ПРИМЕНЕНИЕ МЕТОДА ОПОРНЫХ ВЕКТОРОВ В РЕАЛИЗАЦИИ БЛОКА ПРОГНОЗИРОВАНИЯ ПАРАМЕТРОВ СЛОЖНОЙ ТЕХНИЧЕСКОЙ СИСТЕМЫ

Ю.В. Дубенко[1), Е.Е. Дышкант[2)

1) к.т.н., доцент кафедры Информатики и вычислительной техники ФГБОУ ВО «Кубанский государственный технологический университет».
2) старший преподаватель кафедры Внутризаводского электрооборудования и автоматики Армавирского механико-технологического института (филиала) ФГБОУ ВО «Кубанский государственный технологический университет».

Аннотация: в статье приводится структура блока прогнозирования параметров сложных технических систем, реализованного на основе метода опорных векторов.

Ключевые слова: метод опорных векторов, прогнозирование, оптимизация.

APPLICATION OF THE SUPPORTED VECTORS METHOD IN THE IMPLEMENTATION OF THE FORECASTING UNIT FOR THE INDICATORS OF COMPLEX TECHNICAL SYSTEM

Yu.V. Dubenko[1), E.E. Dyshkant[2)

1) Ph.D., associate professor of the Department of Informatics and Computer Engineering of the Kuban State Technological University.
2) Senior Lecturer of the Department of Internal Electrical Equipment and Automation of the Armavir Mechanical-Technological Institute (Branch) FSBI of HE "Kuban State Technological University".

Annotation: the article presents the structure of the unit for predicting the parameters of complex technical systems, implemented on the basis of the support vector method.

Keywords: support vector method, prediction, optimization.

Совершенствование методов и подходов к управлению сложными техническими системами является одной из важнейших задач системного анализа. Важным условием надежности системы управления является возможность качественного управления сложной технической системой в условиях неопределенности, т.е. система должна быть способна «автоматически изменять значения своих параметров или структур при непредвиденных изменениях внешних условий на основании анализа состояния или поведения системы так, чтобы сохранялось заданное качество ее работы». Подобные системы относят к классу адаптивных. Адаптивное управление по прогнозированию позволяет предугадать возникновение проблемной ситуации, что позволяет снизить степень неопределенности и вовремя сработать на упреждение. Большое значение в этой связи имеет точность прогноза. В настоящее время все большую популярность в прогнозировании набирают методы теории искусственного интеллекта (ИИ). Среди методов теории ИИ отметим метод опорных векторов (SupportVectorMachine, SVM) [2], применяемый в задачах классификации и регрессии [3]. По результатам анализа литературы к главным преимуществам метода опорных векторов можно отнести [2,3,4,5] меньшее время сходимости в сравнении с ИНС, более простую процедуру определения структуры модели, при этом в точности результата данный метод практически не уступает ИНС.

В этой связи посвятим данную статью разработке архитектуры блока прогнозирования показателей сложной технической системы. Далее подробно рассмотрим основные компоненты разрабатываемого блока.

Адаптивный блок SVM-регрессии

В обучающем множестве $\{\bar{x}_k, y_k\}_{k=1}^{t}$- вектор $\bar{x}_k$ содержит значения главных компонент z_i, y_k – соответствующее значение временного ряда прогнозируемой величины ΔW. Пусть $\{\bar{x}_k, y_k\}_{k=1}^{t}$, $\bar{z}_k \in \mathbb{R}^n$, $y_k \in \mathbb{R}^n$ - обучающее множество, $f(\bar{x})$ – функция, имеющая отклонение от целевых показателей y_k не больше величины ε для всех обучающих данных, при этом величины ξ и ξ^* является «фиктивными переменными», такими, что [2,3,4,5]

$$min\ \frac{1}{2}||\omega||^2 + c\sum_{k=1}^{t}(\xi_{\ k} + \xi^{\ *}_{\ k})$$

$$\text{если}\begin{cases} y_k - \bar{\omega}^T\bar{x} - b \le \varepsilon + \xi_{\ k} \\ \bar{\omega}^T\bar{x} + b - y_k \le \varepsilon + \xi^{\ *}_{\ k} \\ \xi_{\ k}, \xi^{\ *}_{\ k} \ge 0 \end{cases}$$

Решение задачи сводится к следующей системе [4, 5]:

$$\max\begin{cases} -\frac{1}{2}\sum_{k,l=1}^{t}(\alpha_k - \alpha_k^*)(\alpha_l - \alpha_l^*)K(\bar{x}, \bar{x}_k) \\ -\varepsilon\sum_{k=1}^{t}(\alpha_k - \alpha_k^*) + \sum_{k=1}^{t} y_k(\alpha_k - \alpha_k^*) \end{cases}$$

$$\text{если} \sum_{k=1}^{t}(\alpha_k - \alpha_k^*) \text{и}\ \alpha_k, \alpha_k^* \in [0, c]$$

где c - параметр сложности, от величины которого зависит количество вычисляемых опорных векторов, определяется эмпирическим путем.

В итоге получаем следующее уравнение регрессии [4]:

$$a(x) = \sum_{k=1}^{t} (\alpha_k - \alpha_k^*)\, K(\bar{x}, \bar{x}_k) - \omega_0$$

где $a(x)$ – функция, наилучшим образом аппроксимирующая исходные показатели $\{\bar{x}_k, y_k\}_{k=1}^{t}$.

Весьма важной задачей является выбор ядра. Отметим следующие виды функции ядра: полиномиальное, гауссово и MLP-ядро [4]. Наиболее часто используемым является гауссово ядро, определяемое формулой [4]:

$$K(x, x_k) = exp(-||\bar{x} - \bar{x}_k||^2/\sigma^2)$$

где σ – определяемый эмпирическим путем параметра «разброса функции вокруг центральной точки» [4].

В итоге получаем два блока: «блок SVM-регрессии» и «блок SVM с инициализируемыми параметрами».

Отметим, что четкие критерии выбора величины параметров c, σ отсутствуют и их величина определяется эмпирическим путем. В этой связи возникает актуальность применения в этих целях методов оптимизации, таких как GA (Genetic algorithm), ACO (Antcolonyoptimization), PSO (Particleswarmoptimization) [1], что позволит повысить точность конечного результата. Подробно данный вопрос рассматривается в следующих разделах.

Блок оптимизации параметров SVM с применением алгоритма ACO

В основе работы данного блока заложен алгоритм [1], адаптированный для данной задачи. Для выполнения данного алгоритма в качестве вершин графа используются инициализируемые случайными числами значения параметров c и σ. В качестве целевой функции применяется функция $Func_{ij} = \frac{1}{MAPE_{ij}}$, где $MAPE_{ij}$ – величина средней абсолютной ошибки [1] SVM при выбранных параметрах c_i и σ_j - чем меньше величина ошибки, тем более оптимальным является путь.На вход блока поступает промежуточный результат выполнения алгоритма SVM - $\bar{y}_{\text{р}}$, промежуточный показатель ошибки обучения $MAPE$, промежуточные весовые коэффициенты α, параметры c, σ для дальнейшей оптимизации (если не достигнуто условие останова алгоритма); выходные параметры: оптимизированные значения параметров $c_{\text{о}}$, $\sigma_{\text{о}}$, $k_{1\text{о}}$, $k_{2\text{о}}$, соответствующая им ошибка $MAPE$, результат выполнения SVM – $y_{\text{р}}$, весовые коэффициенты α.

Блок оптимизации параметров SVM с применением GA

Основан на применении генетических алгоритмов [1]. Вид применяемой хромосомы: $Ch < c_1, \sigma_1 >, \dots, < c_l, \sigma_l >$. Функция приспособленности хромосомы: $Pr(Ch_q) = 1/(\frac{MAPE(Ch_q)}{l})$. Входные и выходные данные для блоков оптимизации параметров SVM с применением алгоритмов ACO и GA аналогичны.

Блок оптимизации параметров SVM с применением PSO

Представленный алгоритм представляет собой адаптированную для данной задачи версию алгоритма, приводимого в [1]. Схематическое представление применяемой частицы: $Particlec, \sigma$. Применяемая целевая функция: $Cf(Particle_q) = 1/MAPE(Particle_q)$, где $q = 1, \dots, M_1$ – номер частицы. Входные и выходные данные для блоков оптимизации параметров SVM с применением алгоритмов ACO и PSO аналогичны.

Блок оптимизации параметров SVM

На основании полученных выше блоков простроим «блок оптимизации параметров SVM», основу которого составляют блоки OP-GA – «блок оптимизации параметров SVM с применением алгоритма GA»; OP-PSO – «блок оптимизации параметров SVM с применением алгоритма PSO»; OP-ACO1, OP-ACO2, OP-ACO3 – блоки оптимизации параметров SVM с применением алгоритма ACO с различными вариантами начального положения «муравьев»; SVM – «блок SVM»;SVM-Init – «блок SVM с инициализируемыми параметрами».

Структура «адаптивного блока SVM-регрессии»

Добавим к «блоку оптимизации параметров SVM» блок сохранения и загрузки параметров SVM получим «адаптивный блок SVM-регрессии».

Схема полученного блока прогнозирования показателей сложной технической системы

Структурная схема полученного «блока прогнозирования показателей сложной технической системы» представлена на рисунке 1.

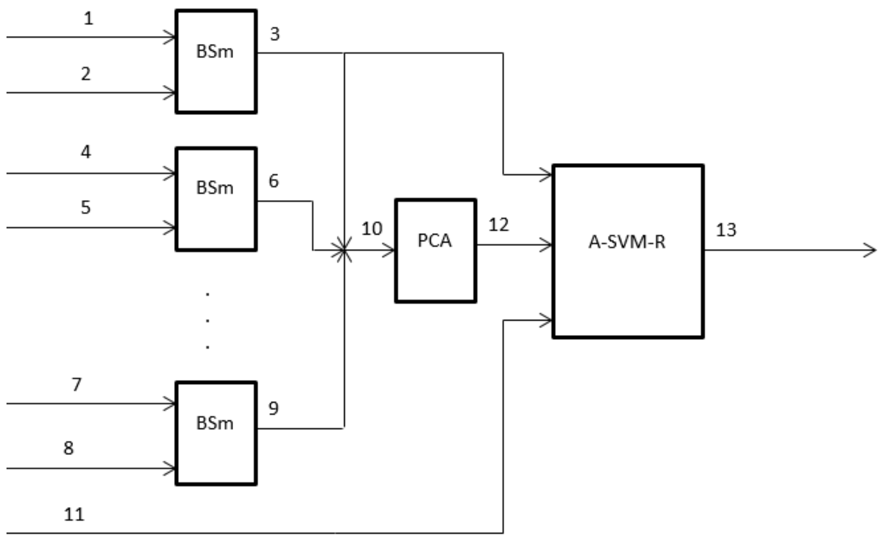

Рисунок 1 – Структурная схема полученного «блока прогнозирования показателей сложной технической системы»

На рисунке 1 приняты следующие условные обозначения: BSm – «блок сглаживания временного ряда», выполненный на основе метода Винтерса-Холта [7]; PCA – «блок снижения размерности и отбора наиболее информативных факторов», выполненный на основе метода «главных компонент» [6]; A-SVM-R – «адаптивный блок SVM-регрессии», 1– исходный временной ряд прогнозируемой величины ΔW; 2 – параметры блока сглаживания временного ряда ΔW; 3 – «сглаженный» временной ряд ΔW; 4 – исходный временной ряд вторичного фактора F_1; 5 – параметры блока сглаживания временного ряда F_1; 6 – «сглаженный» временной ряд F_1; 7 – исходный временной ряд вторичного фактора F_n; 8 – параметры блока сглаживания временного ряда F_n; 9 – «сглаженный» временной ряд F_n; 10 – временные ряды исходных n факторов; 10 – векторы данных $\{\bar{x}_k\}_{k=1}^{t}$, включающие ретроспективные показатели прогнозируемой величины и вторичных факторов; 11 – параметр, устанавливающий режим работы блока («режим обучения», «режим прогнозирования»); 12 – временные ряды z_i, $i = 1, \dots, n'$(вторичные факторы, оказывающие влияние на величину на прогнозируемую величину); 13 – результат прогнозирования $y_{\text{р}}$.

Разработанный блок обладает следующими преимуществами: высокая точность прогноза, достигаемая за счет охвата широкого спектра факторов, оказывающих влияние на прогнозируемую величину, применения высокоэффективных методов прогнозирования, а также снижения размерности и отбора наиболее информативных факторов; адаптивность, достигаемая за счет возможности автоматической настройки параметров SVM, оказывающих влияние на точность результата.

Список использованной литературы:

1. Дубенко Ю.В., Дышкант Е.Е. Разработка математической модели многофакторного нечеткого прогнозирования потерь электроэнергии: монография / Кубан. гос. технол. ун-т. – Краснодар: Изд. ФГБОУ ВПО «КубГТУ», 2016. – 120 с.

2. Хайкин С. Нейронные сети: полный курс, 2-е изд., испр. / С. Хайкин; Пер. с англ. – М.: ООО «И.Д. Вильямс», 2006. – 1104 с.

3. Вьюгин В.В. Математические основы теории машинного обучения и прогнозирования / В.В. Вьюгин – М. МЦНМО 2013, – 304 с.

4. Suykens Johan A. K. Least squares support vector machines / Johan A. K. Suykens, Jony Van Gestel, Jos De Brabanter, Bart De Moor and JoosVandewalle. – London: World Scientific, 2002., 310 p.

5. Smola A.J., Schölkopf B. A tutorial on support vector regression / A.J. Smola, B. Schölkopf // Statistics and Computing. – 2004. – Vol. 14, Issue 13 – P. 199–222.

6. Айвазян С.А. Прикладная статистика: Классификация и снижение размерности: Справ.изд. / С.А. Айвазян, В.М. Бухштабер, И.С. Енюков, Л.Д. Мешалкин; Под ред. С.А. Айвазяна. – М.: Финансыистатистика, 1989. – 607 с.

7. Jansen M. Call Centre Forecasting. A comprehensive analysis of missing data, extreme values, holiday influences and different forecasting methods [Электронноеиздание]/ Jansen M. – Tilburg: Tilburg University, 2010. – Режимдоступа: URL: http://dtic.mil/dtic/tr/fulltext/u2/a473648.pdf .