

ОСОБЕННОСТИ ПРИМЕНЕНИЯ ЭТАЛОННЫХ МОДЕЛЕЙ ДЛЯ РАЗМЕТКИ ВРЕМЕННОГО РЯДА ПРИ РАСПОЗНАВАНИИ СОСТОЯНИЙ СЛОЖНОГО ОБЪЕКТА

С.И. Колесникова

Томский политехнический университет
Томский государственный университет систем управления и радиоэлектроники
E-mail: skolesnikova@yandex.ru

Представлена модель разметки стохастического временного ряда с нелинейным трендом на основе алгебраического подхода к синтезу корректных алгоритмов, являющаяся развитием проблемно-ориентированной теории синтеза обучаемых семейств алгоритмов с требуемыми свойствами. На основе модели получено семейство алгоритмов эталонной разметки временного ряда, исследованы его свойства. Приводятся данные численного моделирования.

Ключевые слова:

Сложный динамический объект, состояние объекта, распознавание состояний, стохастический временной ряд, разметка временного ряда, эталонная разметка временного ряда.

Key words:

Object in uncertainty, object state, recognition of states, stochastic time series, marking of stochastic time series, etalon marking of stochastic time series.

Исторически оценки состояний сложных динамических объектов (СДО) основаны, главным образом, на методах моделирования сложных систем, теории анализа, обработки и оценивания сигнальной информации, методах технической диагностики, методах анализа и прогнозирования временных рядов, методах нелинейной динамики и распознавания образов [1, 2].

Современные исследования распознавания состояний сложных объектов связаны с работами [3] (автоматизация огрубленного численного исследования динамической системы на основе использования методов распознавания образов и статистического моделирования), [4] (распознавание последовательности состояний сложного источника, как чередование и наложение характерных последовательностей друг с другом), [5] (управление состояниями сложных технических объектов на основе полимодельного многокритериального описания) и многими др.

Направление, связанное с применением алгебраического подхода [2, 6–8] к решению некорректных задач, является основным при автоматическом построении алгоритмов для распознавания нежелательных ситуаций (предаварийных) динамических систем, и развивается в трудах ВЦ РАН как исследование и апробация технологии разметки временных рядов с позиций теоретико-множественного описания [2]. В основе алгебраического подхода лежит идея разметки точек ряда аксиомами (правилами). На этапе обучения строится система аксиом, а на этапе распознавания – каждому классу характерного поведения ставится в соответствие определенная последовательность аксиом. Ключевой проблемой является выбор системы аксиом для данной конкретной задачи. Следует отметить, что формализованный подход к разметке стохастического временного ряда (СВР) отсутствует (известны отдельные эвристические решения с использованием нейросетей и генетических алгоритмов [8].

Несмотря на развитость выше перечисленных технических и математических подходов, существует ряд нерешенных проблем, связанных с особенностями нелинейных и нестационарных СДО: а) большой процент ошибок при использовании в задачах обнаружения предвестников зарождающихся «опасных» состояний (дефектов, разрушений), связанный с тем, что разброс величин измеряемых параметров превышает изменения, характерные для появления контролируемых состояний; б) проблема моделирования нестационарных рядов в настоящее время в теоретическом плане не разрешена, а в практическом – производится «подгонкой» и не всегда успешно; в) нейросетевые методы, логические методы и методы нечеткой логики позволяют строить более точные модели в условиях ограниченного набора обучающих данных, но при этом характеризуются относительной сложностью практической реализации, высокими требованиями к ресурсам ЭВМ, ограничениями применимости в реальном времени.

Целью настоящей работы является представление результатов исследования применения существующих эталонных моделей [9–14] к решению задачи разметки СВР и распознавания состояний сложного объекта, под которым понимается объект, характеризующийся свойствами: отсутствие полного аналитического описания (недостаточность априорной информации для построения адекватной модели, структурно сложный объект); нелинейность имеющихся моделей описания и/или нестационарность сопровождающего его поведение процесса (временного ряда).

Прежде всего, в продолжение работ [15, 16] внесем ясность в вопрос об алгоритме (приложение [15]) и алгоритме из [16], который возник по вине автора данной работы: во-первых, в списках литературы работ [15, 16] вместо указанной работы под номерами 14, 17, соответственно, должна быть указана работа [14] того же автора; во-вторых,

первая строка в приложении работы [15] должна читаться так: «алгоритм формирования мета-эталонных [14]». Автор данной работы сожалеет о допущенной ошибке и приносит свои извинения автору работы [14].

В данной статье дается основное содержание модели и реализующих ее метода и алгоритма разметки СВР для выявления закономерностей в стохастических рядах (решающих правил) при решении задачи распознавания состояний сложных объектов [6, 7]; дается правило применения эталонных моделей [9–14] для разметки временного ряда, показавшее хорошие результаты при распознавании состояний электро-механического объекта, где время отклика системы принятия решения весьма критично. Представлены результаты программного моделирования и примеры практического применения построенной модели.

Основные понятия. Постановка задачи

Пусть L – линейное нормированное пространство всевозможных числовых последовательностей; дан временной ряд $y_1, \dots, y_n, y_j, j=1, n$ – аддитивная смесь изменяющейся со временем детерминированной составляющей x_k и измерительного белого шума $\xi_j, E\xi_j=0, E\xi_j^2=\sigma_\xi^2<\infty$:

$$y_j = x_j + \xi_j, j \geq 0. \quad (1)$$

Предполагается, для i -го фрагмента ряда (1) (интерпретируемого как состояние динамического объекта) процесс описывается моделью:

$$y_j^{(i)} = x_j^{(i)} + \xi_j^{(i)}, j \geq 0, i = \overline{1, I}, \quad (2)$$

где $x_j^{(i)} = f_j^{(i)} = f^{(i)}(j\Delta), \Delta > 0, f^{(i)}(t) \in R$ – некоторая неизвестная функция, описывающая поведение неслучайной составляющей $x_j^{(i)}$ СВР.

Задача выделения тренда определяется пятеркой зафиксированных параметров $\Theta(\Phi, M, \mu, LS, \sigma_\xi^2)$, где $\Phi = \{f_k(t), k = \overline{1, n_j}\}$ – множество функциональных зависимостей, домен алфавита разметки $M = \{l_1, \dots, l_m\}$, μ – система аксиом, LS – обучающая выборка, и ставится как задача классификации: каждой точке ряда u должен быть сопоставлен символ из словаря разметки M (номер класса из множества классов).

Решение задачи на основе проблемно-ориентированной теории

1. Модель разметки СВР. Модель разработана на основе проблемно-ориентированной теории синтеза корректных алгоритмов [2], базовым принципом которой является алгебраический подход [1] к построению корректных процедур обработки информации на базе некорректных эвристических алгоритмов.

Формализация модели разметки состоит из двух этапов: 1) описание класса задач, критериев регулярности, разрешимости задачи разметки СВР и полноты; 2) построение эвристических алгоритмов решения задачи и корректирующих операций, на базе которых формируется корректная (безошибочная на прецедентах) процедура.

Определение 1. Стохастический вектор-объект определяется как вектор $Y^d = ((t_1, y_1), \dots, (t_d, y_d)), d \geq 1, t_j, y_j \in R, Y_j = (t_j, y_j) \in R^2, t_j = j\Delta, \Delta > 0, d \geq 1, t_1 < \dots < t_d$, где y_j удовлетворяет (1), (2).

Определение 2. Объекты $Y^d = ((t_1, y_1), \dots, (t_d, y_d)), Y^d = ((t'_1, y'_1), \dots, (t'_d, y'_d)), d \geq 0$ статистически эквивалентны, если в условиях модели (1) из того, что $y_j = x_j(t) + \xi_j(t), y'_j = x'_j(t) + \xi'_j(t)$ следует $x_j(t) = x'_j(t), j = \overline{1, d}$.

Определение 3. Разметки l_1^d, l_2^d – почти одинаковые ($l_1^d \approx l_2^d$), если число позиций, в которых метки не совпадают (не размечены) ($l_0 = 0$) меньше порогового значения.

Система аксиом называется корректной, если она удовлетворяет дополнительным ограничениям – требованиям полноты и однозначности. Система аксиом полна, если для любой точки исследуемого временного ряда найдется аксиома из системы аксиом, её размечающая; система аксиом удовлетворяет условию однозначности, если любая точка любого временного ряда может быть размечена лишь одной аксиомой.

Под «нулевой» аксиомой понимается аксиома, выполняемая во всякой точке исследуемого временного ряда, где не выполнима ни одна другая аксиома из фиксированной системы аксиом. Наличие «нулевой» аксиомы обеспечивает выполнение свойства полноты системы аксиом.

2. Локальные системы аксиом разметки СВР.

Условие корректности алгоритма А. Задача Θ выделения трендов заключается в синтезе такого алгоритма A , что для всех статистически эквивалентных вектор-объектов из любого обучающего поднабора алгоритм A дает почти одинаковые ответы. Для обеспечения разрешимости некорректной задачи разметки решаются два вопроса: 1) вопрос локализации аксиом и алгоритмов разметки и поиска оптимальной системы окрестностей; 2) вопрос регуляризации задачи разметки. Решение первого вопроса обеспечивается двумя локальными системами аксиом $\mu = \{\mu_u\}$: система $\mu_1 = \{\mu_u^1\}$ размечает скользящее окно ряда переменной длины, с величиной сдвига, равному размеру окна; система $\mu_2 = \{\mu_u^2\}$ размечает одну точку по окрестности $O(y_j, j_i + 1) = ((t_{j_1}, y_{j_1}), \dots, (t_{j_2}, y_{j_2})), i_1 \in [1, d], j \geq i_1$.

Правило 1 разметки временного ряда (система аксиом $\mu_1 = \{\mu_u^1\}$). Аксиома

$$\mu_u^1 : \bigcup_{d=1}^{\infty} (S^d \times M^d \times A^p) \rightarrow \{0, 1\}$$

задается на $d = (i_2 - i_1 + 1)$ точках; точка $(t_j, y_j) \forall j \in [i_1, i_2]$ является точкой с разметкой $l_j = f_u$ для отрезка $[t_{j_1}, t_{j_2}]$, если в условиях (1) при фиксированных функциях ϕ, ρ имеют место:

$$(a_1^{Ak}, \dots, a_{p_k}^{Ak}) = \arg \min_{a^{Ai} \in R^{p_k}} Cr_t \phi(a^{Ai}, j),$$

$$Cr_t \phi(a^{Ai}, j) = \sum_{l \in \{j-d+1, \dots, j\}} \phi \left(\left| y_l - \sum_{o=1}^{p_k} a_o^{Ai} y_{l-o} \right| \right), \quad (3)$$

ϕ – некоторая монотонно возрастающая на $(0, \infty)$ функция, $\phi(0) = 0, \dot{\phi}(x) = 0$ для любого $x > 0$,

$$\sup_{x \in R^*} |x^2 \dot{\phi}(x)| < \infty, \quad \rho(\mathbf{a}^k, \mathbf{a}^{Ak}) = \|\mathbf{a}^k - \mathbf{a}^{Ak}\|;$$

$$u = \begin{cases} \arg \min_{k=1, n_j} \rho(\mathbf{a}^k, \mathbf{a}^{Ak}), \text{Crt}_{\phi}(\mathbf{a}^{Ak}(p_k), j) < e_{\phi_j}, \\ l_0, \text{Crt}_{\phi}(\mathbf{a}^{Ak}(p_k), j) \geq e_{\phi_j}, \end{cases} \quad (4)$$

$\mathbf{a}^{Ak} = \mathbf{a}^{Ak}[i_1, i_2]$, \mathbf{a}^k – векторы AR- и DS-коэффициентов (авторегрессионной AR-модели и разностных схем), сопоставленные отрезку $[t_{i1}, t_{i2}]$, и функции f_k , соответственно; величина e_{ϕ_j} определяет точность подгонки (3) AR-модели для фиксированных ϕ, y_j .

Правило 2 разметки временного ряда (система аксиом $\mu_2 = \{\mu_u^2\}$). Аксиома $\mu_u^2 = \mu_u^2(\mathbf{O}(Y_j, d), l^j, \mathbf{a}^{Ak})$ – бинарная функция, задаваемая на одной точке $Y_j = (t_j, y_j)$ с окрестностью $\mathbf{O}(Y_j, d) = ((t_{d-j+1}, y_{d-j+1}), \dots, (t_j, y_j))$ по правилу: точка (t_j, y_j) является точкой с разметкой $l_j = f_u$, если в условиях модели (1) имеют место (3), (4) при фиксированных функциях ϕ, ρ , где $\mathbf{a}^{Ak} = \mathbf{a}^{Ak}[j, j+d-1]$, \mathbf{a}^k – векторы AR-коэффициентов и DS-коэффициентов, сопоставленные отрезку $[t_j, t_{j+d-1}]$ и функции f_k .

Основанием построения систем аксиом разметки является существование однозначного соответствия между функциями $f_k(t)$, $k=1, n_j$ с дробно-рациональным Z–преобразованием соответствующих последовательностей $\{f_k(j\Delta)\}$, $j \geq 0$ и значениями векторов DS-коэффициентов (разностных схем). Близость (по норме) векторов AR-коэффициентов (авторегрессии) и DS-коэффициентов определяет тип функции [17]; метод назван ARADS (AutoRegression, Adaptive algorithm, Difference Scheme).

Теорема 1 (Полнота и однозначность системы аксиом). Системы аксиом $\mu_1 = \{\mu_u^1\}$, $\mu_2 = \{\mu_u^2\}$, определенных правилами 1 и 2, для разметки СВР, порожденного процессом типа (2), обладают свойствами полноты и однозначности.

На базе алгоритма разметки с вышеопределенными системами аксиом $\mu = \{\mu_u\}$ разработан алгоритм скользящей реконструкции ряда как модификация широко известного метода Бока, основные положения которой следующие:

- используется идеология скользящего окна, размер и величина сдвига которого зависит от положения на временной оси анализируемого интервала;
- дается правило выбора вида функциональной зависимости для каждого окна, параметры которой оцениваются по текущему окну;
- модели аппроксимирующих функций могут быть неравными на разных сегментах, а длина временного ряда не ограничена;
- траектории сшиваются в скользящем режиме: в j -м окне строится новая траектория и подгоняется к построенной в $(j-1)$ -м окне, которая не изменяется (полагается окончательной) до момента начала j -го окна (начальное условие каждой следующей модели задано).

3. Регуляризация задачи разметки. Для решения вопроса регуляризации задачи разметки наряду с алфавитом $M_\alpha = \{l_1^\alpha, \dots, l_m^\alpha\}$ вводится алфавит M_β как основа регуляризирующей системы аксиом с приори-

ритетами μ^β : аксиома l_B^β выполнима только тогда, когда не выполнимы аксиомы $\{l_j^\alpha, j \notin B\}$: $M_\beta = \{l_B^\beta | B \in \mathcal{B} = (B_1, \dots, B_I)\}$, $B_i \subseteq \{1, \dots, m\}$, $i=1, I$. Соответствующие алфавитам $M_\alpha \subseteq M_\beta$ системы аксиом μ^α, μ^β и разметки названы $\alpha(\beta)$ -системой и $\alpha(\beta)$ -разметкой; обоснование способа регуляризации опирается на результаты теории информации [18, 19].

Определение 4. Условие статистической согласованности. $\alpha(\beta)$ -разметки статистически согласованы при выполнении условий:

$$P(l_j^\alpha, l_B^\beta) = P(l_B^\beta)P(l_j^\alpha / l_B^\beta), \quad j \in B;$$

$$P(l_j^\alpha) = \sum_{B \in \mathcal{B}} P(l_B^\beta)P(l_j^\alpha / l_B^\beta), \quad \forall j = \overline{1, m}. \quad (5)$$

Определение 5. Условие регуляризации. Алгоритм β -разметки при фиксированных статистически согласованных алфавитах M_α, M_β назван корректным регуляризатором, если выполнены условия:

$$P(l_B^\beta / l_j^\alpha) = 0, \quad j \notin B; \quad P(l_B^\beta / l_j^\alpha) > 0, \quad j \in B;$$

$$P(l_B^\beta / l_j^\alpha) > 0, \quad \text{для } B = \{j\}. \quad (6)$$

Далее обозначено l_B вместо l_B^β и l_j вместо l_j^α .

Определение 6. Задача разметки Θ β -разрешима, если существует корректный алгоритм β -разметки.

Поставлена задача оценивания распределения $\hat{P}_\alpha = (\hat{p}_{\alpha 1}, \dots, \hat{p}_{\alpha m})$ α -разметки l^α по распределению $P_\beta = (p_{\beta 1}, \dots, p_{\beta I})$ β -разметки l^β .

Определение 7. Условие асимптотической регулярности. β -разрешимая задача разметки Θ является асимптотически регулярной тогда и только тогда, когда для любого допустимого набора возможных решений, порожденного корректным алгоритмом β -разметки, существует α -разметка, вероятностное распределение которой $P_\alpha = (p_{\alpha 1}, \dots, p_{\alpha m})$ является единственным, максимизирующим вероятность β -разметки.

Теорема 2. (Критерий асимптотической регулярности) Задача разметки Θ асимптотически регулярна тогда и только тогда, когда для нее существует корректный алгоритм β -разметки A_β , удовлетворяющий условиям (5), (6).

4. Правило разметки СВР на основе эталонных моделей. В качестве диагностических признаков для i -го состояния Ω_i , $i=1, I$, принимается набор эталонов состояний СДО, построение которых осуществляется по одному из следующих методов [9–14], для которых удобно использовать классификацию [20]:

1) методы (Stolp, A-Stolp, FRiS-Stolp), основанные на FRiS-функции [9], суть применения которой означает получение оценок локальных плотностей классов в каждом объекте и вычисление отношений этих оценок; методы обладают хорошей обобщающей способностью; фактически этот же принцип применен и в методе мета-эталонных [14] с возможностью коррекции (дообучения) выборки;

2) метод опорных векторов SVM, в котором эталонами (опорными объектами) являются «пограничные» объекты; метод релевантных векторов RVM [12], отбирающий в качестве эталонов объекты, отстоящие от границы классов на определенном рас-

стоянии с целью избавления от шумовых объектов, что приводит к меньшему числу опорных объектов по сравнению с методом опорных векторов SVM [10, 11] и более высокой обобщающей способности;

3) метод отбора эталонов для алгоритма ближайшего соседа, основанный на минимизации функционала полного скользящего контроля [21], недостатком которого является низкая эффективность по времени.

Спецификой эталонной разметки временных рядов является «наложение» эталонов, связанное со смежностью фрагментов рядов при попарном рассмотрении состояний и способность эталонов выделять амплитуду шума (рис. 1), которая может быть весьма полезна при использовании метода эмпирической модовой декомпозиции [22], где, как известно, требуется ресурсоемкая операция интерполяции для построения огибающих.

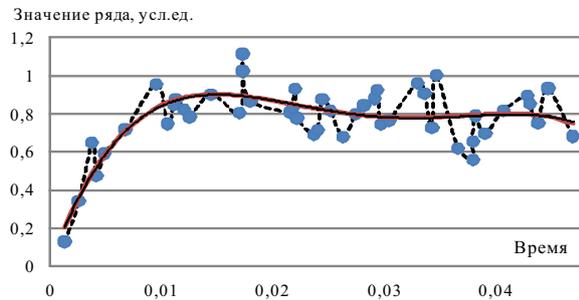


Рис. 1. Эталоны FRIS-Stolp временного ряда при 15%-м шуме

Введем дополнительные определения и сформируем систему аксиом.

Определение 8. Правило сопоставления i -му отрезку ряда длины b_i j -го эталона $E_j(b_j, E_j)$ назовем эталонной разметкой СВР.

Окрестность $O(s_h, d_h)$ точки (называемой опорной) $s_h = (t_h, y_h)$ — это вектор-объект: $O(s_h, d_h) = ((t_{i_1}, y_{i_1}), \dots, (t_h, y_h), \dots, (t_{i_2}, y_{i_2}))$, $i_1, i_2 \in \{1, \dots, N\}$, $i_1 < i_2$, $h \in \{i_1, \dots, i_2\}$, где величина $d_h = i_2 - i_1 + 1$ состоит из суммы размеров $i_2 - i_1$ окрестности и опорной точки окрестности $s_h = (t_h, y_h)$.

Определение 9. Совокупность вектор-объектов $O = \{O(s_h, d_h)\}$, $s_h = (t_h, y_h)$, $O(s_h, d_h) = ((t_{d-j+1}, y_{d-j+1}), \dots, (t_j, y_j))$, $h = 1, N$ образует систему O -окрестностей.

Пусть сформирована система эталонов $\{E_u\}$ по одному из существующих методов [9–14], заданное правило эталонной разметки СВР.

Правило 3 разметки временного ряда (система аксиом $\mu_3 = \{\mu_u^3\}$). Аксиома $\mu_u^3 = \mu_u^3(O(s_h, d_h), l^h)$ — бинарная функция, задаваемая на $d_h = (i_2 - i_1 + 1)$ точках; точка $s_h = (t_h, y_h) \forall h \in [i_1, i_2]$ является точкой с разметкой $l_h = E_u$ для отрезка $[t_{i_1}, t_{i_2}]$, если в условиях (1) при фиксированных функциях ρ имеют место:

$$u = \begin{cases} \arg \min_{k=1, n_E} \rho(\bar{s}_h, E_k), \rho(\bar{s}_h, E_k) < e_h, \\ l_0, \rho(\bar{s}_h, E_k) \geq e_h, \end{cases} \quad (4)$$

где $\rho(\bar{s}_h, E_k)$ — расстояние между усреднением по окрестности $O(s_h, d_h)$ точки s_h и эталоном E_k , величина e_h определяет погрешность правила.

Система окрестностей O_*^d должна удовлетворять оптимальному решению трехкритериальной задачи [23]: 1) минимальность неопределенности β -разметки вектор-объекта

$$H_\beta = - \sum_{B \in B} \ln(P(l_B)) P(l_B),$$

$$O_*^d = \arg \min_{O^d \in R^2} H_\beta = \arg \max_{O^d \in R^2} \sum_{B \in B} \ln(P(l_B)) P(l_B);$$

2) отсутствие (минимальность) ошибок на прецедентах, что выполнимо в случае корректности алгоритма β -разметки; 3) максимальная скорость алгоритма разметки.

5. Оценивание информативности эталонов. Традиционно в качестве критерия информативности признаков используется доля правильно распознанных объектов обучающей выборки в процедуре скользящего контроля. Информативность признаков измеряется перечисленными ниже показателями.

Показатель относительного сходства

$$Cr_1 = \sum_{j=1}^n (r_j^2 - r_j^1) / (r_{\max} - r_{\min}),$$

где n — объем обучающей выборки; r_j^2, r_j^1 — расстояния j -го объекта из обучающей выборки до ближайшего объекта своего образа и до ближайшего объекта образа-конкурента, соответственно; r_{\max}, r_{\min} — максимальное и минимальное расстояния между объектами обучающей выборки (метод RELIEF [13]).

Показатель Cr_2 на основе FRIS-функции [9]. Обозначим множества эталонов классов K_1 и K_2 через U_1 и U_2 , соответственно, $U_1 \cup U_2 = U'$. Вычисляем значения степени относительного сходства исследуемого нового объекта a^* с ближайшими эталонами каждого из классов:

$$\rho_{1/2} = F_{u/v} = \frac{r_u - r_v}{r_v + r_u}, \quad \rho_{2/1} = F_{v/u} = \frac{r_v - r_u}{r_u + r_v},$$

где r_u и r_v — минимальные расстояния от объекта a^* до ближайших u -го и v -го эталонов классов K_1 и K_2 , соответственно, с учетом их весовых коэффициентов. Решение принимается в пользу максимального значения степени сходства $s = \arg \max(\rho_1, \rho_2)$.

Показатель Cr_3 эффективности (являющиеся числовым выражением информативности признаков) на основе нелинейной скаляризации нескольких показателей, характеризующих признаки [23, 24].

Вероятностные и статистические показатели информативности признаков:

- для случая нормального распределения значений признаков применяется критерий Фишера в виде отношения $Q = |m_1 - m_2| / (d_1 + d_2)$, где m_1, m_2 и d_1, d_2 — математические ожидания и дисперсии первого и второго образов, соответственно;
- мера близости на основе коэффициента линейной корреляции $r(z_1, z_2); \rho(z_1, z_2) = 1 - |r(z_1, z_2)|$,

$$r(z_1, z_2) = \sum_{i=1}^n \bar{z}_1(y_i) \bar{z}_2(y_i), \quad \text{где } \bar{z}_1(y_i), \bar{z}_2(y_i) \text{ — нор-}$$

мированные и центрированные значения признаков z_1, z_2 для объектов выборки $y = (y_1, \dots, y_n)$;

$\rho(z_1, z_2) = 0$ тогда и только тогда, когда признаки связаны линейной зависимостью;

- меры важности признаков на основе энтропийного критерия Шеннона и дивергенции Кульбака, информационного критерия Акаике.

6. Алгоритмические композиции. Алгоритм разметки на основе системы аксиом 3 параметризуется видом используемых расстояний между объектом и эталоном, существенно влияющим на качество распознавания, рис. 2.

Формы графиков эффективности алгоритмов распознавания разных состояний сложных объектов (рис. 2) в зависимости от вида используемого расстояния $A(\rho)$ свидетельствуют о наличии участков «хуже», «лучше», «соизмеримо» для одной и той же алгоритмической модели и являются основанием построения композиций алгоритмов $C(A_1(\rho), \dots, A_g(\rho))$, где C – корректирующая операция [1, 2].

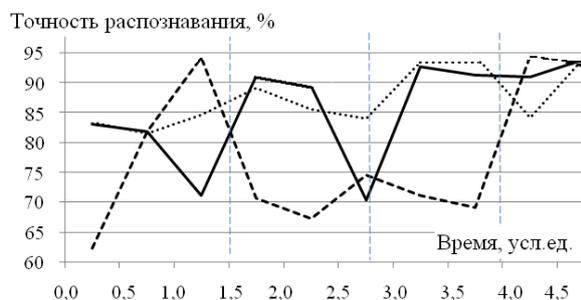


Рис. 2. Динамика усредненной эффективности распознавания 4-х состояний по сигналу объекта тремя алгоритмами $A(\rho)$ при фиксированной модели эталонов (Евклида (сплошная линия), Хемминга (пунктир), FRI-S-функции [9] (точечная линия))

Численное моделирование на ПЭВМ

В таблице приведены результаты экспериментальных исследований зависимости эффективности решающих правил от площади пересечения состояний СДО для обучающей выборки размером 10^4 объектов. Результаты являются средними по 20-и экспериментам.

На рис. 3 иллюстрируется возможность успешного применения эталонной модели для «кодирования» состояний СДО с последующим распознаванием состояний СДО, положительной особенностью которого является «разделение» отрезков, как реализаций образов состояний СДО, несмотря на их пересечение (30 %-е на рис. 3).

В таблице использовано обозначение типов эталонов, полученных по разным методам: E_0 – эталоны обычного усреднения на заданном окне (фрагменте); E_s – эталоны-столпы на основе функции FRI-S (FRI-S-Stolp); E_g – мета-эталон [14]; $S, \%$ – доля площади пересечения состояний (в %); E_{SVM} – эталоны метода опорных векторов SVM; E_{RVM} – эталоны метода релевантных векторов RVM; в качестве меры близости использовалась FRI-S-функция [9].

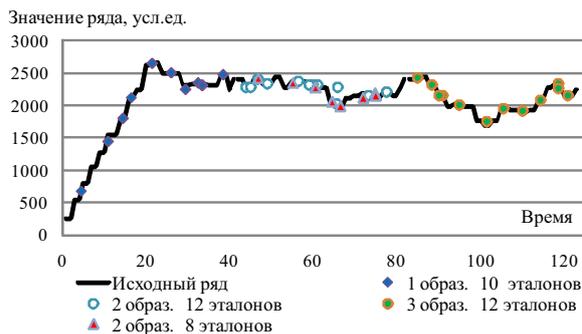


Рис. 3. Эталонная разметка временного ряда на примере сигнала частоты вращения ротора электродвигателя (период опроса непрерывных сигналов 840 мкс)

Таблица. Зависимость эффективности решающих правил от площади пересечения состояний при 30%-м шуме

$S, \%$	Эффективность распознавания состояний с применением эталонов, %					Время обучения при шаге квантования 0,287, мкс	Время распознавания, мкс
	E_s	E_g	E_{SVM}	E_{RVM}	E_0		
0	99,9	99,0	91,9	98,8	99,9	32	406
10	98,8	99,4	90,8	99,8	99,3	34	450
20	98,1	97,1	89,1	98,1	97,0	48	690
30	97,4	97,0	77,4	97,4	86,4	65	701
40	96,5	96,0	76,5	96,3	54,1	85	1003
50	95,2	90,2	65,2	91,1	34,7	197	1690

В качестве показателя уровня шума использована относительная погрешность γ :

$$\gamma = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100 \%,$$

где \hat{y}_i – значение сигнала, уровень шума в котором измеряется; y_i – истинное значение сигнала; n – объем наблюдений; данные приведены усредненым по 20-ти реализациям.

Выводы

Представлена модель разметки стохастического временного ряда с нелинейным трендом на основе алгебраического подхода к синтезу корректных алгоритмов. Результат исследования получен на базе развития [6, 7] проблемно-ориентированной теории синтеза обучаемых семейств алгоритмов выделения тренда в конечных плоских конфигурациях [2]. Построено правило эталонной разметки временного ряда. Достоинством композиций алгоритмов является способность решать задачи, связанные со сравнением динамических объектов, их классификацией и распознаванием состояний сложных объектов с неопределенностью в условиях минимальной априорной информации.

Работа выполнена при финансовой поддержке грантов РФФИ № 10-01-00462-а, 11-08-98071-р-Сибирь_а.

СПИСОК ЛИТЕРАТУРЫ

1. Журавлев Ю.И., Рудаков К.В. Об алгебраической коррекции процедур обработки (преобразования) информации // Проблемы прикладной математики и информатики. – М.: Наука, 1987. – С. 187–198.
2. Рудаков К.В., Чехович Ю.В. Алгебраический подход к проблеме синтеза обучаемых алгоритмов выделения трендов // Доклады РАН. – 2003. – Т. 388. – № 1. – С. 33–36.
3. Неймарк Ю.И., Таранова Н.Н., Теклина Л.Г. О возможностях изучения хаотических движений в конкретных динамических системах методами распознавания образов и математического моделирования // Математические методы распознавания образов: Сб. докладов XIV Всеросс. конф. – Владимирская обл., г. Суздаль, 21–26 сентября 2009 г. – М.: МАКС Пресс, 2009. – С. 422–425.
4. Грызлова Т.П. Формализация задачи распознавания последовательности состояний сложного источника // Математические методы распознавания образов: Сб. докладов XIV Всеросс. конф. – Владимирская обл., г. Суздаль, 21–26 сентября 2009 г. – М.: МАКС Пресс, 2009. – С. 333–337.
5. Охтилев М.Ю., Соколов Б.В. Юсупов Р.М. Интеллектуальные технологии мониторинга и управления структурной динамикой сложных технических объектов. – М.: Наука, 2006. – 410 с.
6. Колесникова С.И. Метод распознавания и оценивания состояний слабоформализованного динамического объекта на основе разметки временного ряда // Известия РАН. Теория и системы управления. – 2011. – № 3. – С. 3–14.
7. Колесникова С.И., Мертвцов А.Н. Метод разметки стохастического временного ряда // Труды Института системного анализа РАН. – 2011. – Т. 61. – № 1. – С. 48–59.
8. Васин Е.А., Костенко В.А., Коваленко Д.С. Автоматическое построение алгоритмов, основанных на алгебраическом подходе, для распознавания предаварийных ситуаций динамических систем // Искусственный интеллект. – 2006. – № 2. – С. 130–134.
9. Zagoruiko N.G., Borisova I.A., Dyubanov V.V., Kutnenko O.A. Methods of Recognition Based on the Function of Rival Similarity // Pattern Recognition and Image Analysis. – 2008. – V. 18. – № 1. – P. 1–6.
10. Cortes C., Vapnik V. Support-vector networks // Machine Learning. – 1995. – V. 20. – № 3. – P. 273–297.
11. Burges C.J.C. A tutorial on support vector machines for pattern recognition // Data Mining and Knowledge Discovery. – 1998. – V. 2. – № 2. – P. 121–167.
12. Tipping M. Sparse Bayesian learning and the relevance vector machine // J. Machine Learning Res. – 2001. – № 1. – P. 211–244.
13. Kira K., Rendell L. The Feature Selection Problem: Traditional Methods and a New Algorithm // Conf. Artificial Intelligence (AAAI-92). Proc. of the 10th Nat'l. Cambridge, Massachusetts, October 23–25, 1992. – P. 129–134.
14. Volchenko E.V. Research of features in association of training sample objects to meta-objects // Pattern Recognition and Image Analysis. New Information Technologies (PRIA-9–2008): Proc. of the 9th Intern. Con. – Nizhni Novgorod, September 15–20, 2008. – V. 1. – P. 291–294.
15. Колесникова С.И. Методы распознавания состояний динамических систем // Известия Томского политехнического университета. – 2010. – Т. 316. – № 5. – С. 55–62.
16. Колесникова С.И., Волченко Е.В. Подход к сглаживанию и реконструкции формы состояний стохастического объекта на основе модели эталонов // Известия Томского политехнического университета. – 2010. – Т. 316. – № 5. – С. 34–40.
17. Семенычев В.К. Идентификация экономической динамики на основе моделей авторегрессии. – Самара: АНО «Изд-во СНЦ РАН», 2004. – 243 с.
18. Галлагер Р. Теория информации и надежная связь. – М.: Советское радио, 1974. – 720 с.
19. Шоломов Л.А. О собственной информации нечетких текстов // Нелинейная динамика и управление. Вып. 6. – М.: Физматлит, 2008. – 340 с.
20. Воронцов К.В. Лекции по методам оценивания и выбора моделей // Forecsys. 2007. URL: <http://www.ccas.ru/frc/papers/vor04twim.pdf> (дата обращения: 25.10.2010).
21. Иванов М.Н., Воронцов К.В. Отбор эталонов, основанный на минимизации функционала полного скользящего контроля // Математические методы распознавания образов: Сб. докладов XIV Всеросс. конф. – Владимирская обл., г. Суздаль, 21–26 сентября 2009 г. – М.: МАКС Пресс, 2009. – С. 119–122.
22. Huang N.E., Shen Z., Long S.R., Wu M.C., Shih H.H., Zheng Q., Yen N.C., Tung C.C., Liu H.H. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis // Proc. Royal. Soc. Lond. A. – 1998. – V. 454. – P. 903–995.
23. Колесникова С.И. Свойства корректной модификации метода парных сравнений // Интеллектуальные системы. – 2010. – Т. 14. – Вып. 1–4. – С. 183–202.
24. Колесникова С.И., Янковская А.Е. Оценка значимости признаков для тестов в интеллектуальных системах // Известия РАН. Теория и системы управления. – 2008. – № 6. – С. 135–148.

Поступила 17.03.2011 г.