

УДК 004.931:007.5

**РАЗРЕЖЕННАЯ ВЕЙВЛЕТНАЯ ДЕКОМПОЗИЦИЯ СИГНАЛОВ ВИБРАЦИИ  
ДЛЯ ЗАДАЧИ РАСПОЗНАВАНИЯ ОБРАЗОВ****Ю.П. АСЛАМОВ, А.П. АСЛАМОВ, канд. тех. наук И.Г. ДАВЫДОВ, А.В. ЦУРКО  
(Белорусский государственный университет информатики и радиоэлектроники)**

*Проанализировано пространство признаков алгоритма разреженной декомпозиции сигналов по избыточному вейвлетному словарю для задачи анализа формы вибрационных сигналов во временной области. Предложен алгоритм поэземплярного распознавания элементов оборудования на базе разреженной вейвлетной декомпозиции и машинного обучения. Изучены вопросы построения генератора обучающей выборки для задачи распознавания образов. Предложена методика поиска оптимальных параметров метода одноклассовой классификации One-Class SVM. Представлены результаты тестирования алгоритма распознавания элементов оборудования на наборах вибрационных данных, снятых с подшипников качения и зубчатых передач.*

**Ключевые слова:** *вибродиагностика, разреженная декомпозиция, вейвлет, пространство признаков, распознавания образов, машинное обучение.*

**Введение.** Получившая в последнее время распространение концепция развития промышленности «Industry 4.0» подразумевает переход от *регламентного* обслуживания промышленного оборудования к обслуживанию *по состоянию*. Необходимым условием для осуществления подобного перехода является наличие полностью автоматических систем вибрационной диагностики, интегрированных с единой системой управления предприятием. Отличие автоматических систем от экспертно-ориентированных заключается в полном исключении человека (эксперта) из процесса принятия решений о техническом состоянии оборудования.

Достоверность работы автоматических систем во многом определяется методами выделения диагностических признаков, характеризующих состояние промышленного оборудования. Во многих случаях недостаточное, а иногда и избыточное количество диагностической информации, затрудняет принятие верного решения. Можно выделить два пути повышения достоверности работы автоматических систем вибрационной диагностики:

- 1) разработка вспомогательных методов, повышающих информативность, стабильность и достоверность экспертно-ориентированных пространств диагностических признаков;
- 2) разработка принципиально новых методов и подходов оценки технического состояния оборудования, оценка качественно новых признаков, создание инвариантных пространств признаков и пр.

Основой современной вибрационной диагностики являются методы спектрального анализа [1, 2]. С одной стороны, указанные методы позволяют с высокой достоверностью обнаруживать широкий перечень дефектов оборудования. С другой стороны, они имеют ряд особенностей, затрудняющих их использование в системах автоматической вибродиагностики:

- 1) сильная зависимость спектральных методов от наличия и состава кинематической схемы оборудования, которая должна содержать максимально полное и точное описание всех элементов;
- 2) достоверность диагностики напрямую связана с точностью определения скорости вращения ротора (рабочего колеса) оборудования;
- 3) параметры элементов оборудования (например, подшипников качения) могут изменяться в результате длительной эксплуатации или при смене режима оборудования [3], что уменьшает достоверность диагностической модели на базе спектральных методов;
- 4) низкая достоверность результатов диагностики промышленного оборудования, работающего в нестационарном режиме.

Частично устранить указанные недостатки можно при помощи набора вспомогательных методов: алгоритмов передискретизации сигнала и слежения за частотой [4], методов уточнения скорости вращения вала [5], алгоритмов статистической подстройки параметров элементов оборудования и т.д. Другим возможным путем повышения достоверности диагностики в этом случае является анализ вибрационных сигналов в частотно-временной и временной областях (анализ формы), свободных от указанных недостатков.

Ранее авторами статьи был предложен алгоритм разреженной декомпозиции сигналов [6] по вейвлетному словарю [7] для создания компактного описания формы сигналов вибрации во временной области. Данный алгоритм основывается на допущении, что вибрационные сигналы имеют ограниченный набор элементарных шаблонов формы, таких как асимметричные экспоненциальные [8] и симмет-

ричные гауссоподобные ударные импульсы, амплитудно-модулированные и синусоидальные колебания [9]. Тогда, если в качестве словаря [7] алгоритма декомпозиции [6] использовать набор базисных функций, созданных на базе выделенных шаблонов, то форма сигнала вибрации может быть охарактеризована распределением его энергии по используемым базисным функциям.

Более того, если предположить, что каждый тип элемента оборудования обладает набором собственных только ему шаблонов формы, то на основе компактного описания сигналов во временной области может быть построена система распознавания указанных элементов. Такого рода система будет актуальна в случаях вибрационной диагностики оборудования при полном либо частичном отсутствии его кинематической схемы.

Кроме того, следует отметить, что в процессе деградации технического состояния оборудования (при длительной эксплуатации) форма генерируемых им вибрационных сигналов может изменяться. Примером тому служит процесс появления ударных процессов в подшипниках качения и зубчатых передачах при зарождении дефектов. При этом в случае подшипника качения как резонансная частота возникших колебаний [10], так и их форма будут квазиинвариантны к скорости его вращения. Следовательно, для указанных элементов возникновение колебаний определенной формы может являться диагностическим признаком для оценки их технического состояния.

Предметом исследования настоящей работы является оценка возможности распознавания подшипников качения и зубчатых передач на основе анализа формы их вибрационных сигналов при помощи алгоритма разреженной вейвлетной декомпозиции.

**Основная часть.** Разреженная вейвлетная декомпозиция [6] представляет собой итерационную процедуру разложения сигнала  $s(t)$  в окрестности некоторой частоты  $f_0$  по набору базисных функций  $\psi_m$  словаря  $\mathcal{D}$  [7], в качестве которых используются семейства вейвлетов *MEXH*, *MEXP*, *MORL*, *SINP* [8, 9]. Каждое из представленных семейств предназначено для выделения временных шаблонов определенной формы. Так, семейство *MEXP* обладает максимальным откликом на экспоненциальные ударные воздействия; семейство *MORL* – на амплитудно-модулированные процессы; семейство *SINP* – на синусоидальные воздействия. Вейвлет *MEXH* используется для обнаружения коротких шумоподобных колебаний, не подходящих ни под один из выделенных шаблонов формы.

Результатом работы алгоритма разреженной вейвлетной декомпозиции является так называемое разреженное представление сигнала  $\mathbf{X}$  и спектр базисных функций  $\mathbf{W}^{\text{BF}}$ , или БФ-спектр.

Разреженное представление  $\mathbf{X}$  характеризует сигнал набором из четырех коэффициентов  $\{f_0, \psi_m, c_m, \tau_m\}_{m \in \mathbb{N}}$ , где  $f_0$  – центральная частота,  $\psi_m$  – тип базисной функции,  $c_m$  и  $\tau_m$  – амплитудный коэффициент и временное положение базисной функции  $\psi_m$  соответственно.

В свою очередь,  $\mathbf{W}^{\text{BF}}$  есть распределение энергии сигнала по базисным функциям  $\psi_m$  словаря  $\mathcal{D} = \{\mathcal{D}^{\text{MEXH}}, \mathcal{D}^{\text{MEXP}}, \mathcal{D}^{\text{MORL}}, \mathcal{D}^{\text{SINP}}\}$  [7]. БФ-спектр является основой для создания пространства признаков разреженной вейвлетной декомпозиции для реализации алгоритмов машинного обучения. Ранее авторами уже была рассмотрена возможность различения сигналов вибрации, полученных от подшипников качения и зубчатых передач, на базе машинного обучения с учителем [11]. При этом были рассмотрены пространства информативных признаков, получаемые из БФ-спектра: *BFS*, *BFS-C-I*, *BFS-C-II*, *BFS-F*, *BFS-L-I*, *BFS-L-II* [11].

Основной целью алгоритмов распознавания является процесс отнесения исследуемого объекта к одному или нескольким из  $k + 1$  взаимоисключающих классов. В настоящее время одним из наиболее эффективных средств решения задачи распознавания является метод одноклассовой классификации. Для идентификации подшипников качения или зубчатых передач по сигналам вибрации авторами предложено использовать алгоритм поэлементного распознавания [12] на базе метода одноклассовой классификации *One-Class SVM* (*OCSVM*).

**Одноклассовая классификация.** Опишем кратко стандартный метод одноклассовой классификации *OCSVM*. Пусть дана выборка из независимых одинаково распределенных элементов  $x_1, \dots, x_l$  из  $\mathbf{R}^n$ . Основная идея алгоритмов одноклассовой классификации состоит в том, чтобы отделить часть объектов выборки, которые считаются принадлежащими к «нормальному» классу, от остальных элементов выборки, которые в том или ином смысле рассматриваются как «аномальные».

Для оригинального алгоритма *OCSVM* [13] аномальными считаются те объекты из выборки, для которых соответствующие вектора описаний в пространстве признаков близки к началу координат.

Пусть дано некоторое отображение  $\phi(\cdot)$ , задающее вектор признаков объекта по его вектору описаний  $x$ , и нормальный вектор гиперплоскости  $w$ . Считается, что точка  $x$  принадлежит нормальному

классу, если выполняется неравенство  $(w \cdot \varphi(x)) - \rho > 0$ . Для нахождения нормального вектора гиперплоскости  $w$  и значения  $\rho$  решается оптимизационная задача [13]

$$\frac{1}{2} \|w\|_2^2 + \frac{1}{\nu l} \sum_{i=1}^l \xi_i - \rho \rightarrow \min_{w, \xi, \rho}, \quad (1)$$

$$s.t. (w \cdot \varphi(x_i)) \geq \rho - \xi_i, \quad \xi_i \geq 0$$

где  $\xi_i$  – расстояние от точки до гиперплоскости;

$\nu$  – коэффициент регуляризации, устанавливающий верхнюю границу выбросов, при которой обучающие образцы считаются аномалией.

Оптимизационная задача (1) выпукла, поэтому решения прямой и двойственной задач совпадают. Выпишем двойственную задачу:

$$-\sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j K(x_i, x_j) \rightarrow \max_{\alpha}$$

$$s.t. \sum_{i=1}^l \alpha_i = 1, \quad 0 \leq \alpha_i \leq \frac{1}{\nu l}.$$

В двойственной задаче скалярное произведение  $(\varphi(x_i) \cdot \varphi(x_j))$  заменено на ядерную функцию  $K(x_i, x_j)$ . Таким образом, фактически для решения задачи одноклассовой классификации нет необходимости знать явный вид отображения  $\varphi(x)$ . При этом решение прямой задачи выражается через решение двойственной:

$$w = \sum_{i=1}^l \alpha_i \varphi(x_i).$$

Свойства задачи таковы, что условие  $\alpha_i \neq 0$  фактически означает, что точка выборки  $x_i$  находится на границе критической области и для нее выполнено равенство  $(w \cdot \varphi(x_i)) = \rho$ , поэтому для любого  $x_k$ , такого что  $\alpha_k \neq 0$ , можно записать

$$\rho = (w \cdot \varphi(x_k)) = \sum_{i=1}^l \alpha_i K(x_i, x_k).$$

Таким образом, решающее правило имеет вид

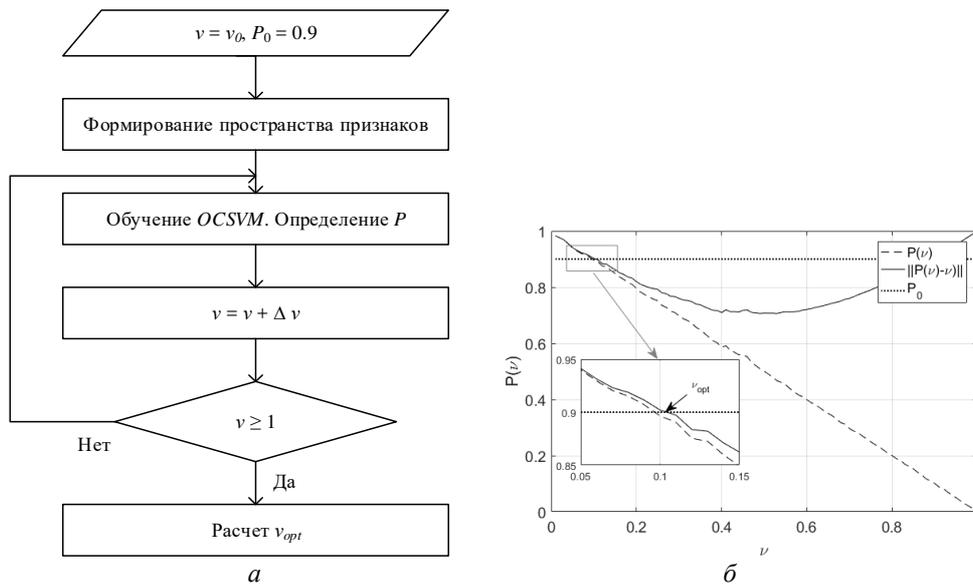
$$f(x) = \sum_{i=1}^l \alpha_i K(x_i, x_j) - \rho. \quad (2)$$

Если  $f(x) > 0$ , то считается, что точка  $x$  принадлежит нормальному классу. Величина  $|f(x)|$  характеризует степень уверенности в соответствующем решении.

Метод одноклассовой классификации *OCSVM* минимизирует область пространства признаков «нормального класса» (1) при максимизации количества объектов обучающей выборки внутри нее. По этой причине *OCSVM* в сравнении с методом *2-class SVM* имеет в среднем меньшую вероятность правильного обнаружения и большую ошибку второго рода (вероятность пропуска), причем разница может исчисляться в разгах [14].

Качество сформированного правила принятия решения (2) полностью определяется вероятностями ошибочных решений, допускаемых при распознавании объектов. Ошибка распознавания возникает из-за пересечения классов в многомерном признаковом пространстве, когда объекты из обучающей выборки одного класса в результате проекции на гиперплоскость ошибочно относят к объектам другого класса. Снизить вероятность ошибочных решений распознавания возможно за счет настройки параметров классификатора в процессе обучения [12].

Применительно к задаче распознавания качество правила принятия решений  $f(x)$  будет определяться вероятностями ложной тревоги и пропуска цели, а регулируемым параметром выступает  $\nu$ , характеризующий долю объектов обучающей выборки, выходящих за пределы гиперсферы. Исходя из этого процесс оптимизации может быть представлен алгоритмом подбора параметра  $\nu$  по критерию минимизации ошибки распознавания или максимизации вероятности правильного распознавания  $P$ . Структурная схема алгоритма оптимизации  $\nu$  представлена на рисунке 1, а, а кривая зависимость  $P(\nu)$  – на рисунке 1, б.



**Рисунок 1. – Обучение классификатора OCSVM:**  
**а – блок-схема алгоритма оптимизации  $\nu$ ; б – определение параметра  $\nu_{opt}$**

Эмпирически было установлено, что оптимальное значение шага изменения  $\nu \in (0,1]$  составляет  $\Delta \nu = 0,01$ . Во многих случаях значение  $\nu \rightarrow 0$  является причиной увеличения вероятности ложной тревоги. По этой причине начальное значение  $\nu$  составляет  $\nu_0 = 0,01$ , а оптимальное значение  $\nu_{opt}$  выбирается по кривой  $\|P(\nu) - \nu\|$  с использованием порога  $P_0$  (см. рисунок 1, б).

**Генератор обучающей выборки.** Как отмечалось выше, основной целью алгоритмов распознавания является процесс отнесения исследуемого объекта к одному или нескольким из  $k + 1$  взаимоисключающих классов. Одним из ключевых факторов, влияющих на качество работы алгоритмов распознавания, является процесс формирования обучающей выборки. Под «обучающей выборкой» понимается множество объектов, для которых априорно известно, к каким классам они относятся. Для задачи вибродиагностики под объектами понимаются вибрационные сигналы или наборы диагностических признаков.

В настоящее время не сформирован исчерпывающий набор вибрационных сигналов, способный описать все возможные конфигурации промышленного оборудования и учитывающий все возможные нюансы как оборудования, так и используемых при снятии данных измерительных систем. Поэтому реализация алгоритмов распознавания на базе инвариантных пространств признаков сталкивается со следующими проблемами:

- а) отсутствие или недостаточный объем обучающей выборки для достоверного обучения;
- б) обучающая выборка описывает не все возможные случаи или не содержит объекты всех классов;
- в) невозможность применения полученных результатов распознавания для иной конфигурации оборудования или иных начальных условий.

Ввиду использования пространства признаков разреженной вейвлетной декомпозиции для решения указанных проблем авторами предложено использовать *генератор обучающей выборки*. Возможность такого шага объясняется следующим: а) анализ формы сигнала проводится в узкой полосе частот  $\Delta f$  в окрестности  $f_0$ , при этом  $\Delta f \ll f_0$ ; б) анализ формы лишь косвенно зависит от скорости вращения вала и конфигурации оборудования; в) пространство признаков разреженной вейвлетной декомпозиции имеет невысокую размерность  $dim = 3-30$ , что эквивалентно количеству степеней свободы для его генерации; г) имеется ограниченное количество шаблонов формы для сигналов вибрации подшипников качения [8] и зубчатых передач [9]. По этой причине может быть сгенерирован как набор модельных узкополосных сигналов, содержащих требуемые шаблоны формы, так и непосредственно само пространство признаков разреженной вейвлетной декомпозиции для различных случаев.

На рисунке 2 приведена структурная схема разработанного авторами генератора обучающей выборки, на основе которого было сформировано  $L_1 = 1407$  модельных сигналов для подшипника качения и  $L_2 = 1324$  – для зубчатых передач.

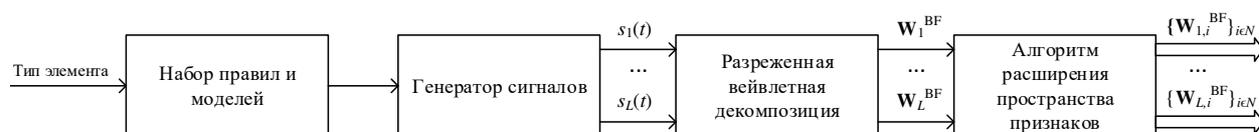


Рисунок 2. – Структурная схема генератора обучающей выборки

Генератор обучающей выборки не относится непосредственно к предмету исследования текущей статьи, поэтому детальное описание процесса его создания и тестирования опущено. Следует лишь отметить, что представленный на рисунке 2 блок расширения пространства признаков предназначен для формирования из оригинального БФ-спектра  $\mathbf{W}^{BF}$  набора вспомогательных пространств признаков  $\{\mathbf{W}_i^{BF}\}_{i \in \mathbb{N}}$  с идентичной или меньшей размерностью. Необходимость такого шага обусловлена тем, что пространство признаков с меньшей размерностью требует меньшее количество сигналов для описания всех возможных объектов  $j$ -го класса.

**Алгоритм поэкземплярного распознавания.** Алгоритм поэкземплярного распознавания [12] подразумевает обучение на предварительном этапе  $N$  классификаторов  $OCSVM$ , каждый из которых предназначен для обнаружения объектов определенного класса. В результате классификации сформированного вектора признаков каждым из  $N$  классификаторов по правилу (2) вычисляет значение коэффициента принадлежности  $K_i = \{0,1\}$  объекта к каждому из  $N$  классов. При этом при  $f(x) \geq 0$  классификатор присваивает коэффициенту  $K_i = 1$ , в противном случае –  $K_i = 0$ . Решение о принадлежности объекта тому или иному классу делается на базе весовых коэффициентов значимости  $k_{\text{знач},i}$ , получаемых на этапе обучения классификаторов. При этом выбор делается в пользу того класса, для которого

$$K_i \cdot k_{\text{знач},i} = \max. \quad (3)$$

Однако первая разработанная авторами реализация алгоритма поэкземплярного распознавания элементов оборудования, при которой обучение  $OCSVM$  (см. рисунок 1, а) проводилось только на сформированных генератором обучающей выборки векторах признаков оригинального БФ-спектра  $\mathbf{W}^{BF}$  с размерностью  $dim = 30$ , имела высокую вероятность пропуска  $FNR = 0,9-0,95$ . Такой результат в основном обусловлен недостатками генератора обучающей выборки, для нивелирования которых предложено следующее:

а) процедура обучения классификаторов (см. рисунок 1, а) проводится только на объектах «нормального класса», при этом оптимальное значение  $v_{opt}$  выбирается по критерию минимизации вероятности пропуска;

б) применяется процедура расширения пространства признаков (см. рисунок 2) для формирования подпространств  $\{\mathbf{W}_i^{BF}\}_{i \in \mathbb{N}}$  с меньшей размерностью, чем  $\mathbf{W}^{BF}$  [11].

При таком подходе для распознавания каждого из  $N$  классов формируется  $M$  классификаторов  $OCSVM$ , каждый из которых обучен на одном из сформированных пространств признаков. Процедуру расчета коэффициентов принадлежности  $K_i = \{0,1\}$  набором из  $M$  классификаторов назовем *голосовани-*

ем. Тогда решение о принадлежности объекта к тому или иному классу может приниматься по подсчету количества голосов как без взвешивания:

$$\sum_{j=1}^M K_{i,j} = \max, \tag{4}$$

так и со взвешиванием:

$$\sum_{j=1}^M K_{i,j} \cdot k_{\text{знач.}i,j} = \max, \tag{5}$$

где  $k_{\text{знач.}i,j} = \log_{16} \left( \dim(\mathbf{W}_{i,j}^{BF}) \right)$  – весовой коэффициент значимости, зависящий от размерности используемого пространства признаков.

Для повышения достоверности распознавания элементов был разработан алгоритм принятия решений на базе правил (4) и (5). В спорных ситуациях элемент оборудования определяется как «неизвестный». Структурная схема алгоритма поэлементного распознавания элементов оборудования представлена на рисунке 3, на котором алгоритм разреженной декомпозиции сигнала по вейвлетному базису обозначен как SWD.

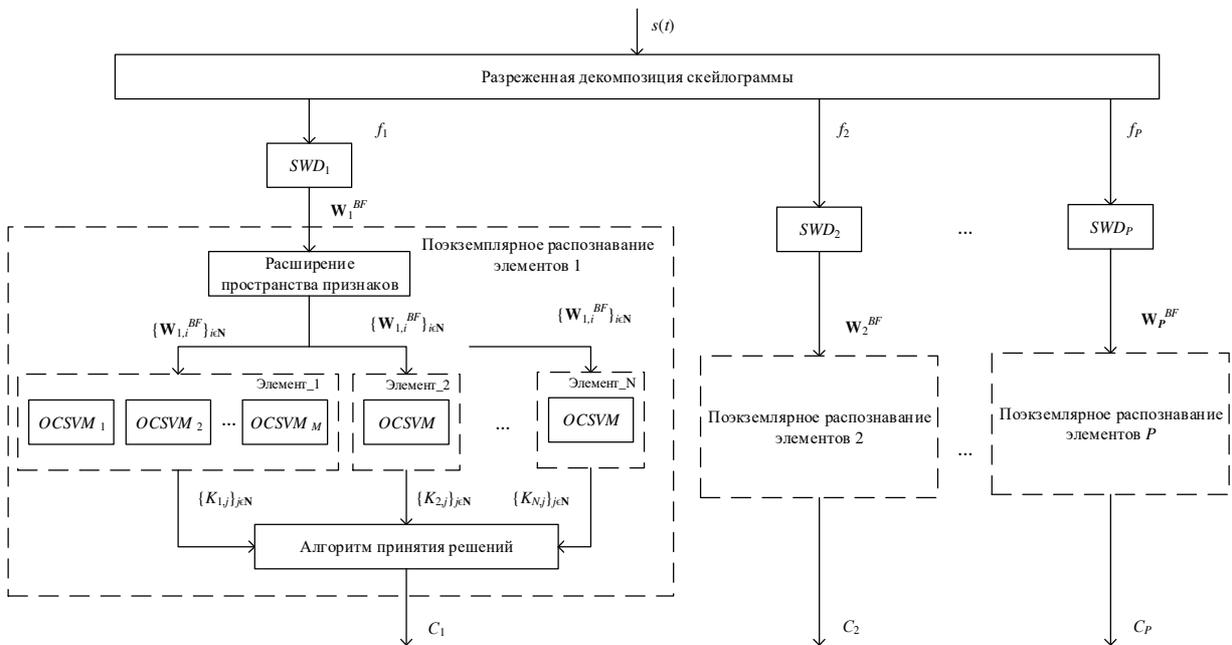


Рисунок 3. – Структурная схема алгоритма поэлементного распознавания

Как представлено на рисунке 3, алгоритм разреженной декомпозиции скейлограммы выделяет набор частот оборудования  $f_1-f_p$ , в окрестности которых сосредоточена значительная часть энергии. Для каждой выделенной частоты применяется алгоритм разреженной вейвлетной декомпозиции сигналов и оценивается эффективность декомпозиции  $\xi$  [7, 11]. Распознавание элементов схемы проводится только для тех частот, эффективность декомпозиции сигнала в окрестности которых превышает пороговое значение  $\xi_0 = 50\%$ . Распознавание элементов схемы для каждой частоты  $f_i$  проводится независимо.

**Методика эксперимента.** Целью эксперимента является оценка качества работы предложенного алгоритма поэлементного распознавания подшипников качения и зубчатых передач на базе пространства признаков разреженной вейвлетной декомпозиции и генератора обучающей выборки.

Для проведения экспериментов были использованы наборы данных «High Speed Gearbox Dataset» (<http://data-acoustics.com/measurements/gear-faults/>) и «High Speed Bearing Dataset» (<http://data-acoustics.com/measurements/bearing-faults/>)

*acoustics.com/measurements/bearing-faults/*), которые содержат сигналы вибрации, снятые с коробки передач ветрогенератора в нормальном состоянии и при наличии дефектов шестерен.

Кроме того, было сформировано два набора данных «*Bearing 6213 OR Dataset*» и «*Bearing 6213 Norm/OR Dataset*», снятых с подшипника качения 6213 при различных скоростях вращения вала (от 600 до 900 об/мин) в нормальном состоянии и при наличии дефекта наружного кольца. Чувствительность используемого при этом датчика вибрации *B&R* составляла  $s = 100$  мВ/г, частота дискретизации сигналов  $F_s = 96$  кГц.

Обработка данных проводилась в среде *MATLAB*. В качестве классификатора выбрана реализация *OCSVM* на базе *libSVM* (<https://www.csie.ntu.edu.tw/~cjlin/libsvm>). Оценка качества классификации проводилась в терминах [15]:

- 1) чувствительность *TPR* (*true positive rate* или *recall*)

$$recall = TPR = \frac{TP}{P} = \frac{TP}{TP + FN}, \quad (6)$$

где *TP* (*true positive*) – количество истинно-положительных решений (верно идентифицированных образцов);

*P* – количество положительных (идентифицированных) образцов;

*FN* (*false negative*) – количество ложноотрицательных решений (ложно отклоненных образцов);

- 2) точность *PPV* (*positive predictive value* или *precision*)

$$precision = PPV = \frac{TP}{TP + FP}, \quad (7)$$

где *FP* (*false positive*) – количество истинно отрицательных решений (верно отклоненных образцов).

**Результаты и их обсуждение.** Для оценки качества работы алгоритма поэкземплярного распознавания элементов оборудования были проведены эксперименты на наборах вибрационных сигналов. Для каждого набора данных было выделено несколько резонансных частот  $f_i$ – $f_p$ , в пределах которых проводилось распознавание. При этом искомым элементом (истинно верный) для каждой частоты  $f_i$  задавался экспертным путем посредством анализа спектральных признаков в ее окрестности.

В таблице 1 представлены результаты распознавания подшипника качения одиночными классификаторами *OCSVM* на базе различных пространств признаков для набора данных «*Bearing 6213 OR Dataset*».

Таблица 1. – Результаты распознавания подшипника качения для набора данных «*Bearing 6213 OR Dataset*»

Пространство признаков	Частота, Гц							
	$f_1 = 600$		$f_2 = 1100$		$f_3 = 3050$		$f_4 = 5200$	
	<i>TPR</i>	<i>PPV</i>	<i>TPR</i>	<i>PPV</i>	<i>TPR</i>	<i>PPV</i>	<i>TPR</i>	<i>PPV</i>
<i>BFS</i>	0,079	1	0,219	1	0,072	1	0,040	1
<i>BFS-C-I</i>	0,158	1	0,610	1	0,247	1	0,182	1
<i>BFS-C-II</i>	0,099	1	0,276	1	0,083	1	0,040	1
<i>BFS-F</i>	0,436	0,917	0,741	1	0,701	1	0,717	1
<i>BFS-wn</i>	0,079	1	0,219	1	0,052	1	0,040	1
<i>BFS-wn-C-I</i>	0,168	1	0,591	1	0,165	1	0,182	1
<i>BFS-wn-C-II</i>	0,109	1	0,276	1	0,052	1	0,040	1
<i>BFS-wn-F</i>	0,396	1	0,687	1	0,588	1	0,667	1
<i>BFS-wn-cl</i>	0	0	0	0	0	0	0	0
<i>BFS-wn-cl-C-I</i>	0	0	0	0	0	0	0	0
<i>BFS-wn-cl-C-II</i>	0	0	0	0	0	0	0	0
<i>BFS-wn-cl-F</i>	0,465	0,940	0,105	1	0,381	1	0,879	1
<i>BFS-wn-C-I-cl</i>	0	0	0	0	0	0	0	0
<i>BFS-wn-C-II-cl</i>	0	0	0	0	0	0	0	0
<i>BFS-wn-F-cl</i>	0,765	1	0,824	1	0,443	1	0,626	1
Итоговый результат	0,921	0,960	1	1	0,897	1	0,950	1

Распознавание проводилось для четырех выделенных частот  $f_1$ – $f_4$ , эффективность декомпозиции сигнала в окрестности которых превышала пороговое значение. Для классификаторов на базе каждого пространства признаков были рассчитаны параметры чувствительности *TPR* и точности *PPV*. Графа

«Итоговый результат» содержит оценку качества работы алгоритма поэкземплярного распознавания набором представленных классификаторов. Серым цветом выделены лучшие параметры в пределах каждой анализируемой частоты  $f_i$ .

В соответствии с результатами, представленными в таблице 1, можно сделать вывод, что совместное использование набора независимых классификаторов позволяет в значительной мере повысить чувствительность ( $TPR$ ) и точность ( $PPV$ ) распознавания элементов, в сравнении с работой одиночного классификатора (на базе одного пространства признаков). Так, например, для частоты  $f_3$  чувствительность распознавания элемента отдельными классификаторами варьируется в диапазоне  $TPR = [0; 0,701]$ , в то время как результирующее значение составляет  $TPR = 0,897$ .

Авторами детально не рассматривается каждый тип пространства признаков, представленный в таблице 1, так как это не входит в предмет исследования данной статьи. Следует лишь отметить, что наибольшей чувствительностью обладают классификаторы  $OCSVM$  на базе пространства признаков  $BFS-F$  и его модификаций, описывающих распределение энергии сигнала по семействам базисных функций  $MEXH$ ,  $MEXP$ ,  $MORL$  и  $SINP$  [7]. Пространство  $BFS-F$  носит интегральный характер, его размерность ( $dim = 3-4$ ) значительно ниже размерности оригинального БФ-спектра ( $dim = 30$ ) [11]. По этой причине классификаторы на базе  $BFS-F$  имеют в среднем меньшую точность распознавания, чем классификаторы на базе других типов пространств (таблица 1), но большую чувствительность.

На рисунках 4 и 5 представлены результаты распознавания элементов оборудования для сигналов вибрации из наборов «High Speed Bearing Dataset» и «Bearing 6213 OR Dataset» в окрестности частот  $f_4 = 3800$  Гц и  $f_2 = 1100$  Гц соответственно. При этом верным (искомым) элементом для набора данных «High Speed Bearing Dataset» является зубчатая передача, а для «Bearing 6213 OR Dataset» – подшипник качения. На рисунках 4 и 5 имеются следующие обозначения: В – подшипник качения, G – зубчатая передача; 0 – неопознанный элемент; + – результат со средней достоверностью, ++ – результат с высокой достоверностью.

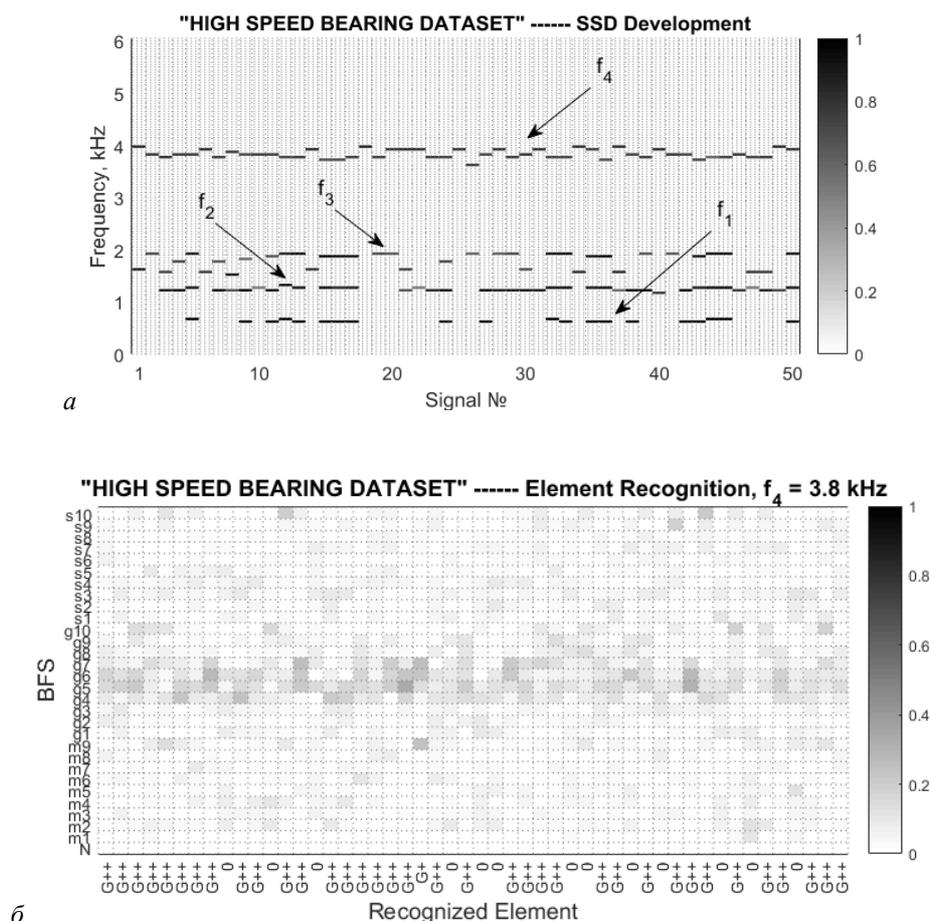


Рисунок 4. – Распознавание элементов схемы для набора данных «High Speed Bearing Datasets»: а – разреженная декомпозиция скейлограммы; б – распознавание элемента для частоты  $f_4$

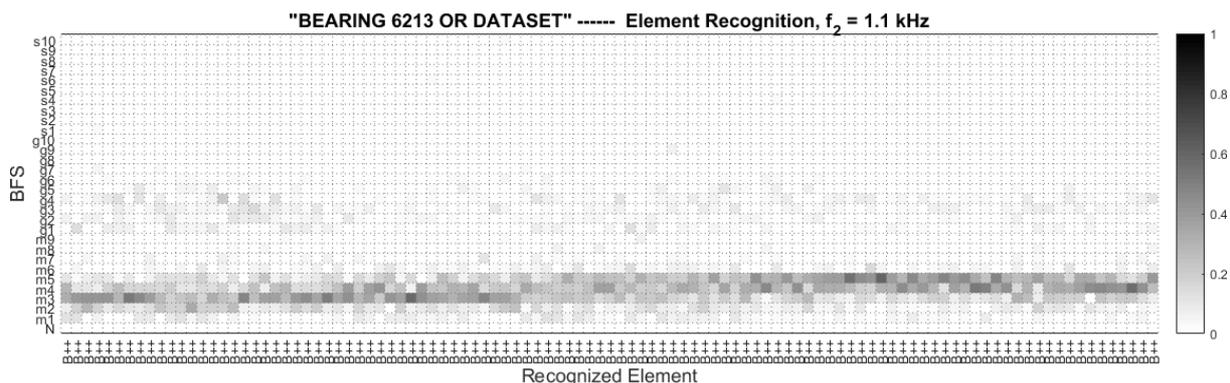


Рисунок 5. – Распознавание элементов схемы для набора данных «*Bearing 6213 OR Dataset*»

В таблице 2 приведены итоговые результаты распознавания элементов оборудования для всех используемых наборов данных. В графе «Набор данных / Параметры» рядом с названием каждого набора данных в круглых скобках обозначен тип искомого элемента: (G) – зубчатая передача, (B) – подшипник качения. В каждом наборе данных было выделено по четыре значимые частоты  $f_1$ – $f_4$ .

Таблица 2. – Итоговые результаты распознавания элементов по наборам данных

Набор данных / Параметры	Частота							
	$f_1$		$f_2$		$f_3$		$f_4$	
	<i>TPR</i>	<i>PPV</i>	<i>TPR</i>	<i>PPV</i>	<i>TPR</i>	<i>PPV</i>	<i>TPR</i>	<i>PPV</i>
<i>High Speed Gearbox Dataset</i> (G)	0,589	0,786	0,923	1	0,706	0,733	0,804	0,945
<i>High Speed Bearing Dataset</i> (G)	1	1	0,951	1	0,782	0,932	0,742	1
<i>Bearing 6213 OR Dataset</i> (B)	0,921	0,960	1	1	0,897	1	0,950	1
<i>Bearing 6213 Norm/OR Dataset</i> (B)	0,821	0,92	1	1	0,865	1	0,756	0,982

В соответствии с результатами проведенных экспериментов для различных наборов данных можно сделать вывод, что алгоритм поэкземплярного распознавания элементов оборудования на основе набора одноклассовых классификаторов способен распознавать элементы оборудования с достаточно высокой достоверностью.

Наименьшая чувствительность метода ( $TPR = 0,589$ ) была зафиксирована для вибрационных сигналов набора данных «*High Speed Gearbox Dataset*» в окрестности частоты  $f_1$ . Причиной такого результата является недостаточно полная сгенерированная обучающая выборка для распознавания зубчатых передач, при формировании которой не были учтены модели ударных процессов шестерен при изломе зубьев. За исключением указанного случая, чувствительность разработанного метода распознавания элементов оборудования лежит в диапазоне  $TPR = [0,706, 1]$  при точности распознавания  $PPV = [0,733, 1]$ .

Следует отметить, что чувствительность и точность распознавания бездефектного подшипника качения в среднем ниже, чем дефектного, что нашло свое отражение в более низких показателях  $TPR$  и  $PPV$  для набора данных «*Bearing 6213 Norm/OR Dataset*» по сравнению с «*Bearing 6213 OR Dataset*» (таблица 2). Причиной тому служит либо полное отсутствие ударных процессов в сигнале бездефектного подшипника, либо их незначительный энергетический вклад в общую энергетику сигнала, что не позволяет с высокой достоверностью определить сигнал как «подшипниковый».

Средние значения параметров  $TPR$  и  $PPV$  для всех используемых в процессе тестирования алгоритма сигналов ( $N = 1115$  шт.) составили  $TPR = 0,882$  и  $PPV = 0,972$ .

**Заключение.** В работе рассмотрено пространство информативных признаков алгоритма разреженной вейвлетной декомпозиции для решения задачи анализа формы сигналов вибрации. Предложен алгоритм поэкземплярного распознавания элементов оборудования на базе разреженной вейвлетной декомпозиции. Освещены вопросы обучения и оптимизации параметров метода одноклассовой классификации *One-Class SVM*. Кратко описан принцип построения генератора обучающей выборки для задачи машинного обучения.

Проведена апробация алгоритма поэкземплярного распознавания элементов схемы на вибрационных сигналах, снятых с подшипников качения и зубчатых передач. Средние значения параметров чувствительности  $TPR$  и точности  $PPV$  распознавания составили  $TPR = 0,882$  и  $PPV = 0,972$  соответственно.

Таким образом, предложенный в статье метод распознавания элементов оборудования на базе разреженной вейвлетной декомпозиции сигналов вибрации может применяться в практике вибрационной диагностики.

## ЛИТЕРАТУРА

1. Абрамов, И.Л. Вибродиагностика энергетического оборудования : учебное пособие по дисциплине «Диагностика в теплоэнергетике» / И.Л. Абрамов. – Кемерово, 2011. – 80 с.
2. Барков, А.В. Вибрационная диагностика машин и оборудования. Анализ вибрации: учеб. пособие / А.В. Барков, Н.А. Баркова. – СПб. : СПбГМТУ, 2004. – 156 с.
3. Pennacchi P. An experimental based assessment of the deviation of the bearing characteristic frequencies / P. Pennacchi [et al.] // CMMNO. – 2013. – (papers).
4. Eltabach, M. Rotating machine speed estimation using vibration statistical approach / M. Eltabach, G. Govaert // WCCM. – 2017. – (papers).
5. Алгоритмы уточнения частоты вращения вала в задачах вибродиагностики роторного оборудования / Ю.П. Асламов [и др.] // Вестник Полоцкого государственного университета. Серия В, Промышленность. Прикладные науки. – 2017. – № 11. – С. 51–58.
6. Разреженная вейвлетная декомпозиция в задачах вибродиагностики роторного оборудования / Ю.П. Асламов [и др.] // Доклады БГУИР. – 2017. – № 8. – С. 91–98.
7. Асламов, Ю.П. Избыточный вейвлетный словарь для разреженной декомпозиции сигналов вибрации / Ю.П. Асламов, И.Г. Давыдов // Вестник Полоцкого государственного университета. Серия С, Фундаментальные науки. – 2018. – № 4. – С. 86–94.
8. Асламов, Ю.П. Вейвлет-функция для диагностики подшипников качения / Ю.П. Асламов, И.Г. Давыдов // Вестник Полоцкого государственного университета. Серия В, Промышленность. Прикладные науки. – 2018. – № 11. – С. 14–22.
9. Вейвлет-функции для диагностики зубчатых передач / Ю.П. Асламов [и др.] // Вестник Полоцкого государственного университета. Серия В, Промышленность. Прикладные науки. – 2018. – № 3. – С. 38–46.
10. Эффективность использования скалограммы для оценки технического состояния роторного оборудования / Ю.П. Асламов [и др.] // Доклады БГУИР. – 2018. – № 2. – С. 12–17.
11. Асламов, Ю.П. Пространство признаков разреженной вейвлетной декомпозиции вибрационных сигналов для задач машинного обучения / Ю.П. Асламов, И.Г. Давыдов // Вестник ГГТУ им. Сухого. – 2018. – № 3. – С. 49–56.
12. Субботенко, А.В. Алгоритм поэкземплярного распознавания на основе метода опорных векторов / А.В. Субботенко // Информация и космос. – 2014. – № 2. – С. 47–53.
13. Burnaev, E. One-Class SVM with Privileged Information and Its Application to Malware Detection [Электронный ресурс] / E. Burnaev, D. Smolyakov // ArXiv, Los Alamos. – Режим доступа: <https://arxiv.org/pdf/1609.08039.pdf>.
14. Arcolano, N. One-class support vector machines: Methods and applications / N. Arcolano, D. Ruboy. // Harvard University, Final Project Presentation. – 2008. – P. 32
15. Powers, D. From Precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation / D. Powers // Journal of Machine Learning Technologies. – 2011. – № 2(1). – P. 37–63.

Поступила 15.08.2018

**SPARSE WAVELET DECOMPOSITION OF VIBRATION SIGNALS  
FOR PATTERN RECOGNITION PROBLEM**

**Y. ASLAMOV, A. ASLAMOV, I. DAVYDOV, A. TSURKO**

*The paper presents the features space of the algorithm for a sparse decomposition of signals by the redundant wavelet dictionary to analyze the waveform of vibration signals. An algorithm for recognition of elements of rotary equipment on the basis of sparse wavelet decomposition and machine learning is proposed. The questions of constructing the generator of the training dataset for pattern recognition problem are considered. A method for estimating the optimal parameters of the One-Class SVM is proposed. The results of testing the recognition algorithm on the datasets of vibration signals of rolling bearings and gears are presented.*

**Keywords:** vibration-based diagnostics, sparse decomposition, wavelet, feature space, pattern recognition, machine learning.