

МЕТОД ВЫДЕЛЕНИЯ ПРИЗНАКОВ ДЕФЕКТОВ ПОДШИПНИКОВ, ОСНОВАННЫЙ НА РАЗЛОЖЕНИИ НА ВАРИАЦИОННЫЕ МОДЫ С ДРОБНЫМ ФУРЬЕ-ПРЕОБРАЗОВАНИЕМ

© 2022 г. Мин Хуэй Вэй^{1,2,*}, Лися Цзян^{1,2,**}, Ди Чжан^{3,***},
Бин Ван⁴, Фэн Мяо Ту^{1,2}, Пэн Бо Цзян^{1,2}

¹ Юго-западный нефтяной университет, Чэнду 610500, Китай

² Сычуаньский университет, Чэнду 610500, Китай

³ Синьцзиньский филиал летной академии гражданской авиации Китая,
Чэнду 611430, Китай

⁴ 3-607, Ченхуили, улица Дагана, Новый район Биньхай, Тяньцзинь, 300280, Китай
E-mail: *wmh881988@163.com; **jlx19982016@163.com; ***403750039@qq.com

Поступила в редакцию 23.10.2021; после доработки 23.12.2021

Принята к публикации 14.01.2022

Предложен новый метод выделения признаков дефектов, основанный на методе разложения на вариационные моды с дробным фурье-преобразованием (ДФП-РВМ). Во-первых, основная идея этого метода заключается в выполнении оптимального дробного фурье-преобразования (ДФП) исходного сигнала. Затем преобразованный сигнал подвергается разложению на вариационные моды (РВМ). Для решения проблемы, заключающейся в сложности определения порядка ДФП, предлагается метод центрального момента четвертого порядка (ЦМЧП) для определения оптимального порядка. А использование критерия асимметрии и эксцесса (КАЭ) оптимизирует параметры РВМ. Вследствие этого может быть оптимизирован и ДФП—РВМ. Наконец, вычисление эксцесса и фильтрации с помощью скользящего среднего (ФСС) разложенного сигнала, чтобы реализовать извлечение признаков дефектов. Экспериментальные результаты исследования показывают, что сигналы, извлеченные этим методом, содержат все больше и больше явных характеристических частот дефектов, что значительно повышает точность контроля дефектов в различных состояниях: нормального состояния подшипника, с дефектом внутреннего кольца, с дефектом тела качения, с дефектов наружного кольца и т.д.

Ключевые слова: дробное фурье-преобразование, разложение по вариационным модам, выделение признаков, диагностика дефектов.

DOI: 10.31857/S0130308222030058

1. ВВЕДЕНИЕ

Подшипник качения является одной из важных частей вращающихся механизмов, входящих в устройство таких транспортных средств, как локомотивы [1], подшипник имеет характеристики сложной конструкции, высокоскоростного движения и большой нагрузки. Подшипники качения являются одной из наиболее уязвимых частей вращающихся механизмов. Условия их эксплуатации оказывают огромное влияние на оборудование, в состав которых входят вращающиеся механизмы. Любая мелкая неисправность может повлиять на нормальную работу оборудования и нанести огромный ущерб стране и людям [2]. Если дефекты в подшипнике можно диагностировать до того, как он выйдет из строя, то можно не только свести к минимуму потери, но и снизить затраты на техническое обслуживание оборудования [3]. Поэтому необходимо диагностировать неисправности подшипников качения. Однако при измерениях сигналы, свидетельствующие о неисправностях подшипников качения, часто смешиваются с большим количеством сигналов помех, что делает собранные сигналы нестационарными и нелинейными. Способ извлечения необходимой информации о характеристиках неисправностей из этих сигналов стал ключом к диагностике неисправностей подшипников качения [4].

Huang и др. [5] предложил метод разложения на эмпирические моды (РЭМ), который адаптивно извлекает эмпирических моды, отражающие основные характеристики сигнала (в соответствии с локальной структурой признаков сигнала на временной шкале), но алгоритму не хватает теоретической поддержки, появятся конечные эффекты и модальное наложение, которые будут влиять на результаты обработки сигнала. Wu Zhenhua и др. [6] представили шумовой метод анализа сигналов при РЭМ и предложили множественное разложение на эмпирические моды (МРЭМ). Хотя этот метод в определенной степени подавляет явление модового алиасинга, эффект не является полным и будет создавать ложные компоненты, а добавление шума увеличивает ошибку восстановления. В 2014 г. Dragomiretskiy и др. [7] предложил разложение на вариационные моды, новый нерекурсивный адаптивный метод обработки сигналов. В последние годы этот метод стал центром

исследований, но они все лишь привели к улучшению в целочисленной области. Из-за ограниченный самый алгоритма проблемы чрезмерного и недостаточного разложения неизбежны.

На основе вышеуказанных исследований в данной статье предлагается ДФП—РЭМ-метод выделения признаков, основанный на оптимизации ЦМЧП и КАЭ. Во-первых, ЦМЧП используется для определения оптимального порядка ДФП. Сигнал подвергается ДФП оптимального порядка. Во-вторых, оптимальные параметры РВМ определяются по КАЭ, а преобразованный сигнал подвергается РВМ. После этого коэффициенты эксцесса и ФСС разложенного сигнала рассчитываются как собственные векторы. Наконец, вектор признаков вводится в классификатор случайного леса для контроля дефектов. По сравнению с методами разложения на вариационные моды, эмпирические моды и множественное разложение на эмпирические моды, метод, предложенный автором статьи, имеет более высокую точность распознавания.

Структура этой статьи следующая. Во втором разделе выводится модель ДФП и предлагается метод определения ее оптимального порядка. В разделе 3 дается введение в РВМ и предлагается лучший метод получения параметров. В разделе 4 описан процесс реализации алгоритма ДФП—РВМ. В разделе 5 приведены эксперименты, иллюстрирующие эффективность предлагаемого метода, а окончательные выводы приведены в разделе 5.

2. ДРОБНОЕ ФУРЬЕ-ПРЕОБРАЗОВАНИЕ

2.1. Определение дробного фурье-преобразования

ДФП, как более обобщенное фурье-преобразования в пространстве области преобразования, позволяет представить сигнал на оси координат, повернутой на любой угол по оси времени, и в определенной степени информация во временной области и информация в частотной области объединяются. Затем выделяются некоторые его параметры [8]. Из-за нестационарного характера сигнала неисправности в последние годы для диагностики неисправностей применялся метод комбинирования ДФП и разложения сигнала [9—12]. Первым, кто дал его определение с математической точки зрения, был Namias [13], который проводил исследования и анализ с точки зрения собственных значений и собственных функций:

Традиционное преобразование Фурье определяется как непрерывный линейный оператор, существующий в пространстве сигналов. Характеристическое уравнение, соответствующее этому оператору, имеет вид:

$$\xi \psi_n(t) = \lambda_n \psi_n(t) = e^{-\frac{jn\pi}{2}} \psi_n(t), n = 0, 1, 2, 3, \dots \quad (1)$$

Уравнение (1) — это определение преобразования Фурье, данное с точки зрения собственных значений и собственных функций, где λ_n — собственное значение; $\psi_n(t)$ — собственная функция, которая может быть выражена как $\psi_n = H_n(t)e^{-t^2/2}$, где $H_n(t)$ — полином Эрмита порядка n и выражается как

$$H_n(t) = (-1)^n e^{t^2/2} \frac{d^n e^{-t^2/2}}{dt^n}. \quad (2)$$

Как можно видеть из формулы (1), преобразование Фурье сигнала ψ_n эквивалентно произведению самого себя на комплексное число λ_n . Далее будет введено определение, которое может быть непосредственно выведено из основного определения ДФП.

Определение 1: пусть ψ_n — собственная функция с собственным значением λ_n при обычном преобразовании Фурье, выражаемая как функция Эрмита—Гаусса, и может быть использована как собственная функция конечного пространства сигналов. Затем дробное фурье-преобразование может быть определено как линейное и удовлетворять:

$$\xi^p \psi_n(t) = \lambda_n^p \psi_n(u) = \left(e^{-\frac{jn\pi}{2}} \right)^p \psi_n(u) = e^{-\frac{jnp\pi}{2}} \psi_n(u), n = 0, 1, 2, 3, \dots \quad (3)$$

Уравнение (3) определяет дробное фурье-преобразование через собственную функцию и собственное значение. Согласно выражению выше, функция с конечной энергией $x(t)$ может быть сначала разложена в линейную суперпозицию собственных функций фурье-преобразования, а затем записана как

$$x(t) = \sum_{n=0}^{\infty} X_n \psi_n(t), \quad (4)$$

где коэффициент разложения $X_n = \int \psi_n(t)x(t)dt$. Тогда пусть ДФП по обеим концам формулы:

$$\xi^p x(t) = \sum_{n=0}^{\infty} e^{-\frac{jpn\pi}{2}} X_n \psi_n(u) = \int \sum_{n=0}^{\infty} e^{-\frac{jpn\pi}{2}} \psi_n(u) \psi_n(t) x(t) dt. \quad (5)$$

Уравнение (5) называется спектральным разложением ядра ДФП, и функция Эрмита—Гаусса ψ_n должна удовлетворять:

$$e^{-j2\pi ut} = \sum_{n=0}^{\infty} e^{-\frac{jn\pi}{2}} \psi_n(u) \psi_n(t), \quad (6)$$

$$\sqrt{1-j\cot\alpha} \cdot e^{j\pi(u^2 \cot\alpha - 2ut \csc\alpha + t^2 \cot\alpha)} = \sum_{n=0}^{\infty} e^{-\frac{jn\pi}{2}} \psi_n(u) \psi_n(t), \quad (7)$$

где $\alpha = p\pi/2$. Из указанной выше формулы может быть видно, что когда $p = 1$, ДФП становится традиционным фурье-преобразованием. В то же время основное определение ДФП [14]:

$$X_p(u) = \int_{-\infty}^{+\infty} K_\alpha(u, t) x(t) dt, \quad 0 < p < 2, \quad 0 < \alpha < \pi, \quad (8)$$

где $K_\alpha(u, t)$ — функция ядра ДФП:

$$K_\alpha(u, t) = \begin{cases} B_\alpha e^{[j\pi(t^2 \cot\alpha + u^2 \cot\alpha - 2ut \csc\alpha)]}, & \alpha \neq n\pi \\ x(u-t), & \alpha = 2n\pi \\ x(u+t), & \alpha = (2n \pm 1)\pi \end{cases}. \quad (9)$$

Сравнивая формулу (8) с формулой (5), функции ядра $K_\alpha(u, t) = e^{-\frac{jpn\pi}{2}} \psi_n(u) \psi_n(t)$ и $B_\alpha = \sqrt{(1-j\cot\alpha)/2\pi}$, где α — это угол вращения, а связь с порядком p следующая: $\alpha = \frac{p\pi}{2}$.

В 1993 г. Almeida указал на физический смысл ДФП. Он интерпретировал ДФП как вращение в частотно-временной плоскости. Как показано на рис. 1, на частотно-временной плоскости осуществляется вращение (t, ω) на угол α против часовой стрелки и его преобразование в домен (u, v) , чтобы получить новое представление сигнала. Следовательно, используя ДФП, можно проследить преобразование всех характеристик сигнала из временной области в частотную, изменяя угол α или порядок p .

2.2. Порядок выбора дробного фурье-преобразования

Сигнал может получить свою полосу пропускания во временной или частотной области посредством оценки центрального момента второго порядка [15]. Из оценки центрального момента второго порядка дробного фурье-преобразования сигнала можно получить ширину полосы сигнала в области дробного фурье-преобразования [16, 17]. Но он очень чувствителен к помехам и его оценочный эффект очень слаб, когда отношение сигнал/шум низкое, поэтому в этой статье используется центральный момент четвертого порядка дробного фурье-преобразования:

$$P_\alpha = \int_{-\infty}^{\infty} |R_x^\alpha(u)|^4 (u - m_\alpha)^4 du, \quad (10)$$

где $R_x^\alpha(u)$ — α — порядок ДФП сигнала и m_α — центральный момент первого порядка дробного фурье-преобразования:




Рис. 1. Схематичная диаграмма вращения в частотно-временной плоскости при дробном фурье-преобразовании.

$$m_{\alpha} = \int_{-\infty}^{\infty} |R_x^{\alpha}(u)|^2 u du. \quad (11)$$

Рассчитывая центральный момент четвертого порядка дробного фурье-преобразования, может быть получен спектр центрального момента четвертого порядка дробного фурье-преобразования. Когда сигнал имеет наименьшую полосу пропускания при дробном фурье-преобразовании, центральный момент четвертого порядка при ДФП сигнала будет иметь максимальное значение в соответствующей области. Поскольку ДФП имеет период 2π и существует формула (12), в интервале $\alpha \in [0, \pi)$ будет наблюдаться максимум. Значение величины α , соответствующее каждой компоненте сигнала, может быть найдено при нахождении локального максимума. Такое значение позволяет сигналам иметь наименьшую полосу пропускания в домене ДФП:

$$R_x^{\alpha+\pi}(u) = R_x^{\alpha}(-u). \quad (12)$$

3. РАЗЛОЖЕНИЕ НА ВАРИАЦИОННЫЕ МОДЫ

3.1. Определение разложения на вариационные моды

Основная идея алгоритма РВМ заключается в том, что большая часть каждой моды исходного сигнала тесно связана с конкретной центральной частотой [18, 19]. С помощью фильтрации Винера, смещения частот и преобразования Гильберта проблема полосы пропускания каждой подмоды разбивается на несколько задач ограничения, а затем используется ряд итерационных методов решения для получения оптимального решения центральной частоты [20]. По сравнению с традиционным методом РЭМ, математическая основа РВМ является более прочной, с лучшими характеристиками сходимости и большей надежностью [21].

Таким образом, РВМ окончательно раскладывает заданный сигнал $f(t)$ на k ЭМ и обеспечивает, чтобы сумма общей ширины полосы разложенных ЭМ была наименьшей. Опишем дальнейшие шаги реализации алгоритма. Во-первых, получить аналитический сигнал каждой ЭМ посредством преобразования Гильберта и рассчитать соответствующий односторонний частотный спектр [22]:

$$\left[\delta(t) + \frac{j}{\pi t} \right] \cdot u_k(t). \quad (13)$$

После этого оценивается центральная частота каждой ЭМ, и частотный спектр каждой ЭМ модулируется в соответствующую полосу частот посредством смещения частот:

$$\left\{ \left[\delta(t) + \frac{j}{\pi t} \right] \cdot u_k(t) \right\} \cdot e^{-j\omega_k t}. \quad (14)$$

Наконец, для расчета нормы квадрата градиента сигнала модуляции L^2 используется гауссова фильтрация. И, исходя из этого, оценивается полоса пропускания каждой ЭМ, а сумма ЭМ полос пропускания минимизируется посредством уравнения ограничения. Выражение уравнения:

$$\left\{ \begin{array}{l} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| d_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot e^{-j\omega_k t} \right] \right\|_2^2 \right\}, \\ s.t. \sum_k u_k = f \end{array} \right. \quad (15)$$

где d_t представляет собой частную производную по времени t ; функции $\{u_k\} = \{u_1, u_2, u_3, \dots, u_k\}$ представляют собой k -е ЭМ-компоненты, полученные при разложении сигнала $\{\omega_k\} = \{\omega_1, \omega_2, \omega_3, \dots, \omega_k\}$, F — центральная частота каждой ЭМ. Вводится расширенное уравнение Лагранжа с квадратичной поправкой на потери α и оператором множителя Лагранжа λ , так что вышеуказанное вариационное уравнение ограничения преобразуется в вариационное уравнение без ограничений и получается оптимальное решение модели:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] \cdot e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle. \quad (16)$$

Из-за увеличения поправки на потери и оператора множителя Лагранжа модель имеет большую точность распознавания и более строгие ограничения при наличии белого гауссова шума. Метод переменного направления множителей используется для поочередного обновления u_k^{n+1} , ω_k^{n+1} и λ^{n+1} в уравнении (16), чтобы получить седловую точку уравнения в вариациях без ограничений:

$$u_k^{n+1} = \arg \min \left\{ \alpha \left(\left\| \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] \cdot e^{-j\omega_k t} \right\|_2^2 \right) + \left\| f(t) - \sum_i u_i(t) \right\|_2^2 \right\}, \quad (17)$$

где ω_k эквивалентно ω_k^{n+1} , а $\sum_{i \neq k} u_i(t)$ также эквивалентно $\sum_{i \neq k} u_i^{n+1}(t)$. Затем используется эквидистантное преобразование Фурье для преобразования вышеуказанного уравнения в частотно-временной области и $\omega - \omega_k$, чтобы провести замену переменной на ω для получения следующего уравнения:

$$\left\{ \begin{array}{l} \hat{u}_k^{n+1} = \arg \min \left\{ \alpha \left(\left\| j(\omega - \omega_k) \left[(1 + \text{sgn}(\omega)) \hat{u}_k(\omega) \right] \right\|_2^2 \right) + \kappa \right\} \\ \kappa = \left\| \hat{f}(\omega) - \sum_i \hat{u}_i(\omega) + \frac{\hat{\lambda}^2(\omega)}{2} \right\|_2^2 \end{array} \right. \quad (18)$$

Используя преимущество симметрии эрмитового реального сигнала, уравнение (18) преобразуется в интегральное уравнение в полупространстве с неотрицательной частотой. Вместе с этим обновленное уравнение u_k^{n+1} может быть получено при квадратичной оптимизации:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}^2(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2}. \quad (19)$$

Схожим образом, в соответствии с условием ограничения минимальной суммы пропускных полос, задача минимума преобразуется в частотную область с использованием эквидистантного преобразования Фурье и получается переменное обновленное уравнение ω_k^{n+1} и λ^{n+1} :

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega}, \quad (20)$$

$$\lambda_k^{n+1} = \lambda^n + \tau(f(t) - \sum_k u_k^{n+1}). \quad (21)$$

РВМ использует метод рекурсивного цикла для разделения исходного сигнала слой за слоем [23], эффективно избегая недостатков модального алиасинга РЭМ, и имеет возможность адаптации [24]. В то же время РВМ использует принцип фильтра Винера для построения задачи с вариационными ограничениями, так что сигнал может быть эффективно и точно разложен в условиях интерференции гауссовского шума [30]. Полученная мода частотной модуляции и амплитудной модуляции (ЧМ—АМ) преобразуется во временной области по эквидистантной теореме Фурье, а затем получаются полоса пропускания и центральная частота каждого компонента, так что каждая мода отражает характеристики различных частотных диапазонов разложенного сигнала [25].

3.2. Выбор параметров алгоритма разложения на вариационные моды

Хотя алгоритм РВМ преодолевает недостатки традиционного РЭМ и его усовершенствованных методов, необходимо установить уровень разложения K и поправку на потери α перед разложением. Выбор параметров оказывает большое влияние на результаты разложения [26]. В этой статье для оптимизации параметров используется КАЭ [27]. Эксцесс — это числовая статистическая величина, отражающая распределение случайных величин. Это безразмерный параметр, очень чувствительный к импульсным сигналам [28]. Эксцесс демонстрирует высокую повторяемость в подшипниках. В момент, когда подшипник только вводится в эксплуатацию, будучи исправным, распределение амплитуды его вибрационного сигнала близко к нормальному распределению, а значение эксцесса составляет около 3. Когда подшипник начинает выходить из строя, амплитуда сигнала будет значительно отклоняться от нормального распределения, а значение эксцесса будет соответственно увеличиваться. В таком случае можно считать, что произошла поломка. И значение эксцесса при разных неисправностях подшипника также будет разным [29, 30]. Стандартное отклонение может отражать степень дисперсии между отдельными элементами в группе набора данных и результат измерения величины дисперсии. КАЭ может отражать разницу между различными ЭМ после РВМ. Чем больше КАЭ, тем больше разница между различными ЭМ.

4. АЛГОРИТМ РАЗЛОЖЕНИЯ, ОСНОВАННЫЙ НА ДФП—РВМ

В данной статье предлагается новый метод выделения признаков при ДФП—РВМ, основанный на ЦМЧП—СКОЭ-оптимизации. Основная идея этого метода состоит в том, чтобы отобразить плохо разделяемые данные в исходных данных в соответствующее пространство дробного порядка, а затем провести РВМ. Экспериментальные данные предоставлены подшипниковым дата-центром электротехнической лаборатории Западного резервного университета Кейза. Модель подшипника качения SKF6205. Скорость вращения двигателя составляет 1797 об/мин, а частота дискретизации — 12 кГц. Диаметр дефекта подшипника со стороны привода составляет 0,1778 мм. Характеристическая частота данных неисправности составляет 107,365 Гц. Конкретные шаги и блок-схема следующие (рис. 2).

Шаг 1: после вычисления центрального момента четвертого порядка каждого дробного порядка находится максимальное значение центрального момента четвертого порядка; соответствующий угол преобразования является оптимальным углом ДФП, по данным выполняется оптимальное ДФП.

Шаг 2: рассчитывается КАЭ, при котором α увеличивается с 1000 до 10000 с шагом 100. K увеличивается с 2 до 11 с шагом 1. Выполняется оптимизация поправки на потери α и уровня разложения K , затем производится РВМ по данным после ДФП.

Шаг 3: выполняется обратное ДФП на каждой ЭМ после РВМ.

Шаг 4: выполняется анализ спектра огибающей по каждой ЭМ.

Из рис. 3 видно, что когда X равно 1,028, значение центрального момента четвертого порядка является наибольшим, поэтому оптимальный порядок ДФП равен 1,028. Затем рассчитывается КАЭ, где поправка на потери α увеличивается от 1000 до 10000 с шагом 100. K увеличивается с 2

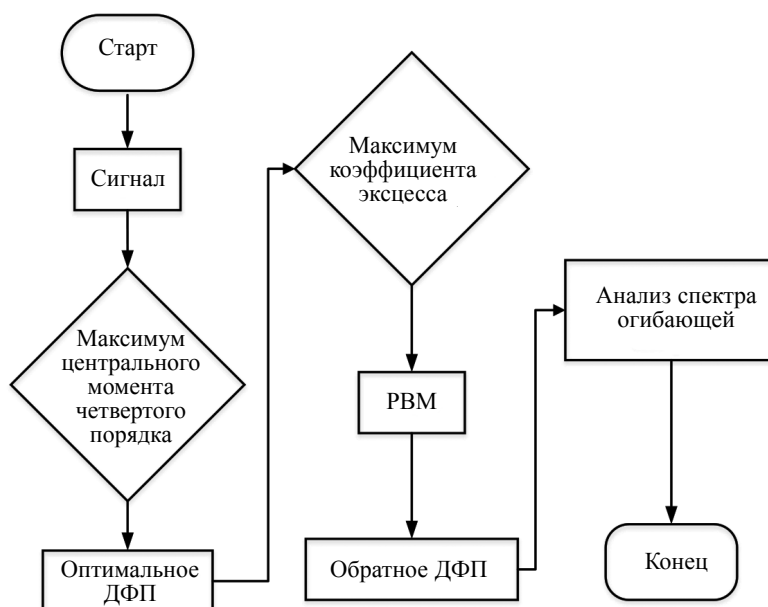


Рис. 2. Блок-схема ДФП—РВМ, оптимизированного по ЦМЧП—КАЭ.

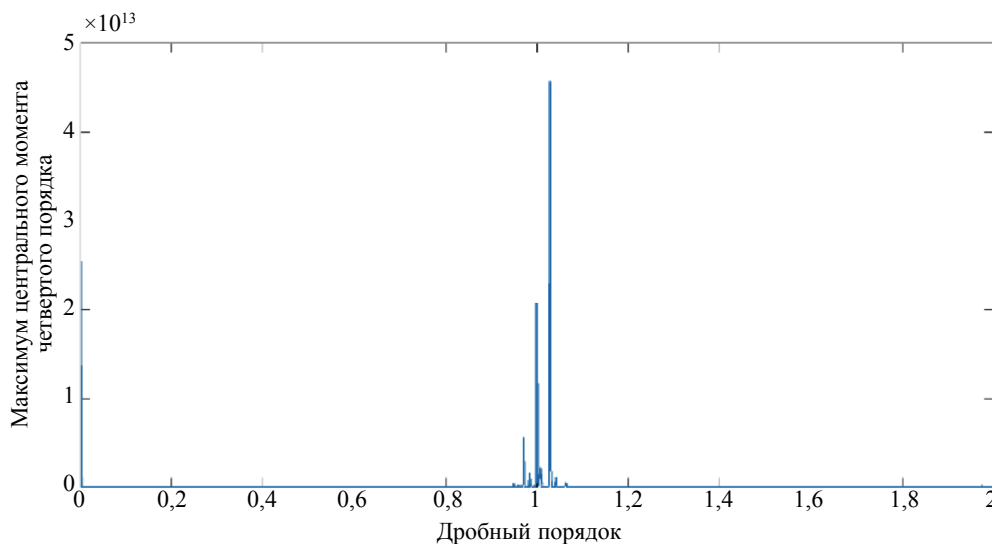


Рис. 3. Порядок ДФП.

до 11 с шагом 1. Из рис. 4 видно, что поправка на потери α увеличивается в 15 раз, что равно 2500, а число уровней разложения K увеличивается в три раза, что равно 4. Видно, что оптимальные параметры α и K РВМ равны 2500 и 4 соответственно.

Из рис. 6 видно, что как разложение РВМ, так и ДФП—РВМ, оптимизированное по ЦМЧП—КАЭ могут эффективно извлекать характеристическую частоту дефекта 107 Гц в сигнале от дефекта. Однако ЭМ1 из РВМ, очевидно, не может выделить характеристическую частоту дефекта, а четыре ЭМ, основанные на ДФП—РВМ, оптимизированные по ЦМЧП—КАЭ, предлагаемые в этой статье, вполне могут выделить среднюю характеристическую частоту дефекта и ее частотное умножение.

В то же время, сравнивая амплитуду характеристической частоты, извлеченную двумя методами, амплитуда характеристической частоты и соответствующий ей множитель частоты на основе

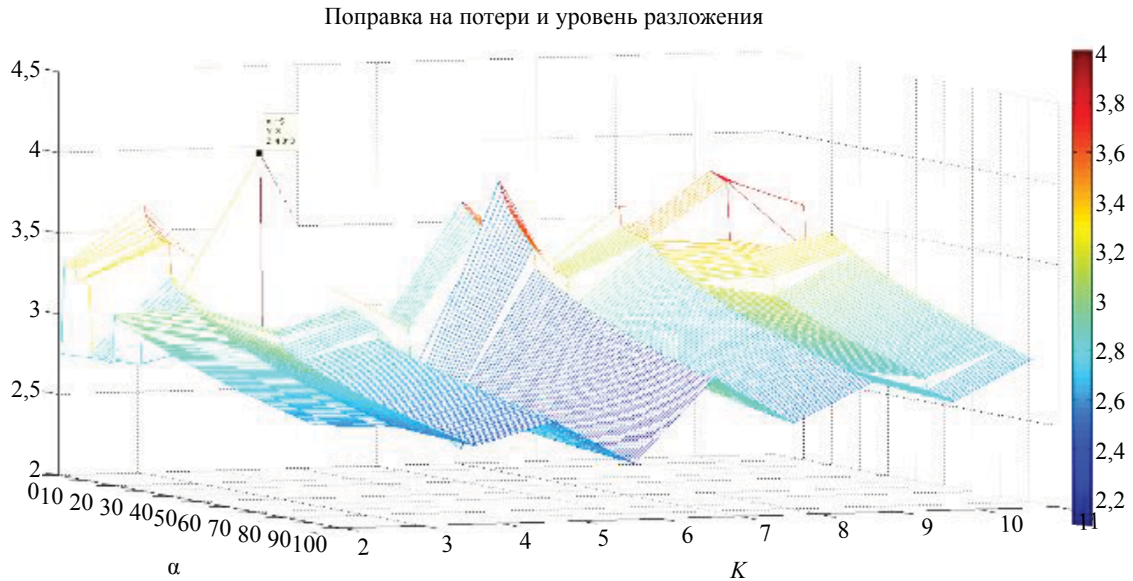


Рис. 4. Оптимизация поправок на потери и уровни разложения.




Рис. 5. Компоненты ДФП—РВМ, оптимизированного по ЦМЧП—КАЭ.

метода ДФП—РВМ, оптимизированного по ЦМЧП—СКОЭ, очевидно больше амплитуды характеристической частоты, полученной из РВМ. Выше показано, что метод, предложенный в данной статье, может предоставить более эффективную информацию о характеристиках дефекта для диагностики подшипников.

5. ЭКСПЕРИМЕНТАЛЬНОЕ ПОДТВЕРЖДЕНИЕ

5.1. Процедура эксперимента

В этом разделе для дальнейшей проверки роли этого метода в диагностике дефектов подшипников для экспериментальной проверки будут использованы данные из базы данных Западного резервного университета и данных, полученных на построенной в этом университете экспериментальной платформе. Конкретный экспериментальный процесс показан на рис. 7.




Рис. 6. Спектр огибающей каждой компоненты:
a — спектр огибающей компоненты ДФП—РВМ, основанный на ЦМЧП—КАЭ; *б* — спектр огибающей каждой компоненты РВМ.

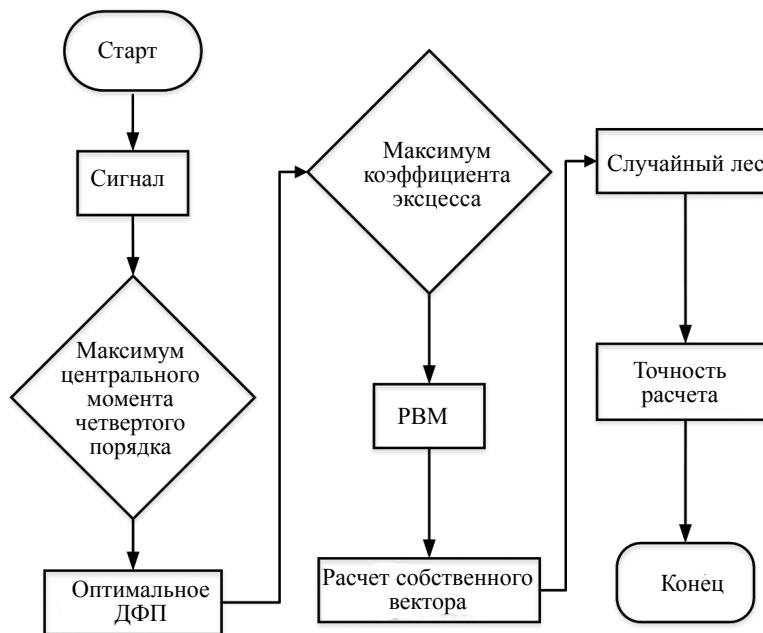


Рис. 7. Блок-схема эксперимента.

5.2. Диагностика дефектов

Используемые экспериментальные данные взяты из базы данных подшипников Западного резервного университета. Экспериментальная платформа состоит из двигателя мощностью 1,5 Вт, датчика крутящего момента, тестера мощности и электронного контроллера. Дефект подшипника — это одноточечное повреждение от электроискровой обработки (ЭИО). Модель подшипника SKF6205, частота дискретизации 12 кГц. Используемые данные являются нормальными базовыми данными для скорости 1797 об/мин. Дефектные подшипники так же вращались со скоростью 1797 об/мин, а диаметр неисправности составляет 0,1778 мм. Временная диаграмма данных показана на рис. 8.

Чтобы проиллюстрировать эффективность ДФП—РВМ, оптимизированного по ЦМЧП—КАЭ при извлечении признаков дефектов сигналов подшипника, в этой статье в качестве векторов признаков дефектов используются коэффициент эксцесса и ФСС. Коэффициент эксцесса и ФСС очень чувствительны к импульсному сигналу дефекта подшипника. Когда подшипник выходит из строя, значения этих двух характеристик значительно изменяются [31]. Векторы признаков, извлеченные с помощью ДФП—РВМ, оптимизированного по ЦМЧП—КАЭ, и векторы признаков, извлеченные с помощью РВМ, РЭМ и МРЭМ, соответственно кластеризуются. Из графика результатов класте-




Рис. 8. Исходная временная диаграмма подшипника в каждом состоянии.

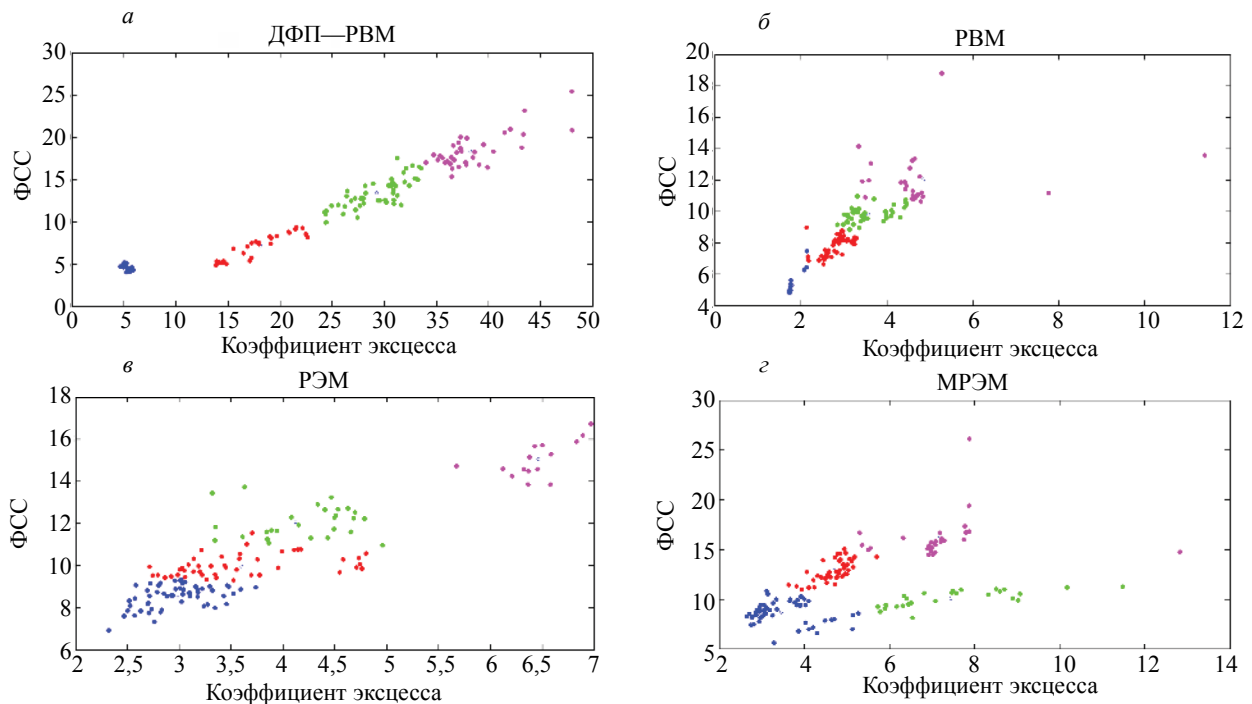


Рис. 9. График результатов кластеризации: а — график кластеризации дробного РВМ; б — график результата кластеризации РВМ; в — график кластеризации РЭМ; г — график кластеризации МРЭМ.

ризации на рис. 9 видно, что векторы признаков, извлеченные с помощью ДФП—РВМ, оптимизированного по ЦМЧП—КАЭ, обладают сильными свойствами кластеризации. Однако эффект кластеризации векторов признаков, извлеченных с помощью РВМ, РЭМ и МРЭМ, слабый, а типы дефекты нечеткие и разрозненные.

Чтобы в дальнейшем проверить эффективность предложенного метода, в этой статье в качестве векторов признаков дефекта используются коэффициенты эксцесса и ФСС, а для диагностики неисправности используется классификатор случайного леса [32]. Во-первых, различные типы неисправностей разделены на 10 групп по 10 000 данных, которые в общей сложности разделены на 40 групп данных. Выполняется ДФП—РВМ, оптимизированного по ЦМЧП—КАЭ для этих 40 наборов данных. Во-вторых, коэффициент эксцесса и ФСС извлекаются из полученных ЭМ в виде векторов признаков дефектов. Для каждого типа неисправности будет получено 40 наборов векторов признаков коэффициента эксцесса и ФСС. Наконец, 32 группы различных типов дефектов используются в качестве обучающего набора классификатора случайного леса, а 8 групп используются в качестве данных тестового набора для проверки точности классификации всей модели. Количество каждого состояния подшипника — как показано в табл. 1. Устанавливается количество деревьев решений в классификаторе случайного леса равным 800, а затем выполняется диагностика дефектов. Используется РВМ, РЭМ и МРЭМ для извлечения соответствующих векторов признаков дефектов из одних и тех же данных и отправки их в классификатор случайного леса для диагностики дефектов.

Таблица 1

Число подшипников в различных состояниях

Состояние подшипника	Обучающий набор	Тестовый набор	Номер
Норма	32	8	1
Дефект внутреннего кольца	32	8	2
Дефект тела качения	32	8	3
Дефект внешнего кольца	32	8	4

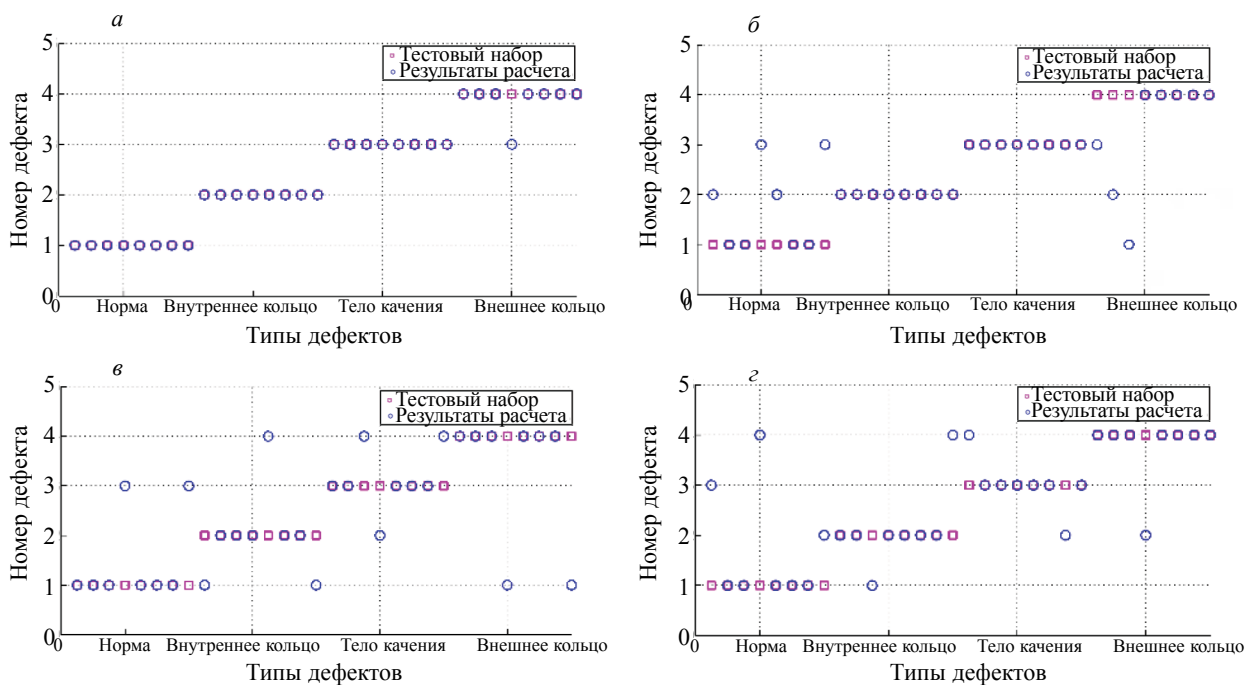


Рис. 10. График результатов классификации:

a — диаграмма результатов ДФП—РВМ-классификации; *b* — диаграмма результатов РВМ-классификации; *v* — диаграмма результатов РЭМ-классификации; *z* — диаграмма результатов МРЭМ-классификации.

В ходе контроля тестового набора результаты классификации четырех методов показаны на рис. 10. Из рисунка видно, что векторы признаков между различными типами дефектов, извлеченные методом выделения признаков ДФП—РВМ, оптимизированного по ЦМЧП—КАЭ, могут быть лучше идентифицированы и классифицированы. График результатов классификации показывает, что прогнозируемый результат в основном соответствует ожидаемому значению. В результатах классификации трех других методов наблюдается большое расхождение между прогнозируемым результатом и ожидаемым значением.

Результаты классификации при использовании четырех различных методов обобщены в табл. 2—5 соответственно. Общая точность процедуры классификации, полученная с использованием метода выделения признаков ДФП—РВМ, оптимизированного по ЦМЧП—КАЭ, составляет 93,75 %. Общая точность классификации на основе РВМ-метода выделения признаков составляет 78,1 %. Общая точность классификации на основе РЭМ-метода выделения признаков составляет 68,75 %. Общая точность классификации, основанной на методе выделения признаков МРЭМ, составляет 75 %. Экспериментальные результаты показывают, что векторы признаков, полученные на основе дробного РЭМ, имеют лучшее разрешение.

Таблица 2

Результаты ДФП—РВМ-классификации

Состояние подшипника	Размер дефекта, мм	Номер	Обучающая выборка	Количество правильно классифицированных образцов	Точность, %
Норма	—	1	8	8	100
Дефект внутреннего кольца	0,1778	2	8	8	100
Дефект тела качения	0,1778	3	8	8	100
Дефект внешнего кольца	0,1778	4	8	7	87,5
Итого	—	—	32	31	96,875

Таблица 3

Результаты РВМ-классификации

Состояние подшипника	Размер дефекта, мм	Номер	Обучающая выборка	Количество правильно классифицированных образцов	Точность, %
Норма	—	1	8	4	50
Дефект внутреннего кольца	0,1778	2	8	8	100
Дефект тела качения	0,1778	3	8	8	100
Дефект внешнего кольца	0,1778	4	8	5	62,5
Итого	—	—	32	25	78,1

Таблица 4

Результаты РЭМ-классификации

Состояние подшипника	Размер дефекта, мм	Номер	Обучающая выборка	Количество правильно классифицированных образцов	Точность, %
Норма	–	1	8	6	75
Дефект внутреннего кольца	0,1778	2	8	5	62,5
Дефект тела качения	0,1778	3	8	5	62,5
Дефект внешнего кольца	0,1778	4	8	6	75
Итого	–	–	32	22	68,75

Таблица 5

Результаты МРЭМ-классификации

Состояние подшипника	Размер дефекта, мм	Номер	Обучающая выборка	Количество правильно классифицированных образцов	Точность, %
Норма	–	1	8	5	62,5
Дефект внутреннего кольца	0,1778	2	8	6	75
Дефект тела качения	0,1778	3	8	6	75
Дефект внешнего кольца	0,1778	4	8	7	87,5
Итого	–	–	32	24	75

5.3. Диагностика на наличие дефектов по данным измерений

В этом разделе проводятся эксперименты по диагностике неисправностей по данным, измеренным на самодельной экспериментальной установке для подшипников качения. Экспериментальная установка для работы с подшипниками качения состоит из двух частей: вращающегося механизма и системы сбора данных (как показано на рис. 11). Часть вращающегося механизма состоит из нормальных/дефектных подшипников и трехфазного двигателя с короткозамкнутым ротором. Подшипник устанавливается на конце вращающегося вала трехфазного двигателя с короткозамкнутым ротором, а скорость вращения измеряется фотоэлектрическим датчиком. Система сбора данных состоит из датчика ускорения ICP, установленного на валу двигателя, и 24-битного сетевого устройства для распределенного сбора данных INV 3060A (включает встроенное служебное программное обеспечение Coinv DASP V10 для сбора данных). Дефект подшипника получают при помощи ЭИО. Прямую линию глубиной и шириной 0,2 мм получают на внутреннем кольце, на внешнем кольце и на шаре для имитации их дефектов. Частота дискретизации составляет 12 кГц, а экспериментальная установка показана на рис. 12.

С помощью экспериментальную установки получены данные по вибрации для четырех состояний, количество данных составило около 119 000 точек. В первую очередь, данные по вибрации для каждого состояния подшипника разделяются и группируются так, что каждая группа имеет 10 000 точек из выборки и итого имеется 20 групп для каждого состояния подшип-




Рис. 11. Блок-схема экспериментальной установки.




Рис. 12. Внешний вид экспериментальной установки.

ника. В общей сложности имелось 80 наборов данных. Во-вторых, над 80 наборами данных было проведено ДФП—РВМ, оптимизированного по ЦМЧП—КАЭ. Затем из полученных ЭМ извлекаются коэффициенты эксцесса и ФСС в виде векторов признаков дефекта. Каждому типу дефекта соответствует 80 наборов собственных векторов коэффициента эксцесса и ФСС. Наконец, 50 групп для различных типов дефектов используются в качестве обучающего набора для классификатора случайного леса, а 30 групп используются в качестве контрольных данных для проверки точности классификации всей модели. Количество решающих деревьев в классификаторе устанавливается равным 800. Результат проверки работоспособности модели с помощью контрольного набора показывает, что уровень точности классификации составляет 90 %, а результат классификации показан на рис. 13.




Рис. 13. Результаты классификации данных по ДФП—РВМ, оптимизированного по ЦМЧП—КАЭ.

По результатам работы метод ДФП—РВМ, оптимизированного по ЦМЧП—КАЭ, не только имеет более высокий показатель точности контроля дефектов по данным вибродиагностики, но и применение этого метода также позволяет определить тип дефекта с более высокой точностью. Это показывает, что метод имеет конкретное практическое применение.

6. ЗАКЛЮЧЕНИЕ

В данной работе объединяются методы дробного фурье-преобразования и разложение на вариационные моды, предложен метод выделения дефектов подшипника дробного фурье-преобразования—разложение на вариационные моды, оптимизированного по центральному моменту четвертого порядка—критерию асимметрии и эксцесса. Во-первых, метод определяет дробный оптимальный порядок через центральный момент четвертого порядка. Во-вторых, параметры метода РВМ оптимизируются по критерию асимметрии и эксцесса. Для сигнала, обработанного этим методом, выполняется спектральный анализ огибающей. Результаты показывают, что по сравнению с прямым РВМ сигнала, сигнал, обработанный этим методом, может получить более очевидные и более характерные сигналы дефекты. Кроме того, коэффициент эксцесса и фильтрации с помощью скользящего среднего извлекается из сигнала, разложенного на основе дробного фурье-преобразования—разложение на вариационные моды, оптимизированного по центральному моменту четвертого порядка—критерию асимметрии и эксцесса, в виде векторов признаков, и отправляются в классификатор случайного леса для диагностики дефектов. По сравнению с РВМ, РЭМ и множественным разложением на эмпирические моды точность диагностики неисправности предлагаемого в данной работе метода значительно выше и достигает 93,75 %. А показатель точности диагностики неисправностей по измеренным данным также высок, что доказывает, что метод имеет конкретное практическое применение и инженерную значимость.

Работа поддержана Государственной Ведущей Лабораторией Нефтяных Ресурсов и Разведки Китайского Университета Нефти (Пекин) (№ PRP/open-1610) и Национальным Фондом Естественных Наук Китая (№ 51804267)

СПИСОК ЛИТЕРАТУРЫ

1. Guan Yang et al. 2MNet: Multi-sensor and multi-scale model toward accurate fault diagnosis of rolling bearing // Reliability Engineering and System Safety. 2021. V. 216.
2. He Deqiang et al. A rolling bearing fault diagnosis method using novel lightweight neural network // Measurement Science and Technology. 2021. V. 32 (12).
3. Zhan Jun, Cheng Longsheng, Peng Zhaoming. Rolling Bearing Fault Intelligent Diagnosis Based on VMD and Improved Multi-classification Matte System // Vibration and shock. 2020. V. 39 (02). P. 32—39.
4. Lu Ou, Dejie Yu, Hanjian Yang. A new rolling bearing fault diagnosis method based on GFT impulse component extraction // Mechanical Systems and Signal Processing. 2016. V. 81. P. 162—182.
5. Huang Norden E. et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis // Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences. 1998. V. 454 (1971). P. 903—995.
6. Wu Z.H., Huang N.E. Ensemble empirical mode decomposition: a noise-assisted data analysis method // Advances in Adaptive Data Analysis. 2009. V. 01 (01). P. 1—41.
7. Zosso D., Dragomiretskiy K. Variational Mode Decomposition // IEEE Transactions on Signal Processing. 2014. V. 62 (3). P. 531—544.
8. Zhang Lei, Xu Shuwen. Nonlinear Frequency Modulation Signal Detection Based on FRFT // Electronic Science and Technology. 2010. V. 23 (02). P. 68—71.
9. Zhang Y., Du X., Wen G. et al. An adaptive method based on fractional empirical wavelet transform and its application in rotating machinery fault diagnosis // Measurement Science and Technology. 2019. V. 30 (3).
10. Shao Y., Lu D., Yang G.X. Application of fractional Fourier transform in fault diagnostics of rolling bearing // Journal of Harbin University of Science and Technology. 2017. V. 22 (03). P. 68—72+79.
11. Mei J.M., Jia J.D., Zeng R.L. et al. A multi-order FRFT self-adaptive filter based on segmental frequency fitting and early fault diagnosis in gears // Measurement. 2016. V. 91. P. 532—540.
12. Wang H.Q. Fractional S transform and its application to gearbox fault diagnosis // Journal of Electronic Measurement and Instrument. 2019. V. 33 (08). P. 133—139.
13. Namias V. The fractional order Fourier transform and its application to quantum mechanics // IMA Journal of Applied Mathematics. 1980. V. 25 (3). P. 241—265.
14. Haldun M. Ozaktas et al. Digital Computation of the Fractional Fourier Transform // IEEE, Transactions on Signal Processing. 1996. V. 44. No. 9. P. 2141—2150.

15. *Alieva T., Bastiaans M.J.* On fractional Fourier transform moments // IEEE Signal Processing Letters. 2000. V. 7 (11). P. 320—323.
16. *Guo Xuewei, Shen Yongjun, Yang Shaopu.* Rolling Bearing Fault Feature Extraction Based on Sample Entropy and Fractional Fourier Transform // Vibration and Shock. 2017. V. 36 (18). P. 65—69.
17. *Xinyu Liu et al.* Automatic extracellular spike denoising using wavelet neighbor coefficients and level dependency // Neurocomputing. 2015. V. 149. P. 1407—1414.
18. *Wang Y., Markert R.* Filter bank property of variational mode decomposition and its applications // Signal Process. 2016. V. 120. P. 509—521.
19. *Wang Fei, Cao Fan.* Separation and Enhancement of multi-component LINEAR FM Signals based on Time-frequency Space Singular Value Decomposition // Data acquisition and processing. 2009. V. 24 (06). P. 767—771.
20. *Zhang Shu, Liu Deping.* Bearing Fault Diagnosis based on BFA Optimization of VMD Parameters // Modular Machine Tool and Automatic Processing Technology. 2020. V. 05. P. 45—47.
21. *Liu Xingdou et al.* Ultra-short-term Wind Power Prediction Model Based on VMD Decomposition and LSTM // IOP Conference Series: Earth and Environmental Science. 2021. V. 838 (1).
22. *Huang Darong, Ke Lanyan, Lin Mengting, Sun Guoxi.* A New Method for Bearing Fault Diagnosis based on Parameter Optimization VMD Multi-Scale Entropy // Control and Decision. 2020. V. 35 (07). P. 1631—163.
23. *Benammar Abdessalem, Chibane Farid.* Resolution Improvement of Ultrasonic Signals Using Sparse Deconvolution and Variational Mode Decomposition Algorithms // Russian Journal of Nondestructive Testing. 2020. V. 56 (6). P. 479—489.
24. *Fengtao Wang, Chenxi Liu, Tao Zhang, Bosen Dun, Qingkai Han, Hongkun Li.* Rolling Bearing Fault Diagnosis Method Based on K-Value Optimization VMD // Vibration. Testing and Diagnosis. 2018. V. 38 (03). P. 540—547.
25. *Zhang Chenchen.* Research on defect recognition method of ultrasonic nondestructive testing based on VMD. Dalian Ocean University, 2020.
26. *Yang Wei, Wang Hongjun.* Rolling Bearing Fault Diagnosis Based on VMD Resonance Sparse Decomposition // Journal of Electronic Measurement and Instrumentation. 2018. V. 9. P. 20—27.
27. *Zhang Chen, Zhao Rongzhen, Deng Linfeng, Wu Yaochun.* Rolling Bearing Weak Fault Feature Extraction Based on SVD-EEMD and TEO* // Vibration. Testing and diagnosis. 2019. V. 39 (04). P. 720—726+900.
28. *Liu Zerui, Xing Jishui, Wang Hongjun, Han Fengxia, Gu Fengfeng.* Rolling Bearing Fault Diagnosis Based on VMD and Fast Spectrum Kurtosis // Journal of Electronic Measurement and Instrument. 2021. V. 35 (2). P. 73—79.
29. *Benammar Abdessalem, Chibane Farid.* Resolution Improvement of Ultrasonic Signals Using Sparse Deconvolution and Variational Mode Decomposition Algorithms// Russian Journal of Nondestructive Testing. 2020. V. 56 (6). P. 479—489.
30. *Hua Li, Tao Liu, Xing Wu, Qing Chen.* Application of optimized variational mode decomposition based on kurtosis and resonance frequency in bearing fault feature extraction // Transactions of the Institute of Measurement and Control. V. 42. Is. 3. P. 518—527.
31. *Tian Jing, Wang Zhi, Zhang Fengling et al.* Dynamic Modeling and Simulation Analysis of Intermediate Bearing Outer Ring Failure // J. Propulsion Technology. 2019. V. 40. No. 03. P. 660—666. DOI:10.13675/j.cnki.tjjs.180081
32. *Roy S.S., Dey S., Chatterjee S.* Autocorrelation Aided Random Forest Classifier-Based Bearing Fault Detection Framework // IEEE Sensors Journal. 15 Sept. 2020. V. 20. No.18. P. 10792—10800.