

УДК 621.438.003

А.П. ГОРШКОВ, Т.П. ГРЫЗЛОВА

Рыбинская государственная авиационная технологическая академия им. П.А. Соловьева, Россия

ДЕКОМПОЗИЦИЯ СИГНАЛОВ СЛОЖНЫХ ИСТОЧНИКОВ НА ОСНОВЕ ХАРАКТЕРНЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ WAVELET-КОЭФФИЦИЕНТОВ

Предложен метод предварительной обработки информации на основе декомпозиции диагностических сигналов и/или их Wavelet-преобразований на информативные и неинформативные элементы. Последовательность считается информативной (характерной, ХП), если частоты ее встречаемости в сигналах разных классов существенно отличаются. Выполнен анализ влияния Wavelet-преобразования на информативность ХП в задачах диагностики подшипников трансмиссии ГТД по вибросигналам и электрических двигателей по моделям флюктуаций тока. Информативность ХП Wavelet-коэффициентов оказалась несколько выше, чем ХП сигналов. Оценки вероятности правильного распознавания, полученные по методу скользящего контроля, показывают, что если источник имеет большой уровень шума, то наиболее полезными являются ХП интегральных Wavelet-коэффициентов. Признаки на их основе обеспечивают полную линейную делимость образов вибрационных сигналов кондиционных и некондиционных подшипников и позволяют уменьшить количество ошибок при диагностике. При наличии обучающей выборки в виде записей цифровых сигналов, зарегистрированных в различных состояниях источника, с помощью программного обеспечения поиска ХП можно экспериментально оценить эффективность разработанного метода для конкретных задач.

Ключевые слова: диагностика, цифровые сигналы, структурные методы анализа, характерная последовательность, Wavelet-преобразование, подшипники трансмиссии ГТД, информативность признака.

Введение

В технической диагностике широко используются такие методы цифровой обработки сигналов, как спектральный анализ, фильтрация, аппроксимация в различных базисах, Wavelet-анализ. Они предоставляют человеку разные образы первичных данных и часто облегчают распознавание. Но проблема выбора признаков для диагностики остается открытой. Множество признаков, характеризующих объект, выбирается специалистом, а эффективность выбора или его ошибочность становится ясной после разработки, тестирования и использования системы распознавания или обработки информации, когда модификации, корректировки, доработки аппаратуры или программного обеспечения трудны, дороги и требуют много времени.

Наметились тенденции по автоматизации процесса принятия решения о состоянии сложных технических объектов, причем это относится и к проблеме выбора информативных диагностических признаков, и к проблеме оценки состояния диагностируемого объекта. Многие задачи принятия решения, если решение базируется, в основном, на прошлом опыте, приводятся к схеме распознавания образов. Исходной информацией для проектирования является множество сигналов с указанием классов

объектов, для которых они зарегистрированы, поэтому задачу синтеза системы распознавания часто решают методами машинного обучения. Важным фактором, влияющим на возможность автоматического анализа, является выбор функции от первичных данных или их преобразований.

Известно большое количество методов и алгоритмов формального синтеза и обучения классификаторов, пригодных в условиях, когда выбор набора функций от первичных данных уже сделан, то есть признаковое пространство фиксировано.

В рамках выбранного семейства признаков можно автоматизировать поиск наиболее информативных признаков. Спроектировано семейство признаков на основе характерных последовательностей, пригодное для автоматического анализа самых разнообразных цифровых сигналов и их преобразований. Показано, что оно позволяет существенно уменьшить количество ошибок при диагностике состояния сложных технических объектов.

1. Структурный анализ сигналов

Основы структурного метода анализа сигналов были изложены Э.М. Браверманом и И.Б. Мучником [1]. Если информация равномерно распределена по кривой и характеризуется поведением кривой в це-

лом, например, ее спектральным составом, скоростью роста, то для ее извлечения обрабатывают всю кривую в целом, например, раскладывая ее по различным системам функций или выполняя преобразование Фурье. Совершенно иные методы извлечения информации необходимы в случаях, когда предполагается, что она содержится в относительно небольших участках кривой, как бывает при анализе электрокардиограмм. В этом случае выделяют информативные участки, а представление информации о кривой в целом следует строить через описание классов выделенных участков. Разделение области задания функции на части, рассмотрение функций на этих участках как самостоятельных единиц наблюдений, сравнение между собой – типичные этапы структурного анализа.

В большинстве работ, посвященных формализации такого подхода, обязательно предполагается заданным набор эталонов информативных участков. Обычно он используется и для их выделения, и для классификации. Набор эталонов для анализа определенного типа экспериментальных кривых выбирается специалистом, хорошо знающим этот тип. Для каждого нового типа кривых строится свой набор эталонов. Такой подход не позволяет полностью автоматизировать процесс обработки кривых, не дает возможности строить алгоритмы, предназначенные для широкого класса экспериментальных кривых, требует привлечения высококвалифицированных специалистов. Его использование затруднительно в тех случаях, когда требуется обрабатывать данные плохо изученных процессов, например, шумов и вибраций новых машин. Автоматическое построение эталонов особенно актуально в связи с проблемой автоматизации научного эксперимента.

Диагностические сигналы являются очень сложными объектами. Они определяются применяемыми датчиками, то есть возможность влиять на процесс получения первичной информации очень ограничена. Математическая модель сигналов или неизвестна, или настолько сложна, что ее использование становится неконструктивным. Построение классификаторов на основе непосредственно наблюдаемых сигналов невозможно из-за очень большого размера данных. Необходимо предварительное извлечение из наблюдаемых сигналов информативных признаков, после чего задача классификации решается известными методами. Формальные методы поиска признаков при неопределенной математической модели сигнала отсутствуют. Часто используются известные из других приложений методы, без обоснования их эффективности (например, спектральное представление сигнала).

Разработаны алгоритмы автоматического поиска признаков, основанные на новом концептуальном

подходе к описанию динамической информации. Основное достоинство предлагаемого подхода заключается в выделении характерных последовательностей, что позволяет учесть динамическую информацию [2 – 6]. Методика не требует стационарности сигналов, пригодна для скалярных и векторных сигналов, не зависит от класса сигналов и инвариантна к некоторым преобразованиям сигналов. Система поиска характерных последовательностей описана в [2 – 6], в настоящей работе представлены исследования, позволяющие сделать вывод о целесообразности Wavelet-анализа.

2. Метод анализа на основе выделения характерных последовательностей

Методы структурного анализа сигналов обычно реализуются в виде системы алгоритмов. В нашем случае система алгоритмов предварительной обработки $\{f_1, \dots, f_m\}$ преобразует сигнал в вектор

размерности m частот v_i характерных последова-

тельности es_i . Заметим, что число характерных последовательностей зависит от обучающих данных и может варьироваться от 1 до заданного максимально допустимого количества m :

$$s_0^{N-1} \xrightarrow{f_1, \dots, f_m} \begin{pmatrix} v_1 \\ \dots \\ v_m \end{pmatrix}. \quad (1)$$

2.1. Характерные последовательности

Из сигнала выделяется J -й кластер элементарных последовательностей $ES_J = \{es_j\}_J$ одинаковой длины $k = \#es_{1J}$. Элементарная последовательность включается в кластер, если по выбранной мере сопоставления последовательностей при заданном пороге они совпадают с эталоном es_{1J} . Для всех сигналов, которые содержатся в обучающей выборке, подсчитывается количество элементарных последовательностей

$$v_J(s_0^{N-1})_p = \#ES_J = \#\{es_j\}_J. \quad (2)$$

Вычисляется информативность этого признака для классификации сигналов. Информативность может быть оценена несколькими способами, например, как отношение межклассового расстояния между множествами значений признаков k внутриклассовому расстоянию. Наиболее наглядна и понятна мера информативности признака Q_b , опреде-

ляемая как доля образов, не попавших в интервал неопределенности $\epsilon_{\mathbf{f}}$, который определяется пере-

сечением областей значений признака f сигналов разных классов:

$$\epsilon_{\mathbf{f}} = [f_{\min}, f_{\max}]_{C1} \cap [f_{\min}, f_{\max}]_{C2} = [f_{Th1}, f_{Th2}] \quad (3)$$

Если информативность признака высока, то эталон J -того кластера переопределяется как характерная последовательность (ХП) \mathbf{cs}_j . Эта процедура повторяется многократно, $J = 1, 2, \dots$, для разных длин k , разных типов метрик и порогов. Она является базовой в комплексе алгоритмов автоматизированного поиска признаков пространств (1) и управляется по обратной связи с системой распознавания по методу k ближайших соседей [2 – 6]. Результатом работы системы поиска признаков пространств CAS \mathbf{fs}

$$\left\{ \mathbf{s}_0^{N-1} \right\}_{C1} \cup \left\{ \mathbf{s}_0^{N-1} \right\}_{C2} \xrightarrow{\text{CAS } \mathbf{fs}} \{ \mathbf{cs}_i \}, i = 1 \dots m \quad (4)$$

является набор ХП $CS = \{ \mathbf{cs}_i \}$, который будет использоваться в диагностирующей системе.

2.2. Преобразования сигнала и признаков

Информативность признаков пространств можно повысить, если в набор CS добавить последовательности, найденные в преобразованиях сигнала $\mathbf{T}(\mathbf{s}_0^{N-1})$. Например, использовать разложение сигнала на блоки $\mathbf{s}_{ib}^{(i+1)b-1}$ равной длины b , вычисление средних значений блоков m_i и формирование последовательности средних \mathbf{Mb} , в b раз более короткой, чем сигнал:

$$\mathbf{s}_0^{N-1} \rightarrow \mathbf{s}_0^{b-1} \cdot \mathbf{s}_b^{2b-1} \cdot \dots \cdot \mathbf{s}_{(i-1)b}^{ib-1} \cdot \dots \cdot \mathbf{s}_{(l-1)b}^{lb-1}; \quad (5)$$

$$m_i = \text{average}(\mathbf{s}_{ib}^{(i+1)b-1}); \quad (6)$$

$$\mathbf{s}_0^{N-1} \rightarrow m_0 m_1 \dots m_{N/b-1} = \mathbf{Mb}_0^{N/b-1}. \quad (7)$$

После Wavelet-преобразования можно использовать последовательности Wavelet-коэффициентов, как дифференциальных (\mathbf{w}), так и интегральных (\mathbf{a}). Сигнал преобразуется в матрицу Wavelet-коэффициентов, а затем каждая строка матрицы (последовательность Wavelet-коэффициентов) в векторы частот характерных последовательностей на каждом уровне Wavelet-преобразования:

$$\mathbf{s}_0^{N-1} \rightarrow \begin{pmatrix} \mathbf{w}_0^{n1-1} \\ \dots \\ \mathbf{w}_0^{nL-1} \end{pmatrix} \rightarrow \begin{pmatrix} v_{1,1} & \dots & v_{1,n1} \\ \dots & v_{l,nl} & \dots \\ v_{L,1} & \dots & v_{L,nL} \end{pmatrix}. \quad (8)$$

Аналогично можно использовать интегральные Wavelet-коэффициенты:

$$\mathbf{s}_0^{N-1} \rightarrow \begin{pmatrix} \mathbf{a}_0^{n1-1} \\ \dots \\ \mathbf{a}_0^{nL-1} \end{pmatrix} \rightarrow \begin{pmatrix} v_{1,1} & \dots & v_{1,n1} \\ \dots & v_{l,nl} & \dots \\ v_{L,1} & \dots & v_{L,nL} \end{pmatrix}. \quad (9)$$

В общем случае можно найти вектор \mathbf{f} :

$$\mathbf{s}_0^{N-1} \rightarrow |v_1 \dots v_M|^T = \mathbf{f}_1^M, \quad (10)$$

в который включены как частоты характерных последовательностей сигналов $v_i = v(\mathbf{cs}_i)$, $i \in 1..m$, так и частоты характерных последовательностей Wavelet-коэффициентов разных типов:

$$v_{l,j} = v(\mathbf{W}(\mathbf{cs}_i)), l \in 1..L, j \in 1..n_l.$$

Компоненты вектора \mathbf{f} образуют пространство признаков. При отборе ХП используется оценка информативности признаков пространств. Очень часто полезно и возможно преобразовать вектор частот ХП с помощью преобразования Карунена-Лоэва в один обобщенный признак:

$$\mathbf{Fr} = \mathbf{KL}(\mathbf{f}_1^M). \quad (11)$$

3. Данные и методика тестирования

Анализ целесообразности Wavelet-преобразования для расширения множества диагностических признаков выполнялся на двух множествах данных: на сигналах вибродиагностики подшипников трансмиссии ГТД [5, 6] и на данных моделей флюктуаций тока электродвигателей, выставленных и описанных на сайтах www.cacs.louisiana.edu, www.cis.temple.edu.

Задача I. Диагностика подшипников трансмиссии ГТД. Имеется 36 сигналов длиной 30000 отсчетов, частота дискретизации – 10 кГц. Сигналы классифицированы – известно, какому множеству – кондиционных или некондиционных подшипников они принадлежат. Поиск характерных последовательностей выполнялся по порогу, обеспечивающему попадание не менее 8% в кластер элементарных последовательностей.

Задача II. Диагностика и классификация неисправностей электродвигателя [7]. Имеется 420 сигналов тока длиной 1500 отсчетов. Частота дискретизации – 33,3 кГц. Сигналы классифицированы на 21 класс – исправный электродвигатель и 20 классов неисправных. Каждый класс представлен 20 сигналами. Поиск характерных последовательностей выполнялся по порогу, обеспечивающему попадание не менее 12% в кластер элементарных последовательностей.

Перебор элементарных последовательностей сигнала для обеих задач велся по особым точкам:

пересечениям нулевого уровня и минимумам (для второй задачи еще и по максимумам). Сравнение элементарных последовательностей велось по метрикам СКО, Чебышева и $(1 - \rho)$, где ρ – коэффициент корреляции. Порог при удалении парных корреляций был установлен равным 0,1.

Оценивались вероятности правильного распознавания \hat{p}_I , \hat{p}_{II} по методу k ближайших соседей по обобщенному признаку (11), сформированному при помощи преобразования понижения размерности (преобразования кластеризации Карунена-Ловэа) признакового пространства на основе частот ХП Wavelet- коэффициентов.

Оценка производится по методу скользящего контроля по блокам, так как объем обучающей выборки очень мал. Для задачи диагностики подшипников трансмиссии ГТД выполнялся скользящий контроль по 6 блокам, для задачи диагностики электродвигателей – по 4. Методика скользящего контроля по k блокам заключается в следующем.

1. Случайным образом разбиваем множество классифицированных образов на k, по возможности одинаковых подмножества, (желательно с сохранением долей образов каждого класса).

2. Строим k разбиений исходного множества на две выборки – обучающую и тестовую. Для каждого разбиения тестовая выборка – это одно из k подмножеств, сформированных на предыдущем шаге, а обучающая – все остальные образы.

3. Для каждого разбиения выполняется поиск признаков, строится классификатор на обучающей выборке, классификатор тестируется на тестовой выборке.

Таким образом, все k оценок будут получены на независимых данных. Оценка точности распознавания – это среднее по k полученным оценкам

4. Анализ результатов экспериментов

Оценки вероятностей правильного распознавания в рассматриваемых задачах приведены в табл. 1.

Количество ХП, отобранных в последовательностях Wavelet-коэффициентов разных уровней, приведены в табл. 2.

В задаче I наибольшее количество ХП находится на 3-м уровне, в задаче II – на уровнях 2 и 1, что можно объяснить фильтрующими свойствами преобразования.

Информативность ХП в зависимости от источника можно оценить по табл. 3. Характерные последовательности проиндексированы в пределах одного источника: сигнала, Wavelet-коэффициентов и интегральных Wavelet-коэффициентов.

Примеры наиболее информативных ХП приведены на рис. 1.

Таблица 1

Вероятности правильного распознавания

Источник ХП	\hat{p}_I , %	\hat{p}_{II} %
Сигналы	83,3	99
Wavelet-коэффициенты	83,3	99
Интегральные Wavelet-коэффициенты	94,4	98
Обобщенный признак	88,8	100

Таблица 2

Количество характерных последовательностей, автоматически отобранных на разных уровнях Wavelet-представления

Источник ХП	Wavelet-коэффициенты		Интегральные Wavelet-коэффициенты	
	ПТ	ЭД	ПТ	ЭД
Уровни анализа				
1	3	7	5	9
2	5	8	3	4
3	12	0	9	2
4	3	0	1	0
5	2		2	
6	0		5	

Таблица 3

Информативность ХП в сигналах вибродиагностики

Источник	Метрика	Уровень	Индекс	Q_f
Сигнал S	$1 - \rho$		1	0,51
			2	0,38
			3	0,5
			4	0,6
			5	0,56
			6	0,46
			7	0,49
Wavelet коэффициенты W	$1 - \rho$		3	0,63
			2	0,63
			5	0,59
			3	0,45
Интегральные Wavelet-коэффициенты Wa	СКО		5	0,75
			3	0,72
			3	0,68
			4	0,67
			3	0,66
			3	0,61

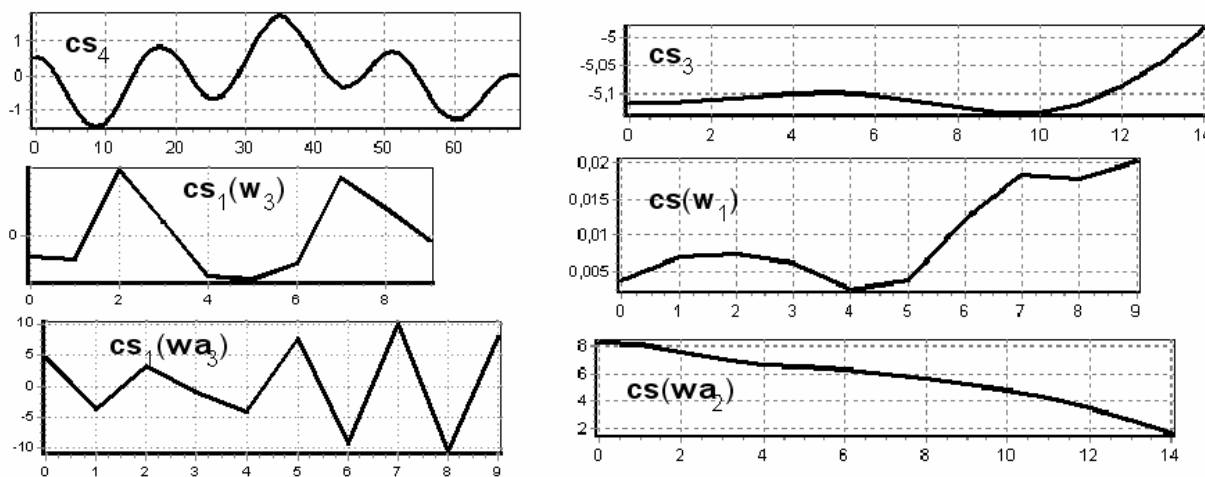


Рис. 1. Примеры наиболее информативных ХП

Новое решение задачи цифровой автоматической диагностики состояния подшипников трансмиссии ГТД, основанное на многомасштабном Wavelet-разложении вибросигналов и подсчете частот характерных последовательностей в интегральных Wavelet-коэффициентах, обеспечивает более высокую вероятность правильного распознавания, чем диагностика при помощи спектральных и стати-

стических признаков. Рис. 2 позволяет сопоставить разделимость образов вибросигналов разных классов при различных источниках для $M = 25$.

Наилучшие результаты получаются при одновременном использовании ХП, найденных в сигналах, Wavelet-коэффициентах и интегральных Wavelet-коэффициентах, особенно при увеличении M до 40.




Рис. 2. Обобщенные образы кондиционных (кружок) и некондиционных (квадрат) ПП.; оси помечены символами источников ХП

Информативность ХП в Wavelet-коэффициентах несколько выше, чем в сигнале, а в интегральных Wavelet-коэффициентах еще выше. По-видимому, основным фактором, влияющим на информативность ХП в задаче диагностики подшипников является уровень высокочастотного шума. На это указывает тот факт, что в задаче I наибольшее число ХП отобрано на 3-ем уровне, а в задаче II – на 2-м. Кроме того, в сигнале более информативные ХП отбираются по коэффициенту корреляции, в интегральных Wavelet-коэффициентах преобладают ХП, отобранные по метрике СКО, в высокочастотных Wavelet-коэффициентах на 3-м уровне используется коэффициент корреляции, а на 5-м – СКО.

Наконец, на необходимость сглаживания указывают хорошие результаты, полученные по ХП в усредненных данных (рис. 2).

Задача II решена на основе модели смеси гауссовских распределений в восстановленных фазовых пространствах [7]. Это решение, как и МХП, обеспечивает 100%-е распознавание для всех 21 состояний ЭД. Испытания проводились по методу скользящего контроля по 10 блокам, эти условия не такие жесткие, в какие были поставлены алгоритмы АХП (4 блока).

Спектры сигналов (рис. 3) не несут информации, пригодной для распознавания.

Заключение

Декомпозиция сигналов сложных источников на характерные последовательности, существенные для диагностики, и неинформативные участки сигнала, а также аналогичные операции над Wavelet-коэффициентами позволяют диагностировать со-

стояние объекта по количеству характерных последовательностей, которые для исправного и неисправного состояния объектов различаются. По определению, если количество элементарных последовательностей для разных состояний объекта отличаются друг от друга несущественно, то последовательности не являются характерными.




Рис. 3. Спектры токов неисправных ЭД с разными дефектами (2 – 4 сломанных пластины)

Реализация метода для конкретных приложений разбивается на два этапа: 1) проверка возможности и эффективности диагностики на основе ХП; 2) структурно-параметрический синтез модулей предварительной обработки информации для диагностики.

Метод поиска ХП в больших объемах данных реализован в программной системе HIPERCUBE, поиск ХП занимает около недели. При наличии обучающей выборки в виде записей цифровых сигналов, зарегистрированных в различных состояниях источника, можно с помощью программного обеспечения поиска характерных последовательностей HIPERCUBE экспериментально оценить пригодность и эффективность предлагаемого метода анализа для конкретных задач. Если метод диагностики на основе ХП оказывается эффективным, то по апробированной технологии быстро разрабатываются и настраиваются программные модули предварительной обработки информации для систем диагностики. Таким образом, при наличии обучающей выборки можно очень быстро выполнить структурно-параметрический синтез модулей предварительной обработки информации и предоставить их программную реализацию.

Литература

1. Браверман Э.М. Структурные методы обработки данных / Э.М. Браверман, И.Б. Мучник. – М.: Наука, гл. ред. физ.-мат. лит., 1983. – 340 с.
2. Горшков А.П. Система диагностики состояния сложных технических объектов по характерным последовательностям цифровых сигналов /

А.П. Горшков, Т.П. Грызлова // Информационные технологии. – М.: Новые технологии, 2008. – № 9. – С. 12-17.

3. Горшков А.П. Система формирования образа и классификации временных рядов по характерным последовательностям. Цифровая обработка сигналов / А.П. Горшков, Т.П. Грызлова // Цифровая обработка сигналов. – 2008. – № 3. – С. 37-41.

4. Горшков А.П. Автоматизированное формирование пространств статистик характерных последовательностей для распознавания изображений и временных рядов / А.П. Горшков, Т.П. Грызлова // Труды 10-й международной конференции «Цифровая обработка сигналов и ее применение». – М., 2008. – Т. 2. – С. 41-45.

5. Диагностика состояния подшипников трансмиссии газотурбинных двигателей в пространствах статистик характерных последовательностей вибраций / А.П. Горшков, Т.П. Грызлова, Б.И. Комаров, В.Т. Шепель // Авиационно-космическая техника и технология. – 2006. – Т. 36, № 10. – С. 67-71.

6. Горшков А.П. Семейство эффективных признаков для диагностики состояния сложных технических систем на примере подшипников трансмиссии ГТД / А.П. Горшков, Т.П. Грызлова // Труды 9-й международной конференции «Распознавание образов и анализ изображений: новые информационные технологии». – Нижний Новгород, 2008. – Т. 2. – С. 47-51.

7. Series Classification Using Gaussian Mixture Models of Reconstructed Phase Spaces / R.J. Povinelli, M.T. Johnson, A.C. Lindgren, J.Ye. Time // IEEE transactions on knowledge and data engineering, june 2004. – Vol. 16, No. 6. – P. 111-114.

Поступила в редакцию 12.05.2009

Рецензент: д-р техн. наук, проф., проф. кафедры В.Т. Шепель, начальник КО сертификации двигателей «ОАО «Сатурн», Рыбинская государственная авиационная технологическая академия им. П. А. Соловьева, Рыбинск, Россия.

ДЕКОМПОЗИЦІЯ СИГНАЛІВ СКЛАДНИХ ДЖЕРЕЛ НА ОСНОВІ ХАРАКТЕРНИХ ПОСЛІДОВНОСТЕЙ WAVELET-КОЕФІЦІЄНТІВ

О.П. Горшков, Т.П. Грызлова

Запропоновано метод попередньої обробки інформації в системах діагностики на основі декомпозиції діагностичних сигналів і/або їх Wavelet-перетворень на інформативні і неінформативні елементи. Послідовність вважається інформативною (характерною, ХП), якщо частоти її зустрічаємості в сигналах різних класів істотно відрізняються. Виконано аналіз впливу Wavelet-перетворення на інформативність ХП в задачах діагностики підшипників трансмісії ГТД по вібросигналах і електричних двигунах по моделях флюктуацій струму. Інформативність ХП Wavelet-коефіцієнтів опинилася декілька вище, ніж ХП сигналів. Оцінки вірогідності правильного розпізнавання, які отримані за методом ковзаючого контролю, показують, що якщо джерело має великий рівень шуму, то найбільш корисними є ХП інтегральних Wavelet-коефіцієнтів. Ознаки на їх основі забезпечують повну лінійну роздільність образів вібраційних сигналів кондиційних і некондиційних підшипників і дозволяють зменшити кількість помилок при діагностиці. За наявності повчальної вибірки у вигляді записів цифрових сигналів, зареєстрованих в різних станах джерела, за допомогою програмного забезпечення пошуку ХП можна експериментально оцінити ефективність розробленого методу для конкретних завдань.

Ключові слова: діагностика, цифрові сигнали, структурні методи аналізу, характерна послідовність, Wavelet-перетворення, підшипники трансмісії ГТД, інформативність ознаки.

A DECOMPOSITION OF COMPLEX SOURCES SIGNALS BASED ON CHARACTERISTIC SEQUENCES OF THE WAVELET-COEFFICIENTS

T.P. Gryzlova, A.P. Gorshkov

The techniques of diagnostics of the complex technical objects is proposed. It is based on signals' decomposition in informational and inconclusive elements and the search of characteristic sequences in digital signals and/or Wavelet-coefficients. A sequence is assumed to be an informative one (characteristic, CS), if the frequencies of CS-occurrence in different classes' signals are essentially divergent. The CS-informativeness of signals and their Wavelet-coefficients were analysed on examples of the problems of diagnostics of transmission bearing of GTE and inductive motors current waveforms. The CS-informativeness of Wavelet-coefficients is occurs some over than one of signals. Estimations of probability of correct classification have been evaluated by sliding test technique. If a source is noised then characteristic sequences in cumulative Wavelet-coefficients are most useful. The CS-based features provide the complete linear discriminability of bearing patterns and allow to reduce amount of errors. We can to evaluate experimentally an effectiveness of CS-analysis techniques on special and concrete problems and systems with the program of CS-search, if we have the learning sample as records of digital signals.

Key words: diagnostics, digital signals, structure analysis techniques, characteristic sequence, Wavelet-transformation, transmission bearing of GTE, feature's informativeness.

Грызлова Татьяна Павловна – канд. техн. наук, доцент, доцент кафедры математического и программного обеспечения электронных вычислительных систем Рыбинской государственной технологической академии им. П.А. Соловьева, Рыбинск, Россия, e-mail: kntpgryzlova@mail.ru .

Горшков Алексей Павлович – ведущий инженер-программист РГАТА, Рыбинск, Россия, e-mail: algor@land.ru, info@iss-lab.ru.