

МЕТОДИКА ВЫЯВЛЕНИЯ ВМЯТИН НА ДОРОЖКАХ ПОДШИПНИКОВ КАЧЕНИЯ НА ОСНОВЕ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ С ДВУМЕРНЫМ ОТОБРАЖЕНИЕМ

© 2022 г. Чжэн Юа^{1,*}, Му Лунтао¹, Чжао Цзюньхао¹

¹Шэньсийский политехнический институт, Сяньян, Китай
E-mail: *zhengyu169@126.com

Поступила в редакцию 03.08.2022; после доработки 30.09.2022

Принята к публикации 30.09.2022

Для реализации методики выявления незначительных повреждений (вмятин) на дорожках подшипников качения были выбраны сверточные нейронные сети (СНС). Чтобы улучшить обучение СНС, для преобразования сигналов вибрации подшипника из изображения в одномерный временной ряд были проанализированы такие алгоритмы преобразования двухмерных изображений, как поля угловой суммы или разности Грамиана, частотно-временная диаграмма вейвлета, матрица перехода Маркова. Чтобы уменьшить объем аппаратных вычислений и сократить время обучения и валидации было использовано кусочно-постоянное представление (КПП) для максимального сжатия данных с сохранением всей информации о сигнале. Также добавляется слой пакетной нормализации для избежания проблемы насыщения градиента функции ReLU, а для преодоления нестабильности стохастического градиентного спуска с импульсом (СГСИ) при разработке СНС применяют метод минипакетов. Каждый вид изображений используется в качестве обучающей выборки, а результаты показывают, что как частотно-временная диаграмма вейвлета, так и диаграмма полей угловой суммы или разности Грамиана могут лучше определять состояние дефекта, причем частотно-временная диаграмма вейвлета была относительно лучше. При сравнении с различными рекуррентными нейросетевыми (РНС) моделями диагностики была доказана обоснованность модели. В то же время модель применяется для идентификации деградации характеристик неисправных деталей, а результаты показывают, что модель может эффективно идентифицировать деградацию внутреннего кольца, наружного кольца и тела качения, а точность для внутреннего кольца и наружного была выше. Данная статья предлагает новую методику выявления вмятин на дорожках подшипников качения.

Ключевые слова: СНС, двумерное изображение, КПП, подшипник качения, диагностика незначительных дефектов.

DOI: 10.31857/S0130308223010074, **EDN:** BWBKMN

1. ВВЕДЕНИЕ

Подшипники качения являются важной основной частью вращающихся механизмов [1] и часто играют важную вспомогательную роль в основном оборудовании [2]. Состояние подшипников качения часто определяет, может ли механизм работать нормально [3, 4]. Поэтому для своевременного обнаружения или предупреждения возможных неисправностей необходимо использовать эффективный метод мониторинга состояния подшипников качения¹ [5]. Это имеет большое значение для обеспечения надежности работы и снижения затрат на техническое обслуживание [6].

В смежных исследованиях Xiaochi L. и др. [7] предложили метод контроля повреждений подшипников², сочетающий алгоритм оптимизации серых волков (ОСВ), нелокальное среднее шумоподавление (НСШ) и полностью адаптированное для шумоподавления разложение на эмпирические моды. Zihao L. и др. [8] описали интеллектуальный метод контроля подшипников качения, основанный на многомасштабном механизме извлечения признаков в смешанной области и доменной адаптации. Xiaojuan L. и др. [9] рассмотрели проблемы потери информации и неправильной работы при извлечении признаков из вибрационных сигналов неисправных подшипников. В статье исследовали гибридный интеллектуальный метод выявления неисправностей машин, основанный на теории вероятностей и улучшенном алгоритме оптимизации серых волков (ОСВ) для оптимизации машины опорных векторов (МОП). Ming W. и др. [10] предложили метод контроля повреждений подшипников качения, основанный на улучшенном разложении по динамическим модам (РДМ). Однако традиционный метод контроля, основанный на фильтрации и подавлении шума,

¹ <http://rcit.su/techinfo66.html>

² Повреждение — нарушение целостности деталей подшипника вследствие воздействия циклических нагрузок в процессе его работы, монтажа, демонтажа, транспортировки и хранения. Вмятина — результат вдавливания твердых частиц отслаивающегося металла в результате образования контактно-усталостных повреждений или попадания в смазку подшипника инородных твердых тел, а также длительного действия на подшипник, находящегося в состоянии покоя, нагрузок пульсирующего характера, приводящих к образованию на дорожках качения колец отпечатков от роликов, называемых «ложным бринеллированием».

производит чрезмерное разложение сигналов от незначительных повреждений, что сокращает полезную информацию и не способствует точной диагностике. В то же время сигналы вибрации подшипника содержат большое количество нелинейных компонентов, пригодность обычных алгоритмов классификации, таких как МОП, не очень хороша.

В связи с вышеуказанными причинами, сверточная нейронная сеть (СНС) обладает хорошей адаптивностью в классификации данных. Tianlong G. и др. [11] непосредственно вводили данные о вибрации подшипника в многомасштабную СНС для диагностирования, но параметры извлечения признаков СНС имеют более очевидные преимущества в высокоразмерных данных [12]. Jiangtao J. и др. [13] описали метод интеллектуального контроля ХСНС (Хаотическая СНС)-ДКП-ОМОВ. Однако этот метод не только имеет комплекс последовательности действий, низкую скорость идентификации неисправностей, но и может иметь долгосрочную зависимость от блоков долгой кратковременной памяти. Xiaoxia Y. и др. [14] реализовали контроль повреждений корпуса подшипников на основе адаптивных графовых сверточных нейросетей (АГСНС), основанных на матричной диаграмме, определяемой по коэффициенту вейвлет-пакета сигнала вибрации корпуса авиадвигателя. Но сигнал вибрации подшипника не был прямо использован, что привело к относительно большому расхождению результатов контроля.

Исходные сигналы вибрации подшипников имеют множество временных характеристик, а содержащаяся в них исходная информация имеет большое значение для осуществления достоверного контроля. Поэтому при выборе СНС в качестве метода обработки информации необходимо максимально использовать исходную информацию, содержащуюся в сигнале. Во-вторых, прямое использование исходных вибрационных сигналов для обучения неизбежно приведет к слишком большой нагрузке на компьютерное оборудование и слишком большому времени обучения, для этого необходимо максимально сократить время обучения, сохранив при этом общую информацию о сигнале. Наконец, метод контроля должен в полной мере использовать способность СНС к распознаванию абстрактных признаков для эффективной идентификации различных незначительных повреждений.

В заключение, используя алгоритм кусочно-постоянного представления (КПП), уменьшается размерность сигналов вибрации подшипников. Одномерные сигналы вибрации преобразуются в двумерные изображения с помощью различных алгоритмов для получения обучающих образцов. Затем разрабатывается СНС, и образцы изображений используются для обучения сети. Наконец, реализована эффективная методика контроля различных незначительных повреждений.

2. ТЕОРЕТИЧЕСКИЕ ОСНОВЫ

Метод генерации двумерных изображений

Угловые поля Грамиана

Угловые поля Грамиана (УПГ) могут преобразовывать одномерные временные ряды в двумерные графики [15, 16]. Принцип преобразования и формула приводятся в уравнениях (1)–(3):

$$\tilde{x}_i = \frac{(x_i - \max(\mathbf{X})) + (x_i - \min(\mathbf{X}))}{\max(\mathbf{X}) - \min(\mathbf{X})}, \quad (1)$$

$$i = 1, 2, \dots, n, \quad \tilde{x}_i \in [-1, 1],$$

где $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ — одномерный временной ряд; $\tilde{x}_i$ — нормализованные элементы одномерного временного ряда.

$$\varphi_i = \arccos(\tilde{x}_i); \quad (2)$$

$$r_i = \frac{t_i}{n},$$

где φ_i — арккосинус $\tilde{x}_i$ в полярных координатах; r_i — радиус в полярных координатах; t_i — временная метка, соответствующая x_i ; n — коэффициент нормализации, показывающий общее число точек в одномерном временном ряде $\mathbf{X}$.

$$\mathbf{GASF} = \begin{pmatrix} \cos(\varphi_1 + \varphi_2) & \cdots & \cos(\varphi_1 + \varphi_n) \\ \cos(\varphi_2 + \varphi_1) & \cdots & \cos(\varphi_2 + \varphi_n) \\ \vdots & & \vdots \\ \cos(\varphi_n + \varphi_1) & \cdots & \cos(\varphi_n + \varphi_n) \end{pmatrix},$$

$$\mathbf{GADF} = \begin{pmatrix} \cos(\varphi_1 - \varphi_2) & \cdots & \cos(\varphi_1 - \varphi_n) \\ \cos(\varphi_2 - \varphi_1) & \cdots & \cos(\varphi_2 - \varphi_n) \\ \vdots & & \vdots \\ \cos(\varphi_n - \varphi_1) & \cdots & \cos(\varphi_n - \varphi_n) \end{pmatrix}, \quad (3)$$

где **GASF** — поля угловой суммы Грамиана (ПУСГ); **GADF** — поля угловой разности Грамиана (ПУРГ).




Рис. 1. УПГ-преобразование одномерного сигнала.

Матрица перехода Маркова

Матрица перехода Маркова (МПМ) кодирует информацию о динамическом переходе через вероятность марковского перехода. Формула выглядит следующим образом (см. уравнения (4), (5)):

$$\mathbf{W} = \begin{pmatrix} \omega_{11}|P(x_i \in q_1|x_{i-1} \in q_1) & \cdots & \omega_{1Q}|P(x_i \in q_1|x_{i-1} \in q_Q) \\ \omega_{21}|P(x_i \in q_2|x_{i-1} \in q_1) & \cdots & \omega_{2Q}|P(x_i \in q_2|x_{i-1} \in q_Q) \\ \vdots & & \vdots \\ \omega_{Q1}|P(x_i \in q_Q|x_{i-1} \in q_1) & \cdots & \omega_{QQ}|P(x_i \in q_Q|x_{i-1} \in q_Q) \end{pmatrix}, \quad (4)$$

где **W** — это матрица перехода Маркова; x_t — данные по временным меткам t в одномерном временному ряду **X**; ω_{ij} — частота квантиля q_i после квантиля q_j ; $\omega_{ij} = P(x_t \in q_i | x_{t-1} \in q_j)$;

$q_j (j \in [1, Q])$ — квантиль; Q — квантильный критерий, распределенный в соответствии с диапазоном значений одномерного временного ряда $\mathbf{X}$.

Матрица перехода Маркова $\mathbf{M}$ строится путем расширения матрицы $\mathbf{W}$ при упорядочивании каждой вероятности во временном порядке:

$$\mathbf{W} = \begin{pmatrix} m_{ij|x_1 \in q_i, x_1 \in q_j} & \cdots & m_{ij|x_1 \in q_i, x_n \in q_j} \\ m_{ij|x_2 \in q_i, x_1 \in q_j} & \cdots & m_{ij|x_2 \in q_i, x_n \in q_j} \\ \vdots & & \vdots \\ m_{ij|x_n \in q_i, x_1 \in q_j} & \cdots & m_{ij|x_n \in q_i, x_n \in q_j} \end{pmatrix}, \quad (5)$$

где m_{ij} — вероятность перехода из квантиля q_i в квантиль q_j ; $m_{ij} = P(q_i \rightarrow q_j)$.




Рис. 2. МПМ-преобразование одномерного сигнала.

Частотно-временная диаграмма вейвлета

Вейвлет-преобразование — средство для частотно-временного анализа сигналов, которым может проводиться обработка сигнала на различных масштабах или разрешениях [18]. Комплексная матрица коэффициентов, полученная из исходного сигнала путем непрерывного вейвлет-преобразования, — это частотно-временная диаграмма вейвлет-преобразования. На рис. 3 показан пример такой диаграммы.




Рис. 3. Частотно-временная диаграмма вейвлета.

СНС

СНС — это разновидность нейронной сети прямого распространения, которая включает в себя сверточные вычисления [19]. Типичные СНС обычно включают сверточные слои, слои функций активации, объединяющие слои и полносвязные слои. Сверточный слой используется для извлечения характеристик данных, и его математическое выражение выглядит следующим образом [20]:

$$x_j^n = f\left(\sum (x_i^{n-1} \cdot \omega_{ij}^n) + b_j^n\right), \quad (6)$$

где x_j^n — j -карта признаков n -го слоя; x_i^{n-1} — i -карта признаков предыдущих слоев; ω_{ij}^n — матрица весов на n -м уровне; b_j^n — соответствующее смещение; $f(\cdot)$ — функция активации.

Объединяющий слой обычно используется для фильтрации информации и уменьшения параметров, участвующих в вычислении в массиве, чтобы предотвратить переобучение. Формула для расчета:

$$x_j^n = f\left(\beta_j^n \text{down}(x_j^{n-1}, M^n) + b_j^n\right), \quad (7)$$

где β_j^n — вес номера j -карты признаков с n слоями; $\text{down}(\cdot)$ — объединяющая функция, включающая максимальное значение, среднее значение и случайное значение; M^n — номер n слоя, который принимает окно свертки, а размер поля свертки $M^n \times M^n$.

Кусочно-постоянное представление

Кусочно-постоянное представление (КПП) — метод восстановления данных исходных временных рядов, используя те же ряды данных разрешения по времени [21], который имеет хороший эффект снижения размерности данных для большинства одномерных временных рядов. КПП-метод рассчитывается по уравнению [22]:

$$\bar{x}_j = \frac{1}{k} \sum_{i=k(j-1)+1}^{k*j} x_i, \quad (8)$$

где x_i — исходный временной ряд длиной $k \cdot j$; $\bar{x}_j$ — временной ряд после усреднения; j — длина. Из этого уравнения можно получить временные ряды после усреднения, главная идея КПП — кусочно усреднить одномерный временной ряд так, чтобы уменьшить размерность данных и сократить их длину, максимально сохранив общую информацию о ряде.

Рис. 4 показывает угловые поля Грамиана без уменьшения разрешения ($512 \times 512 \times 1$) и после его уменьшения ($64 \times 64 \times 1$).




Рис. 4. Результат уменьшения размеров методом КПП: без КПП (а); после КПП (б).

Как видно из рис. 4, после уменьшения разрешения по КПП-алгоритму размер карты угловых полей Грамиана значительно уменьшается. Между тем, полученная карта угловых полей имеет сходство в общих чертах, а в ней сохраняются характеристики изображения.

Метод диагностики

В соответствии с приведенными выше методами преобразования, в данной статье предлагается модель диагностики изображений методом КПП с помощью СНС, как показано на рис. 5.




Рис. 5. Модель диагностики изображений методом КПП с помощью СНС.

В данной модели одномерные вибрационные сигналы от подшипников сначала сжимаются по КПП-алгоритму, а затем создаются изображения после расчета УПГ или МПМ, или частотно-временной диаграммы вейвлета.

Операция свертки сначала выполняется через слой свертки для изучения локальных признаков входного изображения, после чего образец изображения вводится в СНС. Чтобы преодолеть проблему насыщения градиента функции активации, после слоя функции активации был введен слой пакетной нормализации [23] для нормализации входных данных функции активации к области с большим значением градиента. Через объединяющий слой карта входных признаков уменьшается для удаления избыточной информации. После нескольких циклов свертки, пакетной нормализации и операций объединения модель завершает обучение на основе признаков. Наконец, полученная информация о признаках, включая пространственные и временные особенности исходного изобра-

жения, вводится в полносвязный слой для повторной интеграции, точной настройки параметров и отображения в пространство меток образца. Для классификации множества повреждений используется функция softmax [24], математическое выражение которой выглядит следующим образом:

$$y_i = f(z_i) = \frac{e^{z_i}}{e^{z_1} + e^{z_2} + \dots + e^{z_M}} = \frac{e^{z_i}}{\sum_{j=1}^M e^{z_j}}, \quad (9)$$

где z_i — вход для i -го выходного нейрона; M — общее число выходных нейронов; f — функция активации Softmax, а $f(z_1) + f(z_2) + \dots + f(z_M) = 1$.

Чтобы ускорить весовое обучение, в качестве метода обучения в данной работе используется стохастический градиентный спуск с импульсом (СГСИ) [25]. Поскольку СГСИ склонен к неустойчивости вычислений из-за различий в выборке, что не способствует получению хороших результатов классификации, в работе используется метод минипакетов [26], а именно: из набора данных выбираются некоторые подмножества данных. Эти выбранные подмножества данных используются для расчета обновленного значения параметров сети, а затем среднее значение обновленных параметров применяют для настройки параметров всей сети, чтобы учесть стабильность и скорость обновления веса. В качестве функции потерь мы используем перекрестную энтропию, формула которой выглядит следующим образом:

$$H = -\frac{1}{m} \sum_{k=1}^m \sum_j p_k^j \log q_k^j, \quad (10)$$

где m — число элементов в минипакете; k — элемент с номером k в минипакете; j — целевой класс с номером j ; p_k^j — это унитарный вектор, который представляет истинную вероятность того, что элемент с номером k попадет в целевой класс j в минипакете; q_k^j — вектор выходной вероятности функции softmax для элемента с номером k в целевом классе j .

3. ОБРАЗЦЫ И ЭКСПЕРИМЕНТ

Источники данных и образцы

В качестве экспериментальных данных используются полученные в Университете Кейс Вестерн Резерв результаты по выявлению повреждений в подшипниках. Эти данные были получены в ходе экспериментов с радиальным шарикоподшипником (модель: 6205-2RS JEM SKF) [27]. Перед началом эксперимента на внутреннем кольце, наружном кольце и теле качения подшипника с помощью электроэрозионного станка были сделаны искусственные дефекты — одиночные вмятины разного диаметра. Диаметр и расположение вмятин показаны в табл. 1. Сигнал вибрации собирается акселерометром, который размещается в зоне нагрузки посадочного места подшипника ведущего конца на магнитном основании, а данные вибрации собираются 16-канальным цифровым самописцем с частотой дискретизации 12 кГц. Экспериментальная установка показана на рис. 6.



Рис. 6. Экспериментальная установка.

Таблица 1

Диаметр и расположение отдельных лунок

Диаметр, мм	Расположение
0,1778	ВнешК, ВнутК, ТК
0,3556	ВнешК, ВнутК, ТК
0,5334	ВнешК, ВнутК, ТК
0,7112	ВнутК, ТК

ВнутК: внутреннее кольцо; ВнешК: внешнее кольцо; ТК: тело качения

Для того, чтобы произвести обучение и верификацию сверточной нейронной сети, из исходного вибрационного сигнала непрерывно извлекается определенная длина данных и разбивается на несколько подпоследовательностей, как показано на рис. 7.




Рис. 7. Разбиение обучающей выборки.

Для того, чтобы уменьшить размер изображений, повысить скорость обучения нейронных сетей и обеспечить получение необходимой информации при считывании данных, длина подпоследовательности данных может быть рассчитана следующим образом:

$$n \geq \text{ceil} \left(\frac{60}{N} f_s \right), \quad (11)$$

где N — скорость оборота подшипника; f_s — частота дискретизации; n — длина данных выборки; ceil — оператор округления.

Подставляя минимальную скорость вращения подшипника в ходе эксперимента, минимальное значение n , которое можно вычислить, равно 417, поэтому длина подпоследовательности данных определяется равной 512. Размер изображения после уменьшения размерности методом КПП составлял $64 \times 64 \times 1$. Экспериментальные данные собраны с исправных и неисправных подшипников,

Таблица 2

Нагрузка двигателя и его обороты

Нагрузка двигателя, кВт	Обороты двигателя, об/мин
0	1797
0,74	1772
1,47	1750
2,21	1730

а типы повреждений разделены на повреждения внутреннего кольца, наружного кольца и тела качения. Подшипники с различными повреждениями находятся под воздействием четырех нагрузок двигателя, приведенных в табл. 2. Данные были разделены на подпоследовательности, и после уменьшения размерности с помощью КПП были созданы двумерные изображения.

Проектирование СНС

Разработанная сверточная нейронная сеть содержит в общей сложности 18 слоев, включая 1 входной слой, 3 сверточных слоя, 3 слоя пакетной нормализации, 4 слоя нелинейной активации, 3 слоя максимального объединения, 2 полносвязных слоя, 1 слой функции softmax и 1 выходной слой. Структурные характеристики СНС представлены в табл. 3.

Таблица 3

Параметры каждого слоя сверточной нейронной сети

Наименование	Примечание
Входной слой	64×64, 1 канал
Сверточный слой 1	Размер ядра свертки: 5×5, количество: 32 Размер заполнения: 2
Слой пакетной нормализации 1	Ускоряет сходимость сети во время обучения
Слой функции активации 1	Функция ReLU
Слой максимального объединения 1	Размер объединения: 3×3, шаг: 2
Сверточный слой 2	Размер ядра свертки: 5×5, количество: 32 Размер заполнения: 2
Слой пакетной нормализации 2	Ускоряет сходимость сети во время обучения
Слой функции активации 2	Функция ReLU
Слой максимального объединения 2	Размер объединения: 3×3, шаг: 2
Сверточный слой 3	Размер ядра свертки: 5×5, количество: 64 Размер заполнения: 2
Слой пакетной нормализации 3	Ускоряет сходимость сети во время обучения
Слой функции активации 3	Функция ReLU
Слой максимального объединения 3	Размер объединения: 3×3, шаг: 2
Полносвязный слой 1	Количество выходов: 64
Слой функции активации 4	Функция ReLU
Полносвязный слой 2	Количество выходов: 4
Слой функции Softmax	Рассчитывает вероятность выхода из полносвязного слоя
Слой классификации	Определяет класс дефекта в соответствии с определенной вероятностью

Как показано в табл. 3, в качестве нелинейной функции активации в слое функции активации после слоя свертки в данной работе мы выбираем ReLU, так как функция ReLU имеет быструю скорость сходимости и хорошую производительность по сравнению с другими функциями активации [22].

Количество минипакетов составляет 27, начальная скорость обучения — 0,01, коэффициент уменьшения скорости обучения — 0,1, количество циклов уменьшения скорости обучения — 20. Данные перетасовываются перед каждым циклом обучения или верификации, максимальное количество циклов — 100.

Набор образцов

Для того, чтобы улучшить обобщение классификации нейронной сети, различия в нагрузке игнорируются, внимание уделяется только меткам классов повреждений. Классы образцов делятся

на соответствующие нормальные, повреждения тела качения, повреждения внутреннего кольца и повреждения наружного кольца.

В связи с исследованием задачи диагностики незначительных повреждений (вмятин), в качестве источника данных мы выбираем данные от лунки с наименьшим диаметром 0,1778 мм. Каждый тип образов одномерного временного ряда вибрации подшипника рассчитывается в соответствии с вышеизложенным утверждением. Для каждого вида изображения количество образцов в нормальном состоянии составляет 1450, количество образцов с повреждениями тела качения — 950, количество образцов с повреждениями внутреннего кольца — 952 и количество образцов с повреждениями внешнего кольца — 953. Набор образцов для обучения, набор образцов для верификации и набор образцов для тестирования случайным образом делятся в соотношении 6:1:3.

4. ПРОЦЕСС И АНАЛИЗ ЭКСПЕРИМЕНТОВ

Сравнение способности к выявлению повреждений с помощью различных двумерных изображений

Для обучения используется следующее компьютерное оборудование: процессор I5-7500H; ОПЕРАТИВНАЯ ПАМЯТЬ 16 ГБ; GPU 1050Ti; видеопамять 4-5 Гб. Образцы изображений каждого из классов загружаются в СНС соответственно. После обучения кривая точности проверки и кривая значения функции потерь для каждой эпохи показаны на рис. 8.




Рис. 8. Сравнение точности контроля и функции потерь для каждого двумерного изображения: определение точности контроля (а); определение функции потерь (б).

Как можно судить из рис. 8, частотно-временная диаграмма вейвлета, ПУРГ и ПУСГ могут увеличить достоверность контроля до значения более чем 90 % и поддерживать высокий уровень в первых 15 эпохах обучения, в то время как точность контроля с помощью МПМ имеет низкую скорость роста. После 100 эпох обучения точность контроля для каждого метода ПУРГ: 98,07 %; ПУСГ 97,37 %, частотно-временная диаграмма вейвлета: 98,61 %; МПМ 77,44 %. Говоря об итоговой достоверности контроля, ПУРГ или ПУСГ или частотно-временная диаграмма вейвлета способны достичь значительно эффекта разрешения повреждений, в то время как МПМ хуже. Что касается значения функции потерь, ПУРГ/ПУСГ/частотно-временная диаграмма вейвлета (все три) могут быстро уменьшиться и стабилизироваться примерно до 0,1 в течение первых 5 циклов, а окончательная частотно-временная диаграмма вейвлета является относительно наименьшей, поэтому, в целом, эффект диагностирования образца с использованием частотно-временной диаграммы вейвлета является наилучшим. Матрица путаницы тестового набора ПУРГ, ПУСГ, частотно-временная диаграмма вейвлета и МПМ построена так, как показано на рис. 9.

Реальный класс дефекта	а				б				в				г							
	ТК	271	9	2	3	ТК	268	10	1	6	ТК	274	3		8	ТК	193	16	33	43
	ВнутК	4	281		1	ВнутК	8	275		3	ВнутК	4	282			ВнутК	16	261	5	4
	ВнешК			435		ВнешК	5		430		ВнешК			435		ВнешК	32	3	382	18
	Б/Д	4	2		280	Б/Д		1		285	Б/Д	3			283	Б/Д	54	6	10	216
	ТК	ВнутК	ВнешК	Б/Д		ТК	ВнутК	ВнешК	Б/Д		ТК	ВнутК	ВнешК	Б/Д		ТК	ВнутК	ВнешК	Б/Д	
Прогнозируемый класс дефекта																				

Рис. 9. Матрица путаницы для каждого набора тестовой выборки:

ПУРГ (а); ПУСГ (б); частотно-временная диаграмма вейвлета (в); МПМ (г); ВнутК — внутреннее кольцо; ВнешК — внешнее кольцо; ТК — тело качения; Б/Д — бездефектный.

Как видно из рис. 9, независимо от типа выборки ошибка контроля в основном возникает при повреждении тела качения, что указывает на то, что повреждение тела качения трудно выявлять, это может быть связано со сложными компонентами сигнала при повреждении тела качения.

Сравнение с другими моделями

Чтобы доказать эффективность этой модели, ее сравнивают с другими распространенными моделями машинного обучения. В качестве моделей сравнения используются ДКП, 2Н-ДКП и УКБ. С точки зрения структуры сети, каждая в своей основе содержит скрытый слой с числом нейронов 100, размер минипакета 27, число эпох обучения 100, а скорость первичного обучения 0,01. За исключением модели СНС в данной работе все остальные сопоставляемые модели проверяются на одномерных выборках данных вибрации подшипников без снижения размерности РАА, длина которых делится на 512 при том же наборе данных. Кривые точности обучения соответствующих моделей показаны на рис. 10, а количество параметров, время обучения и сравнение точности показаны в табл. 4.

Таблица 4

Сравнение эффективностей различных моделей машинного обучения

Модель	Точность контроля	Количество параметров	Время обучения
Вейвлет-КПП-СНС	0,9861	257412	7 мин 58 с
ДКП	0,8854	245604	2 мин 38 с
2Н-ДКП	0,8429	491204	3 мин 15 с
УРБ	0,8932	184304	2 мин 31 с




Рис. 10. Сравнение точности контроля каждой модели.

Как видно из рис. 10, достоверность предложенного метода увеличивается быстрее всего, и в конечном итоге она может быть стабилизирована на более высоком уровне. Из табл. 4. следует, что количество параметров обучения модели в данной работе умеренное, хотя время обучения не самое короткое, точность тестового набора самая высокая в пределах допустимого времени обучения. Подводя итог, можно сделать вывод, что предложенный метод имеет очевидные преимущества в достоверности контроля по сравнению с другими методами.

Выявление повреждений при снижении эксплуатационных характеристик подшипников

Для дальнейшего исследования возможностей обнаружения этим методом снижения эксплуатационных характеристик неисправного подшипника качения, в качестве метода генерации образа двумерного изображения выбирается частотно-временная диаграмма вейвлета с наилучшими показателями для выявления незначительных повреждений. Как показано в табл. 1, данные об одиночных повреждениях на различных частях внутреннего кольца, внешнего кольца и тела качения, диаметр лунки которых увеличивается от 0,1778 до 0,7112 мм, получены в виде образцов изображений, число образцов повреждений внутреннего кольца 3794, число образцов повреждений внешнего кольца 2856, число образцов повреждений тела качения 3798. Как указано выше, образцы обучающего, проверочного и тестового множеств случайным образом распределяются в соотношении 6:1:3. Следует отметить, что набор данных, используемый в данной работе, не содержит данных о повреждениях наружного кольца при диаметре лунки повреждения 0,7112 мм. Образцы помещаются в СНС для обучения и верификации. Условия обучения совпадают с вышеизложенным утверждением. Точность тестового набора в процессе обучения показана на рис. 11, а точность окончательного тестового набора — в табл. 5.




Рис. 11. Сравнение достоверности выявления различных повреждений при износе: ВнутК — внутреннее кольцо; ВнешК — внешнее кольцо; ТК — тело качения.

Таблица 5

Достоверность выявления различных повреждений при износе

Деталь	Точность контроля
ВнутК	0,9868
ВнешК	0,9907
ТК	0,8709

ВнутК: внутреннее кольцо; ВнешК: внешнее кольцо; ТК: тело качения

Как видно из рис. 11, при наличии повреждений внутреннего и внешнего кольца достоверность распознавания степени повреждения быстро увеличивается в первые несколько эпох и затем поддерживается на высоком уровне, в то время как при повреждении тела качения степень повреждения увеличивается относительно медленнее, а уровень распознавания относительно ниже. Из табл. 5 следует, что досто-

верность распознавания степени повреждения внутреннего и наружного колец намного выше, чем тела качения. В заключение следует отметить, что данный метод обладает определенной достоверностью в распознавании степени повреждения внутреннего кольца, внешнего кольца и тела качения, среди которых внутреннее кольцо и внешнее кольцо имеют относительно более высокую достоверность, а тело качения — относительно более низкую, что также указывает на то, что выявление повреждений тела качения является сложным и трудным.

5. ЗАКЛЮЧЕНИЕ

В данной работе в качестве основного метода выявления незначительных повреждений (вмятин) была рассмотрена СНС. Для достижения хорошего результата контроля и уменьшения времени обучения СНС, сигнал вибрации подшипника уменьшается и сжимается алгоритмом КПП для сохранения полной информации о сигнале, а затем преобразуется в различные образцы двумерного изображения методом ПУРГ/ПУСГ/частотно-временная диаграмма вейвлета /МПМ. При разработке СНС, чтобы преодолеть проблему насыщения градиента функции ReLU, после каждого слоя свертки добавляется слой пакетной нормализации. Метод СГСИ используется для быстрой настройки веса нейронной сети для ускорения обучения. Чтобы преодолеть нестабильность метода СГСИ в данной работе используется метод минипакетов.

Результаты исследования показывают, что:

- 1) путем преобразования одномерных временных рядов сигналов вибрации подшипников в ПУРГ/ПУСГ/частотно-временная диаграмма вейвлета СНС может быть эффективно использована для обучения и определения класса неисправности;
- 2) алгоритм КПП может уменьшить размерность данных, сохраняя при этом общую информацию о сигнале, что позволяет снизить нагрузку на аппаратное обеспечение для обучения модели;
- 3) временно-частотно-временная диаграмма вейвлета имеет некоторые преимущества в точности контроля и больше подходит для идентификации незначительных дефектов подшипников качения;
- 4) независимо от вида выборки двумерного изображения результат контроля внутреннего и внешнего кольца лучше, чем результат контроля тела качения;
- 5) по сравнению с ДКП/2Н-ДКП/УРБ предложенная модель имеет очевидные преимущества в достоверности контроля;
- 6) при обнаружении ухудшения эксплуатационных характеристик различных повреждений модель в данной работе имеет определенную достоверность идентификации повреждений внутреннего кольца, внешнего кольца и тела качения, причем достоверность идентификации повреждений внутреннего кольца и наружного кольца выше.

Данное исследование было поддержано исследовательскими фондами, поддерживающими проекты Политехнического института Шэньси (№ гранта 2022YKZD-001). Авторы заявляют об отсутствии конфликта интересов.

СПИСОК ЛИТЕРАТУРЫ

1. Jie L., Changjie L., Yuhao S., Xingwei S. A study on bearing fault diagnosis based on LSGAN-SqueezeNet // *Journal of Vibration and Shock*. 2022. V. 41. P. 293—300. <https://doi.org/10.13465/j.cnki.jvs.2022.12.036>
2. Xiaoli Z., Minping J. Fault Diagnosis of Rolling Bearing Based on Feature Reduction with Global-Local Margin Fisher Analysis // *Neurocomputing*. 2018. V. 315. P. 447—464. <https://doi.org/10.1016/j.neucom.2018.07.038>
3. Nibaldo R., Pablo A., Lida B., Guillermo C.G. Combining Multi-scale Wavelet Entropy and Kernelized Classification for Bearing Multi-fault Diagnosis // *Entropy*. 2019. V. 21. P. 15—25. <https://doi.org/10.3390/e21020152>
4. Xiaohui G., Shaopu Y., Yongqiang L., Rujiang H., Zechao L. Multi-sparsity-based blind deconvolution and its application to wheelset bearing fault detection // *Measurement*. 2022. V. 199. <https://doi.org/10.1016/j.MEASUREMENT.2022.111449>
5. Mingzhu L., Shixun L., Xiaoming S., Changzheng C. Early degradation detection of rolling bearing based on adaptive variational mode decomposition and envelope harmonic to noise ratio // *Journal of Vibration and Shock*. 2021. V. 40. P. 271—280. <https://doi.org/10.13465/j.cnki.jvs.2021.13.034>
6. Yong H., Hong W., Sui G. New fault diagnosis approach for bearings based on parameter optimized VMD and genetic algorithm // *Journal of Vibration and Shock*. 2021. V. 40. P. 184—189. <https://doi.org/10.13465/j.cnki.jvs.2021.06.025>
7. Xiaochi L., Shi X., Yundong S., Gongmin L., Jinyu T., Xi Z., Zhuang L. Rolling bearing fault diagnosis method based on GWO-NLM and CEEMDAN // *Journal of Aerospace Power*. 2022. P. 1—13. [10.13224/j.cnki.jasp.20210547](https://doi.org/10.13224/j.cnki.jasp.20210547)

8. Zihao L., Guangrui W., Qiao Z., Shuzhi D., Xin H., Haoxuan Z. Rolling Bearing Fault Diagnosis Based on Multi-scale Mixed Domain Feature Extraction and Domain Adaptation // Journal of Vibration, Measurement & Diagnosis. 2022. V. 42. P. 183—185. <https://doi.org/10.16450/j.cnki.issn.1004-6801.2022.01.028>
9. Xiaojuan L., Chengji S. Application of the P-box theory and HGWO-SVM in the fault diagnosis of rolling bearings // Journal of Vibration and Shock. 2021. V. 40. P. 234—241. <https://doi.org/10.13465/j.cnki.jvs.2021.22.032>
10. Ming W., Zhang D., Zhen Y., Yong L., Guoqian W. Dynamic mode decomposition and its application in early bearing fault diagnosis // Journal of Vibration and Shock. 2022. V. 41. P. 313—320. <https://doi.org/10.13465/j.cnki.jvs.2022.12.038>
11. Tianlong G., Zhenhai S., Chenzhong B., Liang C. Fault diagnosis of rolling bearing based on multi-scale convolutional neural network // Machinery Design & Manufacture. 2022. V. 20. P. 20—23. <https://doi.org/10.19356/j.cnki.1001-3997.20211105.003>
12. Xiaoxi D., Qingbo H. Energy-Fluctuated Multiscale Feature Learning With Deep ConvNet for Intelligent Spindle Bearing Fault Diagnosis // IEEE Transactions on Instrumentation and Measurement. 2017. V. 66. P. 1926—1935. <https://doi.org/10.1109/tim.2017.2674738>
13. Jiangtao J., Zifei X., Chun L., Wei-pao M., Jun-qing X., Kang S. Rolling bearing fault diagnosis based on deep learning and chaotic feature fusion // Control Theory & Applications. 2022. V. 39. P. 109—116.
14. Xiaoxia Y., Baoping T., Jing W., Lei D. Fault diagnosis for aero-engine accessory gearbox by adaptive graph convolutional networks under intense background noise conditions. 2021. V. 41. P. 78—86. <https://doi.org/10.19650/j.cnki.cjsi.J2107732>
15. Wang Z., Oates T. Encoding Time Series as Images for Visual Inspection and Classification Using Tiled Convolutional Neural Networks / Workshops at the Twenty-ninth Aai Conference on Artificial Intelligence, 2015
16. Chaolung Y., Zhixuan C., Chenyi Y. Sensor Classification Using Convolutional Neural Network by Encoding Multivariate Time Series as Two-Dimensional Colored Images // Sensors (Basel, Switzerland). 2020. V. 20. P. 168. <https://doi.org/10.3390/s20010168>
17. Hoonyong L., Kanghyeok Y., Namgyun K., Changbum R.A. Detecting excessive load-carrying tasks using a deep learning network with a Gramian Angular Field // Automation in Construction. 2020. V. 120. P. 103390. <https://doi.org/10.1016/j.autcon.2020.103390>
18. Zhupeng W., Jie C., Lianhua L., Lingling J. Fault diagnosis of wind power gearbox based on wavelet transform and improved CNN // Journal of Zhejiang University (Engineering Science). 2022. V. 56. P. 1212—1219. <https://doi.org/10.3785/j.issn.1008-973X.2022.06.020>
19. Sen L., Aiguo W., Xintao D., Cuiwei Y. MGNN. A multiscale grouped convolutional neural network for efficient atrial fibrillation detection // Compbiomed. 2022. V. 148. P. 105863. <https://doi.org/10.1016/J.COMPBIOMED.2022.105863>
20. Reddy B.L., Uma M.R.N., Nelleri A. Deep convolutional neural network for three-dimensional objects classification using off-axis digital Fresnel holography // Journal of Modern Optics. 2022. V. 69. P. 705—717. <https://doi.org/10.1080/09500340.2022.2081371>
21. Yuxian Z., Fang D. Load classification based on piecewise aggregate approximation of particle swarm optimization // Journal of Shenyang University of Technology. 2021. V. 43. P. 123.
22. Ang G., JianYong Z., Fei M., HaoYuan S., Xing Q., Yang X., Xuan L., MengLei G., DanQi L. Electricity Theft Detection Algorithm Based on Triplet Network // Proceedings of the CSEE. 2022. V. 42. P. 3975—3986. <https://doi.org/10.13334/j.0258-8013.pcsee.211040>
23. Yunwei P., Jiang G., Taotao L., Haixiao W. A Recognition Method for Radar Emitter Signals Based on Convolutional Neural Network with Multiple Learning Units // Journal of Beijing University of Posts and Telecommunications. 2021. V. 44. P. 74—82. <https://doi.org/10.13190/j.jbupt.2021-055>
24. Peng Y., Xiaoxu H., Yuhui H., Jin Y., Shi W., Lei L. Online alarm recognition of power grid dispatching based on BERT-DSA-CNN and a knowledge base // Power System Protection and Control. 2022. V. 50. P. 131. <https://doi.org/10.19783/j.cnki.pspc.210705>
25. Ren W., Junpeng H., Qidong Y., Tianren L., Ben Y. Research of LSTM model-based intelligent guidance of flight aircraft // Chinese Journal of Theoretical and Applied Mechanics. 2021. V. 53. P. 2054.
26. Hongrui Z., Guojun Y., Chengji Y., Guangming T., Zhan W., Zhongzhe H., Xiaoyang Z., Xuejun A. Survey on Network of Distributed Deep Learning Training // Journal of Computer Research and Development. 2021. V. 58. P. 100.
27. Wade A.S., Robert B.R. Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study // Mechanical Systems and Signal Processing. 2015. V. 64. P. 100—10.