

УДК 681.518.2:004.942

Краткосрочное прогнозирование многомерных временных рядов с использованием робастных нейросетевых моделей

И. М. Антонян², В. А. Горячая¹, А. И. Зеленский², Е. М. Угрюмова¹¹Національний аерокосмічний університет ім. Н. Е. Жуковського «ХАІ», Україна²Харьковская медицинская академия последипломного образования, Украина

Предложена статистическая модель контроля состояния динамических систем с применением робастных нейросетевых моделей с задержкой во времени. Разработан метод прогнозирования многомерных временных рядов, полученных на основе данных мониторинга переменных состояния динамических систем. Проведено сравнение качества прогнозирования с помощью предложенных моделей (в форме однонаправленной и радиально-базисной обучаемых искусственных нейронных сетей). Получены оценки доверительных интервалов для прогнозируемых значений и размерности пространства коинтегрированных временных рядов с учетом точности измерения переменных состояния.

Ключевые слова: прогнозирование, многомерные временные ряды, обучаемые искусственные нейронные сети, оценивание доверительных интервалов для прогнозируемых значений и размерности пространства коинтегрированных временных рядов, априорная неопределенность данных.

Запропоновано статистичну модель контролю стану динамічних систем із застосуванням робастних нейромережевих моделей з затримкою в часі. Розроблено метод прогнозування багатовимірних часових рядів, отриманих на основі даних моніторингу змінних стану динамічних систем. Проведено порівняння якості прогнозування за допомогою запропонованих моделей (у формі односпрямованої і радіально-базисної штучних нейронних мереж, які навчаються). Отримано оцінки довірчих інтервалів для прогнозованих значень і розмірності простору коінтегрованих часових рядів з урахуванням точності вимірювання змінних стану.

Ключові слова: прогнозування, багатовимірні часові ряди, штучні нейронні мережі, які навчаються, оцінювання довірчих інтервалів для прогнозованих значень і розмірності простору коінтегрованих часових рядів, априорна невизначеність даних.

The statistical state monitoring model of dynamic systems with using robust time lagged neural network have been proposed. The forecasting method of multidimensional time-series, which had derived from monitoring data of dynamical systems variables state have been developed. Comparison of the forecasting quality via proposed models (in form of the feedforward and radial-basis trained neural networks) have been carried out. Estimates of confidence intervals for the predicted values and dimension of the cointegrated time series space with measurement accuracy of state variables have been obtained.

Key words: forecasting, multidimensional time-series, trained artificial neural network, estimation of confidence intervals for the predicted values and the dimension of cointegrated time-series, a priori uncertainty of the data.

1 Постановка проблемы и ее актуальность

Будем рассматривать в качестве объекта исследования процесс контроля состояния элементов динамических систем, к примеру, медико-биологических систем (МБС), основанный на данных мониторинга контролируемых переменных состояния. Результаты мониторинга переменных состояния –

временные ряды – представляют собой совокупность измеренных значений переменных, получаемых на неразрывно примыкающих друг к другу интервалах времени, в течение которых значения переменных существенно не изменяются. Временные ряды эволюционных процессов, являясь дискретной моделью контроля состояния динамических систем, как правило, содержат параметрическую неопределенность, являются нестационарными и зашумлены.

При решении задачи прогнозирования временного ряда требуется структурировать математическую модель контроля состояния (ММКС) – тренд – функциональную зависимость, отражающую связь между последующими и предыдущими значениями временного ряда, адекватно описывающую временной ряд. После того, как ММКС структурирована, требуется вычислить прогнозируемые значения временного ряда, а также их доверительные интервалы.

Задача прогнозирования таким образом в результате ее декомпозиции должна быть представлена как последовательность решения взаимосвязанных задач: мониторинг состояния (выбор и измерения значений контролируемых переменных состояния системы через определенные промежутки времени); определение информативности (значимости) «частных» контролируемых переменных состояния, отражающих свойства элементов; приведение данных мониторинга к виду, пригодному для регрессионного анализа; структуризация ММКС; вычисление прогнозируемых значения временного ряда с применением ММКС, а также соответствующих им доверительных интервалов.

Рассмотрению задач теории и практики контроля состояния динамических систем уделяется большое внимание как учеными на Украине, так и за её пределами. К настоящему времени опубликовано множество работ, посвященных описанию математических моделей и методов контроля состояния технических и МБС [1-13].

Классификация статистических моделей контроля состояния динамических систем и процессов представлена на рис. 1. Можно выделить три основных типа моделей: модели стохастической фильтрации, регрессионные (структурно-параметрические модели) и вероятностные модели. На множестве моделей стохастической фильтрации можно выделить фильтры Калмана-Бьюси [14]. Регрессионные модели делятся на сглаживающие и рекуррентные модели. К сглаживающим моделям относятся методы скользящего среднего и экспоненциального сглаживания [1, 3-5, 13, 15, 16]. Рекуррентные можно разделить на линейные и нелинейные авторегрессионные модели. К линейным относятся модели: ARIMA, GARCH [3-5, 11, 13, 15, 16] и SSM [3, 5, 6], к нелинейным – искусственные нейронные сети (ИНС) [4, 10, 12, 15-17]. На множестве вероятностных моделей можно выделить сети Петри [8] и цепи Маркова (скрытые Марковские модели) [4, 9, 13].

Классификация типов тренда приведена на рис. 2. В рамках технического анализа выделяют два типа тренда: по направленности (восходящий и нисходящий) и по времени существования (долгосрочный, среднесрочный и краткосрочный).



Рис.1 Классификация статистических моделей контроля состояния динамических систем



Рис.2 Классификация типов тренда

Анализ существующих литературных источников показывает, при разработке математических моделей и методов решения задач прогнозирования временных рядов возникает ряд проблем:

- неопределенность входных данных (ограниченный объем выборки, наличие ошибок в данных, коррелируемость переменных состояния);
- большая размерность множества переменных состояния;
- неопределенность в выборе структуры и параметров моделей (в многомерном случае «частные» временные ряды могут быть коинтегрированными);
- неопределенность в выборе формы приведения входных данных к нормальному виду, пригодному для регрессионного анализа;
- неопределенность в выборе критериев качества моделей (обеспечение робастности, достоверности результатов моделирования: заданной точности и адекватности);
- неопределенность при отборе единственного решения многокритериальной задачи оптимизации.

Следует отметить, в работах, посвященных решению задач прогнозирования многомерных временных рядов, отсутствует оценивание информативности (значимости) переменных состояния динамических систем с учетом их

коррелируемости (коинтегрированности «частных» временных рядов) и точности измерения.

Разработанное на сегодняшний день информационное обеспечение не позволяет с достаточно высоким уровнем достоверности решать задачи прогнозирования многомерных временных рядов.

Таким образом, возникает необходимость в совершенствовании существующих и разработке новых математических моделей, методов и реализующей их средств информационной технологии прогнозирования многомерных временных рядов.

Данная работа посвящена разработке метода краткосрочного прогнозирования многомерных временных рядов с учетом коррелируемости переменных состояния динамических систем (коинтегрированности «частных» временных рядов) и точности их измерения, с целью повышения качества процесса диагностирования.

2 Постановка задачи прогнозирования многомерных временных рядов

Будем рассматривать в дальнейшем временные ряды, относящиеся к классу персистентных (с наличием долговременной памяти).

Задано $D_Q = \{q^\circ(t+l)\}$, $q^\circ(t+l) = (\Pi^\circ(t+l), U^\circ(t+l), \Phi^\circ(t+l))$,

$l = -K \dots L$, – конечное множество проектных и режимных параметров Π° , управляющих переменных U° , фазовых переменных Φ° , образующих временной ряд. Здесь t – момент прогноза, K и L – горизонты прогноза. Здесь

$D_Q \in Q$, Q – пространство временных рядов.

Необходимо получить функциональную зависимость, отражающую связь между последующими и предыдущими значениями временных рядов, удовлетворяющую системе предпочтений лица принимающего решения (ЛПР), для заданных горизонтов прогноза:

$$q^\circ(t+L) = F(q^\circ(t+L-1), \dots, q^\circ(t-K)) + \varepsilon_t^\circ \quad (1)$$

Результатом решения задачи должен являться некий математический механизм, в результате работы которого можно было бы получить любое значение векторной функции, представленной данной обучающей выборкой, по заданному вектору входных данных, в диапазоне, ограниченном горизонтами прогноза.

3 Метод прогнозирования многомерных временных рядов с использованием робастных нейросетевых моделей с задержкой во времени

Рассмотрим математическую модель управляемого процесса (ММУП). Для установления соответствия между неформально описанными свойствами выборок (Π°, U°) и формально определенными свойствами агрегированных

переменных Φ° и W° введем шкалу координации реляционных систем, которая в нашем случае может быть представлена кортежем вида:

$$\left\{ (\Pi^\circ, U^\circ), \alpha, \Phi^\circ, \beta, W^\circ, \gamma, \varphi, \omega \right\} : (\forall i = 1 \dots I, j = 1 \dots I) (\Pi^\circ, U^\circ)_i \alpha (\Pi^\circ, U^\circ)_j \Leftrightarrow$$

$\Leftrightarrow \varphi: \Phi_i^\circ \beta \Phi_j^\circ; \omega: W_i^\circ \gamma W_j^\circ$, где $(\Pi^\circ, U^\circ), \Phi^\circ, W^\circ$ – носители реляционных систем; $\Phi^\circ = \varphi(\Pi^\circ, U^\circ)$ – ММКС; $W^\circ = \omega(\Pi^\circ, U^\circ)$ – исходная математическая модель (ИММ).

Выделим подобласти монотонности отображений φ и ω по своим аргументам.

Выполним кластеризацию пространства состояний выделив характерные типы и классы, соответствующие им. Тогда для каждого взятого в отдельности состояния может быть принята гипотеза: отображение φ и ω – изоморфны.

Для каждого выделенного состояния получим регулярные оценки вида: $\forall \{(m, n), U^\circ \in (D_U)_{m, n}, \Phi^\circ \in (D_\Phi)_{m, n}\}$:

$\exists! \Pi^\circ = R(\Phi^\circ, U^\circ) \Rightarrow W^\circ = \omega[R(\Phi^\circ, U^\circ), U^\circ]$, где m – тип состояния ($m = 1 \dots M$); n – класс состояния ($n = 1 \dots N$); $\alpha, \beta, \gamma, R, \omega$ – соответствуют состоянию (m, n) ; R – регуляризирующий оператор.

Представим ММКС в виде разложения в ряд – $\Phi^\circ = \Phi_0^\circ + \left(\frac{\partial \Phi}{\partial \Pi^\circ}\right)_0 \Delta \Pi^\circ + \left(\frac{\partial \Phi}{\partial U^\circ}\right)_0 \Delta U^\circ + o\left[\|\Delta \Pi^\circ\|^2, \|\Delta U^\circ\|^2\right]$. Учитывая, что $\Pi^\circ = R(\Phi^\circ, U^\circ)$, получим: $\Delta \Pi^\circ = \Pi^\circ - \Pi_0^\circ = R(\Phi_{in}^\circ, U_0^\circ) - \Pi_0^\circ$, где $\Phi_{in}^\circ \in [\Phi_0^\circ, \Phi^\circ]$.

Таким образом, в окрестности выделенного состояния ММУП в форме ММКС и ИММ эквивалентна ММУП вида:

$$\Delta \Phi^\circ = F(\Delta \Phi^\circ, \Delta U^\circ); \quad (2)$$

$$\Delta W^\circ = \Omega(\Delta \Phi^\circ, \Delta U^\circ); \quad (3)$$

Здесь (2) – рекуррентная ММКС, (3) – диагностическая модель.

Качество ММКС существенным образом зависит от корректности приведения данных мониторинга к виду, пригодному для регрессионного анализа (нормальному виду), для конкретной объектной области.

Для того, чтобы приблизить распределение к нормальному или же сделать ряд стационарным или однородным, стабилизировать дисперсию и привести все данные к положительным значениям, проводится приведение данных мониторинга к нормальному виду. Краткий анализ достоинств и недостатков нескольких методов приведения данных к нормальному виду представлен в табл. 1 [15].

В данной работе для исключения влияния начальных значений временных рядов $q^\circ(t-K)$ и, как следствие, сокращения порядка авторегрессии при выборе структуры рекуррентной ММКС применялось приведение входных данных к нормальному виду:

$$Y_i(t+l) = \ln\left(\frac{q_i(t+l)}{q_i(t-K)}\right), \quad i = 1 \dots I, l = (-K+1) \dots L, \quad (4)$$

где I – количество рассматриваемых временных рядов (размерность вектора q°).

В настоящее время широкое распространение получили методы прогнозирования временных рядов с использованием обучаемых ИНС (см., например, [15]). Теоретически ИНС не требуют определения взаимосвязей между величинами и соблюдения предположений относительно распределения генеральной совокупности. Применение ИНС для прогнозирования многомерных ММКС особенно актуально в случае, когда «частные» временные ряды являются коинтегрированными.

При помощи нейросетевых моделей с задержкой во времени возможна аппроксимация нелинейных зависимостей между последующими значениями временных рядов от их предыдущих значений и от значений внешних факторов (например, погрешностей измерений). Схема прогнозирования многомерных временных рядов с использованием нейросетевых моделей с задержкой во времени (однонаправленной многослойной и радиально-базисной сетей с одним скрытым слоем [18-20]) представлена на рис. 3.

Таблица 1 – Краткий анализ методов приведения данных к нормальному виду

| Метод | Достоинства | Недостатки |
|----------------------------|--|---|
| Конечные разности | Уменьшение длины ряда | Усложнение статистической структуры ряда (появление корреляции между соседними членами) |
| Скользящее среднее | Выделение формы детерминированной компоненты ряда | Усложнение статистической структуры ряда (появление корреляции между соседними членами) |
| Сезонные разности | Удаление сезонной составляющей | Возможное изменение статистической структуры ряда |
| Логарифмирование | Устранение асимметрии распределения членов ряда | Неприменимо для отрицательных значений, усложнение статистической структуры ряда |
| Преобразование Бокса-Кокса | Выборочное устранение асимметрии распределения членов ряда | Неприменимо для отрицательных значений, усложнение статистической структуры ряда |

Рассмотрим структуру нейросетевых моделей с задержкой во времени. Пусть $\vec{Y}^{(k)} = [Y_1^{(k)}, \dots, Y_{H_k}^{(k)}]^T$, $k=0, 1, 2$ – вектор входных данных k -ого слоя, где H_k – число элементов в k -м слое. Количество выходов сети равно количеству рассматриваемых временных рядов – $H_2 = I$. В случае, когда порядок рекуррентных ММКС (2) с применением нейросетевых моделей с задержкой во

времени в виде (1) принят равным $AR(K)$, количество входов сети будет равно $H_0 = I \cdot K$.

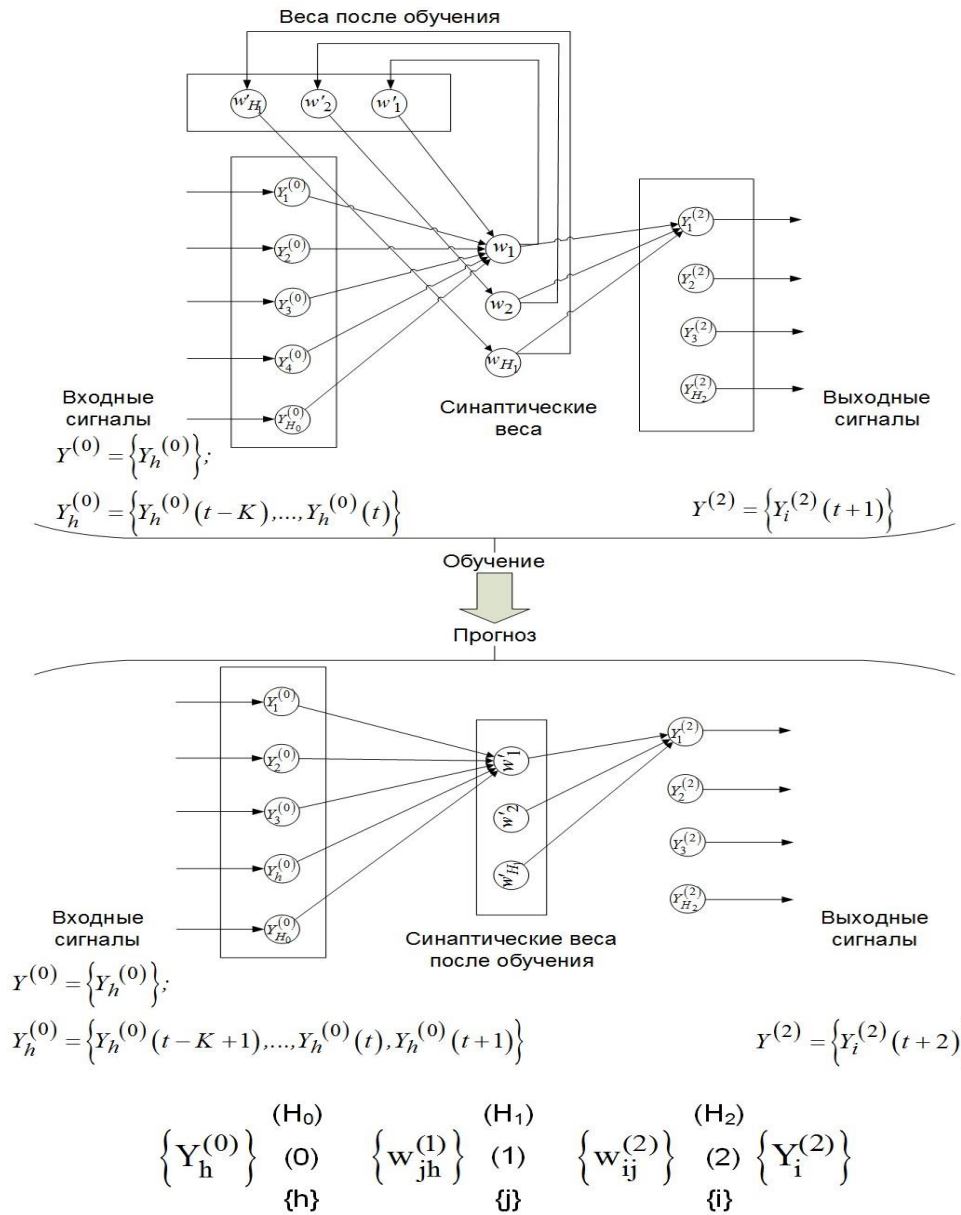


Рис.3 Схема прогнозирования многомерных временных рядов с использованием нейросетевых моделей с задержкой во времени

Аналитическое представление искомых функций для однонаправленной многослойной сети (ОМС) имеет вид:

$$Y_i^{(2)} = f\left(s_i^{(2)}\right), s_i^{(2)} = w_{i0}^{(2)} + \sum_{j=1}^{H_1} w_{ij}^{(2)} Y_j^{(1)}, i = 1 \dots H_2, j = 1 \dots H_1; \quad (5a)$$

$$Y_j^{(1)} = f\left(s_j^{(1)}\right), \quad s_j^{(1)} = w_{j0}^{(1)} + \sum_{h=1}^{H_0} w_{jh}^{(1)} Y_h^{(0)}, \quad h = 1 \dots H_0, \quad (56)$$

где $f(s) = th(\beta s) = \frac{e^{\beta s} - 1/e^{\beta s}}{e^{\beta s} + 1/e^{\beta s}}$ – выбранная передаточная функция,

$f'_s = \beta [1 - f^2(s)]$ – производная передаточной функции.

Структура простейшей радиально-базисной сети (РБС) с одним скрытым слоем аналогична представленной для ОМС (см. рис. 3).

Введем следующие обозначения:

$\vec{c}_j = [c_{j1}, c_{j2}, \dots, c_{jH_0}]^T$, $j = 1 \dots H_1$ – вектор координат центров активационной функции для нейронов скрытого слоя;

$\vec{\sigma}_j = [\sigma_{j1}, \sigma_{j2}, \dots, \sigma_{jH_0}]^T$, $j = 1 \dots H_1$ – вектор, задающий ширину окна активационной функции j -ого нейрона скрытого слоя;

$$\varphi_j(\vec{Y}^{(0)}, \vec{c}_j, \vec{\sigma}_j) = \exp\left[-\frac{1}{2} \sum_{h=1}^{H_0} Z_{jh}^2\right] \equiv \varphi_j \quad \text{– радиально-базисная активационная}$$

функция нейрона скрытого слоя, $Z_{jh} = \frac{Y_h^{(0)} - c_{jh}}{\sigma_{jh}}$, где $h = 1 \dots H_0$;

w_{ij} – вес связи между i -м нейроном выходного слоя и j -м нейроном скрытого слоя (здесь, согласно обозначениям, принятым на рис. 3, имеется в виду, что $w_{jh}^{(1)} = e_{jh} = 1$, $w_{ij}^{(2)} \equiv w_{ij}$).

Аналитическое представление искомым функций для радиально-базисной сети (РБС) имеет следующую структуру:

$$Y_i^{(2)} = s_i^{(2)}, \quad s_i^{(2)} = w_{i0}^{(2)} + \sum_{j=1}^{H_1} w_{ij}^{(2)} Y_j^{(1)}, \quad i = 1 \dots H_2, \quad j = 1 \dots H_1; \quad (6a)$$

$$Y_j^{(1)} = \phi\left(s_j^{(1)}\right), \quad s_j^{(1)} = \frac{1}{2} \sum_{h=1}^{H_0} [z_{jh}]^2, \quad h = 1 \dots H_0, \quad (66)$$

где $\phi(s) = \exp(-s)$ – выбранная активационная функция.

Синтез робастных нейросетевых моделей осуществлялся методом регуляризации [19, 20].

Таким образом, вычисление прогнозируемых значений многомерного временного ряда с использованием предложенных нейросетевых моделей с задержкой во времени может быть выполнено по формулам (5, 6).

Величины средних квадратических отклонений предыдущих $\sigma_{Y_h^{(0)}}$ (при заданной относительной точности измерения переменных $\Delta_{Y_h^{(0)}}$) и последующих

значений временного ряда $\sigma_{Y_i^{(2)}}$ для нейросетевых моделей с задержкой во времени определялись согласно методик [21, 22].

Величины относительных погрешностей оценивания прогнозируемых значений временных рядов вычислялись по формуле:

$$\delta_i^\circ = \pm \frac{\Delta_{q_i}}{q_{th,i}} = \pm (\exp(\Delta_i) - 1), \quad (7)$$

где $\Delta_i = \frac{t(P, k) \sigma_{Y_i^{(2)}}}{\sqrt{N}}$ [21], N – количество измерений этой переменной

(принималось $N=1$).

Очевидно, что предложенные рекуррентные ММКС (2) с применением нейросетевых моделей с задержкой во времени в виде (1, 5, 6) представляют собой коинтеграционные уравнения. Ранг коинтеграции (размерность пространства коинтегрированных временных рядов) $rang(Q)$ может быть определен на основе оценивания информативности переменных нейросетевых моделей [22] – путем вычисления соответствующих коэффициентов информативности (значимости вклада) предыдущих значений временных рядов в последующие:

$$\beta_{ij} = \sum_{l=-K+1}^{L-1} \beta_{ij}^{(t+l)}, \quad i, j = 1 \dots I. \quad (8)$$

4 Результаты прогнозирования и оценивания информативности переменных состояния элементов МБС с использованием ММКС разного типа

Сформирована экспериментальная выборка контролируемых переменных состояния элементов МБС. $D_Q = \{q_p^\circ(t+l)\}$, $l = -K \dots L$, $q_p^\circ(t+l) = \{q_{pi}(t+l)\}$, $i = 1 \dots I$, $p = 1 \dots P$. В рассмотренном случае мы имели: количество наблюдаемых элементов – $P = 17$, количество контролируемых информативных переменных состояния – $I = 7$, горизонты прогноза – $K = 4$ и $L = 1$. В данной работе было выполнено приведение входных данных к нормальному виду (4). Таким образом, предложенные рекуррентные ММКС (2) с применением нейросетевых моделей с задержкой во времени в виде (1, 5, 6), имели количество входов $H_0 = 21$, количество выходов $H_2 = 7$, количество нейронов в скрытом слое принималось равным количеству наблюдаемых пациентов $H_1 = P$. Результаты сравнения значений критериев качества аппроксимации с применением разных типов ММКС, и, в качестве примера, для двух переменных состояния приведены в табл. 2.

На рис. 4 представлены результаты прогнозирования временных рядов переменных состояния на шагах $L = 1, 2$. Результаты представлены для второй (рис. 4а) и седьмой (рис. 4б) переменных для выбранного элемента МБС, где 1 – экспериментальные данные, 2 – прогнозируемые значения с помощью ОМС, 3 –

с помощью РБС. Прогнозирование на шаге $L = 2$ осуществлялось при $K = 3$ и параметрах наилучших обучений ОМС и РБС на шаге $L = 1$.

Таблица 2 – Результаты оценивания качества нейросетевых моделей с задержкой во времени

| Тип ММКС | Энергия среднеквадратичной ошибки, E_{av} | Изменение E_{av} сигнала, децибел |
|---------------|---|-------------------------------------|
| ОМС [21-17-7] | 0,640 | 0,000 |
| РБС [21-17-7] | 0,001 | -28,062 |

Оценки относительных погрешностей δ_i° (7) прогнозируемых значений переменных состояния (в качестве примера, для двух – второй и седьмой) для выбранного элемента МБС при заданной относительной точности измерения непрерывных переменных – 1%, приведены в табл. 3.

В дальнейшем, на основе полученной информации: прогнозируемых значений переменных состояния с учетом оценок границ их доверительных интервалов – лечащий врач переходит к проверке гипотезы о наличии тенденции изменения во времени отклонений переменных от их допустимых значений. Если проверяемая гипотеза окажется истиной, то принимается решение о необходимости корректировки программы лечения.

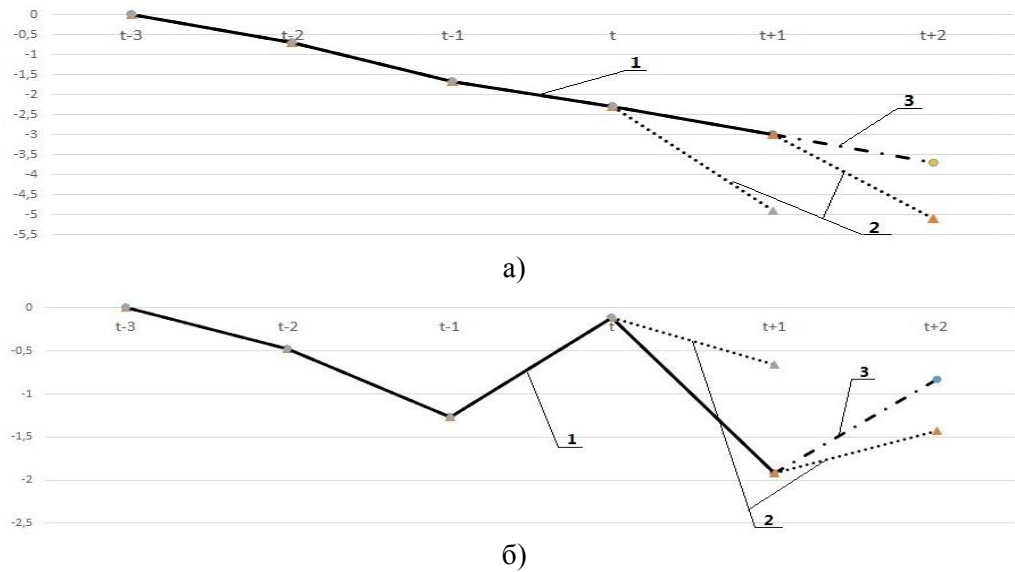


Рис.4 Результаты прогнозирования временных рядов переменных состояния МБС

Таблиця 3 – Относительные погрешности прогнозируемых значений переменных

| Переменная | ОМС | РБС |
|------------|----------------------|----------------------|
| | $\delta_i^\circ, \%$ | $\delta_i^\circ, \%$ |
| 2 | 3,40 | 0,46 |
| 7 | 0,84 | 0,32 |

С целью оценивания ранга коинтеграции $\text{rang}(Q)$ проведен анализ влияния информативности предыдущих значений временных рядов на последующие (в качестве примера, для второй и седьмой переменных – см. рис. 5) с использованием РБС ММКС (8) для выбранного элемента МБС. Выявлено, что в рассматриваемом случае $\text{rang}(Q) = 5$ при $I = 7$, т.е. $\text{rang}(Q) < I$. В частности, видно, что наибольший вклад в ошибку прогнозирования второй и седьмой переменных вносят ошибки измерения второй, четвертой и пятой переменных на предыдущих шагах контроля состояния.




Рис.5 Результаты оценки влияния информативности предыдущих значений временных рядов на последующие для выбранного элемента МБС

5 Результаты и выводы

Предложена классификация статистических моделей контроля состояния динамических систем и процессов. На основе анализа литературных данных выделено три основных типа моделей: модели стохастической фильтрации, регрессионные (структурно-параметрические модели) и вероятностные модели.

Представлен метод краткосрочного прогнозирования многомерных временных рядов, полученных на основе данных мониторинга переменных состояния динамических систем, с использованием робастных нейросетевых моделей с задержкой во времени.

Проведено сравнение качества прогнозирования с помощью предложенных моделей (в форме однонаправленной и радиально-базисной обучаемых искусственных нейронных сетей). Получены оценки доверительных интервалов для прогнозируемых значений и размерности пространства коинтегрированных временных рядов с учетом точности измерения переменных состояния. Показано, что в рассматриваемом случае ранг коинтеграции меньше размерности исходного пространства временных рядов.

ЛИТЕРАТУРА

1. Епифанов С.В. Выбор эффективных критериев тренда для применения в алгоритмах параметрической диагностики / С.В. Епифанов, Б.А. Щербань, Ю.В. Черкасов. – Авиационно-космическая техника и технология. – 2012. – № 8 (95). – С. 232-240.
2. Епифанов С.В. Прогнозирование технического состояния турбореактивного двухконтурного двигателя / С.В. Епифанов, Б.А. Щербань, Н.Д. Багаутдинов, Ю.В. Черкасов. – Авиационно-космическая техника и технология. – 2015. – № 8 (125). – С. 93-101.
3. Тарек Юсеф Баді Біштаві. Обчислювальні методи ідентифікації моделей в задачах прогнозування телетрафіку: Автореф. дис. тех. наук. – Харків: ХНУ ім. В.Н. Каразіна, 2011. – 18 с.
4. Чучуева И.А. Модель прогнозирования временных рядов по выборке максимального подобия: Автореф. дисс. канд. техн. наук. – Москва: МГУ им. Н.Э. Баумана, 2012. – 17 с.
5. Jingfei Yang M. Sc. Power System Short-term Load Forecasting // Elektrotechnik und Informationstechnik der Technischen Universitat: Thesis for Ph.d degree. – Germany, Darmstadt, 2006. – 139 p.
6. Commandeur J.J.F. Statistical Software for State Space Methods / J.J.F. Commandeur, S. J. Koopman, M. Ooms. – Journal of Statistical Software. – 2011. – Vol. 41, № 1. – 18 p.
7. Frank R.J. Time Series Prediction and Neural Networks / R.J. Frank, N. Davey, S.P. Hunt. – Journal of Intelligent and Robotic Systems, 2001. – Vol. 31, Issue 1. – P. 91-103.
8. Смирнова Е.И. Моделирование структуры состояний сложной системы для задач прогнозирования / Е.И. Смирнова. – Штучний Інтелект. – В. Новгород: ДонНТУ, ИПИИ «Наука і освіта», 2000. – 4 с. URL: <http://ea.dgtu.donetsk.ua:8080/jspui/bitstream/123456789/22945/1/МОДЕЛИРОВАНИЕ%20СТРУКТУРЫ%20СОСТОЯНИЙ%20СЛОЖНОЙ.pdf> (дата обращения: 21.10.2015).
9. Фаворская М.Н. Прогнозирование в системах распознавания образов на основе скрытых Марковских моделей / М.Н. Фаворская, Н.Д. Торгашин, А.Г. Зотин // Вестник Сибирского государственного аэрокосмического университета. – 2006. – Серия: «Математика, механика, информатика». – Выпуск 3. – С. 59-63. ISSN 1816-9724
10. Крючин О.В. Прогнозирование временных рядов с использованием нейронных сетей типа Вольтерри и сравнение показателей с многослойным персептроном / О.В. Крючин, О.В. Кондратков. – Электронный научный журнал «Исследовано в России», 2010. – Т.13. – ISSN 1819-4192. – С. 953-967.
11. Щелкалин В.Н. Математические модели и методы, основанные на совместном использовании идей методов «Гусеница»-SSA и Бокса-Дженкинса // Тр. IX междунар. конф. «Идентификация систем и задачи управления» SICPRO'12 / Харьковский национальный университет радиоэлектроники. – М., 2012. – С.728-771.

12. Дмитриев А.Н. Моделирование временных рядов заболеваемости с использованием искусственных нейронных сетей / А.Н. Дмитриев, В.В. Котин. Медицинская техника. – 2013. – № 1 (277). – С. 35-38.
13. Time Series Analysis for Business Forecasting [Электронный ресурс]. URL: <http://home.ubalt.edu/ntsbarsh/business-stat/stat-data/forecast.htm#rzchartforcat> (дата обращения: 21.10.2015).
14. Браммер К. Фильтр Калмана-Бьюси. Детерминированное наблюдение и стохастическая фильтрация. / К. Браммер, Г. Зиффлинг., Пер. с нем. – Главная редакция физико-математической литературы.– М.: «Наука», 1982. – 200 с.
15. Гуржий А.Н. Математическое обеспечение информационно-управляющих систем. Прогнозирование: учеб. пособ. / А.Н. Гуржий, В.М. Левыкин, Б.В. Шамша, Т.Б. Шатовская. – Х.: ООО «Компания СМИТ», 2013. – 372 с.
16. Тихонов Э.Е. Прогнозирование в условиях рынка: учебное пособие / Э.Е.Тихонов. – Невинномысск, 2006. – 221 с. – ISBN 5-89571-077-8.
17. Минаев Ю.Н. Методы и алгоритмы решения идентификации и прогнозирования в условиях неопределенности в нейросетевом логическом базисе / Ю.Н. Минаев, О.Ю. Филимонова, Бенамеур Лиес. – М.: Горячая линия-Телеком, 2003. – 205 с.
18. Хайкин С. Нейронные сети: полный курс. / С. Хайкин. – М.: ООО «И.Д. Вильямс», 2006. – 1104 с.
19. Стрелец В. Е. Системное совершенствование элементов сложных технических систем на основе концепции обратных задач: монография/ В. Е. Стрелец, А.А.Трончук, Е.М. Угрюмова и др.; под общ. ред. М. Л. Угрюмова. – Х.: Нац. аэрокосм. ун-т им. Н. Е. Жуковского «Харьк. авиац. ин-т», 2013. – 148 с. – ISBN 978-966-662-312-9.
20. Меняйлов Е.С. Формирование облика технических систем в условиях неопределенности входных данных на основе методов искусственного интеллекта / Е.С.Меняйлов, Е.М. Угрюмова, А.А. Трончук, С.В. Черныш // Авиационно-космическая техника и технология. – 2014. – № 7 (114). – С.169-174.
21. Румшинский Л.З. Математическая обработка результатов эксперимента / Л.З. Румшинский. – Главная редакция физико-математической литературы. – М.: «Наука», 1971. – 192 с.
22. Антонян И.М. Метод оценивания информативности переменных нейросетевых моделей систем и процессов при неопределенности данных / И.М. Антонян, В.А. Горячая, А.И. Зеленский, Е.М. Угрюмова. // Вісник Харківського національного Університету. Збірник наукових праць. – 2015, №1156 серія: «Математичне моделювання. Інформаційні технології. Автоматизовані системи управління». – Випуск 26. С. 5-16. URL: http://www.irbis-nbuv.gov.ua/cgi-bin/irbis_nbuv/cgiirbis_64.exe?C21COM=2&I21DBN=UJRN&P21DBN=UJRN&IMAGE_FILE_DOWNLOAD=1&Image_file_name=PDF/VKhIMAM_2015_1156_26_3.pdf (дата обращения: 21.10.2015).