 10.3390/S22072490. — Text : electronic // Sensors. — 2022. — Vol. 22, № 7. — P. 2490.
6. Grover C. A novel fault diagnostic system for rolling element bearings using deep transfer learning on bispectrum contour maps / C. Grover, N. Turk. — DOI: 10.1016/j.jestch.2021.08.006. — Text : electronic // Eng. Sci. Technol. an Int. J. Elsevier. — 2022. — Vol. 31. — P. 101049.
7. Zhang K. A hybrid deep-learning model for fault diagnosis of rolling bearings in strong noise environments / K. Zhang. — DOI: 10.1088/1361-6501/AC4A18. — Text : electronic // Meas. Sci. Technol. IOP Publishing. — 2022. — Vol. 33, № 6. — P. 065103.

8. Yuan Z. Bearing fault diagnosis using a speed-adaptive network based on vibro-speed data fusion and majority voting / Z. Yuan, Z. Ma, X. Li [et al.] — DOI: 10.1088/1361-6501/AC46EE. — Text : electronic // Meas. Sci. Technol. IOP Publishing. — 2022. — Vol. 33, № 5. — P. 055112.
9. Chen Z. Rolling Bearing Fault Diagnosis Using Time-Frequency Analysis and Deep Transfer Convolutional Neural Network / Z. Chen, J. Cen, J. Xiong. — DOI: 10.1109/ACCESS.2020.3016888. — Text : electronic // IEEE Access. Institute of Electrical and Electronics Engineers Inc. — 2020. — Vol. 8. — P. 150248–150261.
10. Prognostics Center of Excellence. — Data Repository. — URL: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/#bearing> (accessed: 21.01.2022). — Text : electronic.
11. Zhang R. Fault Diagnosis from Raw Sensor Data Using Deep Neural Networks Considering Temporal Coherence / R. Zhang, Z. Peng, L. Wu [et al.]. — DOI: 10.3390/s17030549. — Text : electronic // Sensors. — 2017. — Vol. 17, № 3. — P. 549.
12. Xu Y. A hybrid deep-learning model for fault diagnosis of rolling bearings / Y. Xu, Z. Li, S. Wang [et al.] — DOI: 10.1016/j.measurement.2020.108502. — Text : electronic // Measurement. Elsevier. — 2021. — Vol. 169. — P. 108502.
13. Huang M. Fault diagnosis of rolling bearing based on empirical mode decomposition and convolutional recurrent neural network / M. Huang, T. Huang, Y. Zhao [et al.]. — DOI: 10.1088/1757-899X/1043/4/042015. — Text : electronic // IOP Conf. Ser. Mater. Sci. Eng. IOP Publishing. — 2021. — Vol. 1043, № 4. — P. 042015.

*Д. М. ШАХОД, О. Л. ИБРЯЕВА*

*Южно-Уральский государственный университет, г. Челябинск*

**УДК 004.032.26, 004.048**

## **НЕЙРОСЕТЕВОЙ АЛГОРИТМ ПОДАВЛЕНИЯ ЭХА В УСЛОВИЯХ ДВОЙНОГО РАЗГОВОРА**

***Аннотация.** В работе решается задача подавления акустического эха в условиях двойного разговора на основе нейронной сети, оценивающей идеальную двоичную маску ИВМ из признаков, извлеченных из смеси сигналов ближнего и дальнего конца. Новизна предложенного метода заключается*