

УДК 681.5.015:007

А.П. РОТШТЕЙН¹, Д.И. КАТЕЛЬНИКОВ²

НЕЧЁТКО – ХАОТИЧЕСКОЕ ПРОГНОЗИРОВАНИЕ ВРЕМЕННЫХ РЯДОВ

¹Иерусалимского политехнического института, Махон Лев, Израиль²Вінницький національний технічний університет,
вул.Хмельницьке шосе, 95, м.Вінниця, Україна

Анотація. У статті запропоновано метод прогнозування часових рядів на основі інтеграції нечіткої логіки і теорії хаосу. Застосування теорії хаосу дозволяє підвищити точність прогнозування за рахунок визначення оптимальної структури нейро-нечіткої моделі прогнозування.

Анотация. В статье предложен метод прогнозирования временных рядов на основе интеграции нечёткой логики и теории хаоса. Применение теории хаоса позволяет повысить точность прогнозирования за счёт определения оптимальной структуры нейро-нечёткой модели прогнозирования.

Abstract. This paper proposes a method for time series forecasting based on the integration of fuzzy logic and chaos theory. Application of chaos theory allows to improve the accuracy of forecasting by determining the optimal structure of the neuro-fuzzy model.

Ключові слова: прогнозирование временных рядов, нейро-нечёткая система вывода, теория хаоса, время задержки, размерность фазового портрета.

ВВЕДЕНИЕ

Временной ряд рассматривается здесь как последовательность наблюдений некоторой скалярной величины. Прогнозирование будущей динамики временного ряда по известной предыстории актуально во всех областях знаний: физике, медицине, экономике и др.

Создание классической теории прогнозирования временных рядов связано с именами Н. Винера, А.Н. Колмогорова, Р. Калмана [1]. Для формализации неопределенности классическая теория использует аппарат статистики и случайных процессов.

С середины 70-х годов прошлого века параллельно и независимо друг от друга развиваются два новых направления в формализации неопределенности: нечёткая логика и теория хаоса.

Нечёткая логика, основы которой заложены Л. Заде в работе [2], являются эффективным средством аппроксимации нелинейных зависимостей с помощью правил "ЕСЛИ <входы>, ТО <выход>". Для извлечения таких правил из временного ряда необходима обучающая выборка, которая связывает m предыдущих (входных) значений ряда с $(m + 1)$ -м (выходным) значением (рис.1). Популярным программным средством извлечения нечётких правил из обучающей выборки является ANFIS – адаптивная нейро-нечёткая система вывода [3], реализованная в среде MATLAB.

Следует подчеркнуть, что число входов (m) и время задержки между соседними наблюдениями (τ), как правило, задаются интуитивно. Очевидно, что от значений этих параметров (m и τ) зависит точность прогнозирования временного ряда. Однако, в рамках нечёткой логики вопрос о выборе m и τ не решается.

Возникновение теории хаоса принято связывать со статьей Лоренца [4], в которой описан так называемый странный аттрактор. Как и классическая теория нелинейных колебаний [5], теория хаоса [6] изучает поведение динамической системы с помощью фазового портрета. Однако, в теории колебаний фазовый портрет, строится на основе системы дифференциальных уравнений. В теории же хаоса изучаются объекты, для которых система уравнений не известна, и единственно доступной информацией о динамическом объекте является временной ряд. В этом случае по временному ряду может быть реконструирован фазовый портрет (аттрактор), топологические свойства которого совпадают со свойствами неизвестного нам объекта, который генерирует наблюдаемый ряд. Теоретической основой реконструкции фазовых портретов по временным рядам является специальный раздел теории хаоса,

именуемый эмбедология (embedology) [7,8].

В этой статье предлагается метод прогнозирования временных рядов на основе интеграции нечёткой логики и теории хаоса. Эффективность метода иллюстрируется компьютерными экспериментами с двумя рядами.

В разделе 2 описывается нечёткий аппроксиматор, используемый для моделирования зависимостей "входы-выход".

В разделе 3

приводятся необходимые сведения о выборе оптимальной размерности (m) и времени задержки (τ), используемые для реконструкции фазового портрета временного ряда.

В разделе 4 описываются результаты компьютерных экспериментов с двумя временными рядами, доказывающие возможность повышения точности нечёткой модели прогнозирования за счёт выбора оптимальных значений параметров m и τ .

1. НЕЧЁТКИЙ АППРОКСИМАТОР

1.1 Основные модели. Для аппроксимации нелинейной функции $y = f(x_1, x_2, \dots, x_n)$, будем использовать модель Такаги-Сугено (Takagi-Sugeno) [9], которая представляет собой нечёткие правила "ЕСЛИ-ТО" с линейной правой частью.

Правило j :

$$\begin{aligned} & \text{IF } (x_1 = A_{1j}) \dots \text{ and } (x_i = A_{ij}) \dots \text{ and } (x_n = A_{nj}), \\ & \text{THEN } y_j = \beta_{0j} + \beta_{1j}x_1 + \dots + \beta_{ij}x_i + \dots + \beta_{nj}x_n, \end{aligned} \quad (1)$$

где $j = 1, 2, \dots, r$, r - общее число правил;

A_{ij} - нечёткий терм для оценки переменной x_i в j -м правиле, $i = 1, 2, \dots, n$;

β_{0j} и β_{ij} - неизвестные параметры.

Для формализации нечётких термов A_{ij} нами используются следующие функции принадлежности:

$$\mu_{ij}(x_i) = \frac{1}{1 - \left| \frac{x_i - c_{ij}}{a_{ij}} \right|^{2b_{ij}}}, \quad (2)$$

где $\mu_{ij}(x_i)$ - степень принадлежности переменной x_i к терму A_{ij} ,

a_{ij}, b_{ij}, c_{ij} - неизвестные параметры.

Нечёткий вывод выполняется по формуле




Рис. 1. Временной ряд как система "входы-выход"

$$y = \frac{\sum_{j=1}^r w_j y_j}{\sum_{j=1}^r w_j}, \quad (3)$$

где веса правил вычисляются перемножением степеней принадлежности:

$$w_j = \prod_{i=1}^n \mu_{ij}(x_i). \quad (4)$$

Неизвестные параметры, входящие в нечёткий аппроксиматор (1)-(4), находятся методом наименьших квадратов. Необходимая при этом процедура оптимизации реализована в ANFIS [3] на основе обучающей выборки с использованием технологии нейронных сетей.

1.2 Пример. Рассмотрим нелинейную функцию

$$y = \frac{x_1 x_2 (x_1^2 - x_2^2)}{x_1^2 + x_2^2}, \quad x_1 \in [0.2, 4.0], \quad x_2 \in [-3.0, 3.0], \quad (5)$$

график которой представлен на рис. 2а.

Будем считать эту функцию генератором экспериментальных данных (обучающей выборки), из которых извлекается нечёткая модель. Нами использовалась обучающая выборка из 81 точки (x_1, x_2, y) , фрагмент которой представлен в табл. 1.

Таблица 1.

Фрагмент обучающей выборки

№	x_1	x_2	y
1	0,2	-3	0,59469
2	0,2	-2,25	0,442945
...
40	2,1	-0,75	-1,21867
41	2,1	0	0
...
80	4	2,25	4,673591
81	4	3	3,36

Нечёткая модель, полученная с помощью ANFIS и обучающей выборки, состоит из 4-х правил:

IF $x_1 = A_{11}$ and $x_2 = A_{21}$, THEN $y_1 = 1.285 x_1 - 0.5109 x_2 - 1.887$.

IF $x_1 = A_{11}$ and $x_2 = A_{22}$, THEN $y_2 = -1.285 x_1 - 0.5109 x_2 + 1.887$

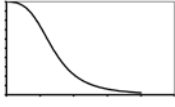
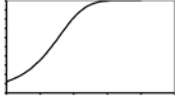
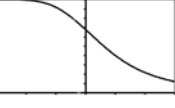
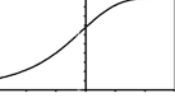
IF $x_1 = A_{12}$ and $x_2 = A_{21}$, THEN $y_3 = -3.446 x_1 - 5.11 x_2 - 9.72$.


IF $x_1 = A_{12}$ and $x_2 = A_{22}$, THEN $y_4 = 3.446 x_1 - 5.11 x_2 + 9.72$.

Настройка модели потребовала 50 итераций. Параметры функций принадлежности нечётких термов приведены в табл. 2.


Таблица 2.

Параметры функций принадлежности


Терм	График	a_{ij}	b_{ij}	c_{ij}
A_{11}		1.572	1.901	-0.1945
A_{12}		2.208	2.075	3.553
A_{21}		3.379	1.856	-2.761
A_{22}		3.379	1.856	2.761



a)



b)



c)

Рис. 2. Результаты нечёткой аппроксимации

- a) экспериментальные данные
- b) нечёткая модель
- c) модуль невязки




Рис. 3. Структура нейро-нечёткой сети

Структура нейро-нечёткой сети, которая соответствует полученным правилам, представлена на рис. 3, где

$$w_{11} = \mu_{11}(x_1) \cdot \mu_{21}(x_2), w_{12} = \mu_{11}(x_1) \cdot \mu_{22}(x_2)$$

$$w_{21} = \mu_{12}(x_1) \cdot \mu_{21}(x_2), w_{22} = \mu_{12}(x_1) \cdot \mu_{22}(x_2)$$

$$\bar{w}_{ij} = w_{ij} (w_{11} + w_{12} + w_{21} + w_{22})^{-1}, i, j = 1, 2.$$

На рис. 2b и 2c представлены графики нечёткой модели и модуля невязки, т.е. разности между модельными и экспериментальными результатами, соответственно. Из этих графиков видно, что приемлемая точность аппроксимации достигается при выборе всего двух термов для каждой переменной (x_1, x_2) . Естественно, что при увеличении числа термов точность аппроксимации будет увеличиваться.

2. ВРЕМЕННОЙ РЯД КАК ДИНАМИЧЕСКАЯ СИСТЕМА

2.1 Фазовый портрет. Предполагается, что наблюдаемый временной ряд $x(t)$ генерируется некоторой динамической системой

$$\frac{dV}{dt} = f(V), V = (v_1, v_2, \dots, v_n) \quad (6)$$

с неизвестными параметрами состояния (v_i) и размерностью (n) .

Возникает вопрос: можно ли, зная лишь $x(t)$, восстановить динамику системы (6)? Оказывается, что можно. Для этого, на основе ряда $x(t)$ реконструируется фазовый портрет, свойства которого (в том числе, размерность) совпадают со свойствами фазового портрета неизвестной системы (6). Этот замечательный факт впервые был установлен в работе [10] и математически строго доказан сначала в [7], а затем в более общем виде в [8].

Основные идеи этой теории состоят в следующем. Поскольку наблюдаемая переменная $x(t)$ зависит от n неизвестных переменных v_i , то естественно предположить, что динамика временного ряда подчиняется дифференциальному уравнению:

$$\frac{d^n x}{dt^n} = F\left(x, \frac{dx}{dt}, \frac{d^2 x}{dt^2}, \dots, \frac{d^{n-1} x}{dt^{n-1}}\right). \quad (7)$$

Входящие сюда производные интерпретируются как неизвестные параметры степенного ряда

$$x(t) = a_0 + a_1 t + a_2 t^2 + \dots,$$

в который разлагается нелинейная функция $x(t)$.

Производные из (7) можно вычислять из сигнала $x(t)$ методом конечных разностей:

$$\frac{dx}{dt} \approx \frac{x(t + \Delta t) - x(t)}{\Delta t},$$

$$\frac{d^2 x}{dt^2} \approx \frac{x(t + 2\Delta t) - 2x(t + \Delta t) + x(t)}{\Delta t^2},$$

и т.д., где Δt - квант времени для $x(t)$.

Таким образом, информация о производных содержится в векторе

$$V_i = [x(i), x(i + L), \dots, x(i + (m - 1)L)] , \quad (8)$$

где m - вложенная размерность (embedding dimension), L - временная задержка (delay time). Алгоритм реконструкции аттрактора на основе вектора (8) выглядит так:

$$V_1 = [x(t_1), x(t_1 + \tau), x(t_1 + 2\tau), \dots, x(t_1 + (m - 1)\tau)]$$

$$V_2 = [x(t_2), x(t_2 + \tau), x(t_2 + 2\tau), \dots, x(t_2 + (m - 1)\tau)]$$

...

$$V_j = [x(t_j), x(t_j + \tau), x(t_j + 2\tau), \dots, x(t_j + (m - 1)\tau)] ,$$

где $\tau = L(t_{i+1} - t_i)$, $L = 1, 2, \dots$

Этот алгоритм определяет отображение

$$V_j = M(V_{j-1}), \quad (9)$$

Согласно теореме Такенса [11], при достаточно большом m , аттрактор (9) обладает теми же свойствами, что и аттрактор оригинальной системы (6). Для практической реконструкции аттрактора по заданому временному ряду необходимо определить значения параметров m и τ .

2.2 Выбор времени задержки. При выборе времени задержки τ необходимо учитывать следующее. С одной стороны, τ должно быть достаточно большим чтобы значение $x(t)$ отличалось от значения $x(t + \tau)$. С другой стороны, если τ будет слишком большим, то в момент $t + \tau$ система утратит информацию о том, что было в момент t . С учетом этих критериев, в работе [11], предложен

метод, основанный на понятии взаимной информации между $x(t)$ и $x(t + \tau)$.

Пусть для сигнала $x(t)$ известны минимальное (\underline{x}) и максимальное (\bar{x}) значения. Разобьем интервал $[\underline{x}, \bar{x}]$ на j одинаковых по размеру подинтервалов (рекомендуется $j = 100$). Взаимная информация между значениями $x(t)$ и $x(t + \tau)$ определяется формулой

$$I(\tau) = \sum_{h=1}^j \sum_{k=1}^j P_{h,k}(\tau) \ln P_{h,k}(\tau) - 2 \sum_{h=1}^j P_h \ln P_h, \quad (10)$$

где P_h и P_k - вероятности того, что значение $x(t)$ попадет внутрь подинтервалов k и h , соответственно,

$P_{h,k}(\tau)$ - совместная вероятность того, что значение $x(t)$ находится в подинтервале h , а значение $x(t + \tau)$, - в подинтервале k .

Если $\tau \rightarrow \infty$, то значения $x(t)$ и $x(t + \tau)$ становятся независимыми, и $P_{h,k}(\tau)$ разлагается на множители $P_h \cdot P_k$. Поэтому $I(\tau \rightarrow \infty) \rightarrow 0$. Согласно [13], оптимальное время задержки соответствует первому минимуму функции $I(\tau)$.

2.3 Выбор размерности аттрактора. Оптимальной считается такая минимальная размерность аттрактора, начиная с которой фазовая траектория лишается самопересечений.

При выборе оптимальной размерности нами используется метод ложного ближайшего соседа (false nearest neighbor), предложенный в работе [12]. Этот метод основан на допущении о том, что в правильно реконструированном аттракторе соседние точки фазовой траектории остаются достаточно близкими на последующих итерациях. Если же ближайшие точки расходятся, то они называются ложными ближайшими соседями. Задача состоит в выборе такой размерности m фазового пространства, при котором доля точек, имеющих ложных соседей, сводится к минимуму.

Для вычисления доли ложных ближайших соседей используется следующий алгоритм. Пусть m -мерная точка

$$V_i^{(m)} = [x(t_i), x(t_i + \tau), \dots, x(t_i + (m-1)\tau)]$$

имеет ближайшего соседа – точку

$$V_j^{(m)} = [x(t_j), x(t_j + \tau), \dots, x(t_j + (m-1)\tau)]$$

такую, что

$$\|V_i^{(m)} - V_j^{(m)}\| < \varepsilon,$$

где $\|\dots\|$ - квадратная норма, а ε - малое число, не превосходящее стандартное отклонение данных.

Является ли точка $V_j^{(m)}$ ложным соседом точки $V_i^{(m)}$? Для ответа на этот вопрос необходимо увеличить размерность фазового пространства на единицу, т.е. $m := m + 1$, и посмотреть изменение расстояния между точками i и j :

$$R_j = \frac{\|V_i^{(m+1)} - V_j^{(m+1)}\|}{\|V_i^{(m)} - V_j^{(m)}\|} = \frac{|x(t_i + m\tau) - x(t_j + m\tau)|}{\|V_i^{(m)} - V_j^{(m)}\|}.$$

Если $R_j > R_T$, где R_T - некое пороговое значение (рекомендуется $R_T = 15$), то точка j

является ложным соседом точки i .

Условие $R_j > R_T$ проверяется для всех точек временного ряда и разных $m = 2, 3, \dots$, до тех пор, пока доля точек, для которых $R_j > R_T$, будет сведена к нулю.

3. КОМПЬЮТЕРНЫЕ ЭКСПЕРИМЕНТЫ

В этом разделе приводятся результаты экспериментов с двумя временными рядами. Первый ряд представляет собой решение системы дифференциальных уравнений, генерирующей известный в теории хаоса аттрактор Рёсслера (Rössler) [13]. Второй ряд, - это данные почасовой нагрузки в электросетях штата Техас, США. Для каждого из рядов строился фазовый портрет, из которого определялись время задержки (τ) и встроенная размерность (m). Затем эти параметры (τ, m) использовались при формировании обучающих выборок в ANFIS-моделях прогнозирования.

В программу эксперимента входило исследование качества ANFIS-модели временного ряда в зависимости от параметров (τ, m) реконструированного аттрактора, которые обычно выбираются эвристически. Для этого использовался критерий RMSD (root-mean-square deviation) – среднеквадратичное отклонение:

$$RMSD(\tau, m) = \sqrt{\frac{1}{M_t} \sum_{i=1}^{M_t} (x_i - x_i(\tau, m))^2}, \quad (11)$$

где M_t - объем тестирующей выборки; x_i - экспериментальное значение ряда в i -ой точке; $x_i(\tau, m)$ - значение ряда в i -ой точке, полученное с помощью ANFIS-модели при соответствующих значениях параметров τ и m .

3.1 Аттрактор Рёсслера. Этот аттрактор генерируется системой уравнений [13]:

$$\begin{cases} \frac{dx}{dt} = -y - z \\ \frac{dy}{dt} = x + ay \\ \frac{dz}{dt} = b + z(x - c) \end{cases},$$

где a, b, c - положительные числа, от которых зависит характер колебаний.

При $a = b = 0.2$, $c = 4.0$ получаем хаотический ряд переменной x , изображённый на рис. 4. Для генерации значений ряда использовался Chaotic Systems Toolbox из пакета MATLAB.




Рис. 4. Временной ряд Рёсслера

Зависимость взаимной информации $I(\tau)$ от времени τ представлена на рис. 5. Из графика видно, что первый минимум функции $I(\tau)$ достигается при значении $\tau = 7$, которое выбирается в

качестве оптимального времени задержки.

Зависимость доли (δ) ложных ближайших соседей от размерности (m) фазового пространства представлена на рис. 6. Из этого графика видно, что минимальное значение δ достигается при $m = 3$, что соответствует оптимальной размерности фазового пространства. Аттрактор, восстановленный по временному ряду (рис. 4), показан на рис. 7.




Рис. 5. Функция взаимной информации для ряда Рёсслера




Рис. 6. Доля ложных соседей (δ) как функция размерности (m) для ряда Рёсслера




Рис. 7. Реконструированный фазовый портрет ряда Рёсслера ($\tau = 7, m = 3$)

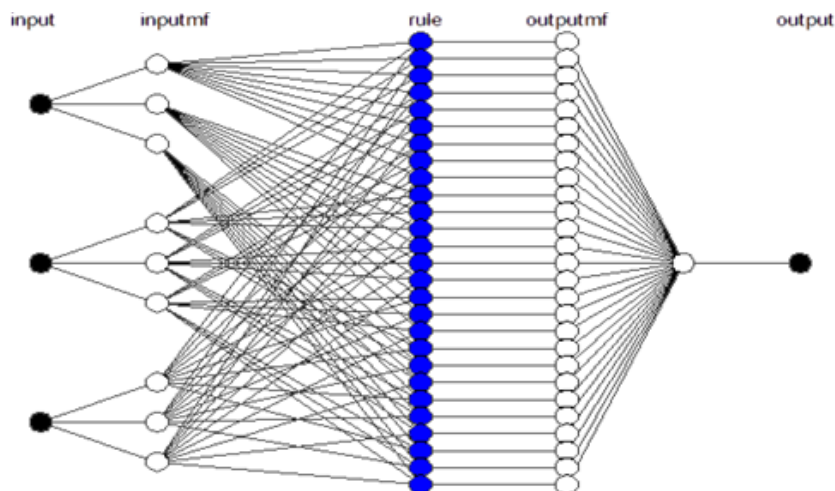


Рис. 8. Структура ANFIS-модели ряда Рёсслера

Структура ANFIS-моделі ряду Рёсслера представлена на рис. 8. Для навчання нейро-нечёткої мережі використовувалося 400 точок і 1000 ітерацій. Сопоставлення експериментальних і модельних значень ряду показано на рис. 9. Нормований модуль невязки між теорією і експериментом, обчислений за формулою

$$\tilde{\varepsilon}_i = \left| \frac{x_i(\tau, m) - x_i}{\bar{x} - \underline{x}} \right|, \quad i = 1, 2, \dots, 400,$$

представлен на рис. 10.




Рис. 9. Експериментальні (сплошна лінія) і модельні (пунктир) значення ряду Рёсслера




Рис. 10. Модуль невязки для ряду Рёсслера

В табл. 3 приведені значення RMSD -критерія (11) при різних часових затримках (τ) і різних розмірностях фазового простору (m). Из этой таблицы видно, что наименьшая ошибка моделирования достигается при $m = 3$ и $\tau = 7$, что подтверждает целесообразность интеграции нечёткой логики с теорией хаоса.

Таблиця 3.

Значення RMSD -критерія для ряду Рёсслера

m	τ		
	6	7	8
2	0,0789	0,0793	0,0888
3	0,0752	0,0711	0,0757
4	0,0747	0,0749	0,0756

3.2 Нагрузка в электросетях. На рис. 11 показан фрагмент временного ряда почасовой нагрузки (в кВт) в электросетях штата Техас, США (по данным сайта www.ercot.com за 2013 год). Рассматривалось $24 \times 365 = 8760$ значений ряда.




Рис. 11. Фрагмент ряда почасовой нагрузки в электросетях

Для применения метода взаимной информации и метода фальшивых ближайших соседей, значения ряда нормировались в интервале $[0,1]$ по формуле:

$$\tilde{x}_i = \frac{x_i - \underline{x}}{x - \underline{x}},$$

где \tilde{x}_i - нормированное значение, \underline{x} (\overline{x}) - минимальное (максимальное) значение.

Обучающая выборка (training data) представляла из себя 2628 случайно выбранных точек ряда (30% от общего количества). Из графиков на рис. 12 и 13 следует, что оптимальное время задержки (τ) и размерность фазового портрета (m) составляют $\tau = 10$ и $m = 5$. Трехмерная структура фазового портрета показана на рис. 14.




Рис. 12. Функция взаимной информации для почасовой нагрузка в электросетях




Рис. 13. Доля ложных соседей (δ) как функция размерности (m) для почасовой нагрузка в электросетях

Нейро-нечёткая сеть, построенная при оптимальных значениях m и τ , имеет 5 входов по три термина для каждого. Поскольку ANFIS предусматривает набор правил с полным перебором термов, то данная модель содержит $3 \times 3 \times 3 \times 3 \times 3 = 243$ правила. Модель обеспечивает хорошую сходимость экспериментальных и модельных данных (рис. 15 и рис. 16). Обучение сети потребовало 250 итераций. Из табл. 4 видно, что выбор оптимальных значений m и τ обеспечивает существенное повышение точности моделирования по сравнению с интуитивным выбором этих параметров.




Рис. 14. Фазовый портрет для почасовой нагрузки в электросетях ($\tau = 10, m = 5$)




Рис. 15. Экспериментальные (сплошная линия) и модельные (пунктир) значения почасовой нагрузки в электросетях




Рис. 16. Модуль невязки для почасовой нагрузки в электросетях

Таблица 4.

Значения RMSD – критерия для почасовой нагрузки в электросетях

<i>m</i>	τ		
	1	10	12
2	4108,16	780,49	2647,9
3	5764,32	674,51	2857,87
4	5249,01	696,28	2468,73
5	5196,14	586,36	3408,54

3.3 Сравнение методов прогнозирования. В Табл. 5 представлены результаты сравнения предлагаемого нами метода с наиболее популярными методами прогнозирования временных рядов: скользящего среднего (moving average), авторегрессионного интегрированного скользящего среднего (ARIMA - Autoregressive Integrated Moving Average) и экспоненциального сглаживания (exponential smoothing). Сравнение проводилось по двум критериям: RMSD, который описан выше и рассчитывается по формуле (11) и по критерию MAPE (mean absolute percent error), который рассчитывается по формуле

$$MAPE(\tau, m) = \frac{100\%}{M_t} \sum_{i=1}^{M_t} \left| \frac{x_i - x_i(\tau, m)}{x_i} \right|, \quad (12)$$

где M_t - объем тестирующей выборки; x_i - экспериментальное значение ряда в i -ой точке; $x_i(\tau, m)$ - прогнозное значение ряда в i -ой точке, полученное с помощью ANFIS-модели при соответствующих значениях параметров τ и m .

Таблица 5.

Сравнение методов прогнозирования для временного ряда почасовой нагрузки в электросетях

Метод	RMSD	MAPE
ANFIS	586.36	1.54%
Скользящего среднего	7522.10	19.80%
ARIMA	1733.46	4.56%
Экспоненциального сглаживания	3136.05	8.25%

Результат Табл.5 позволяет сделать вывод о преимуществе нечётко-хаотического метода по точности прогнозирования.

ЗАКЛЮЧЕНИЕ

В этой статье предложен метод прогнозирования временных рядов на основе интеграции нечёткой логики и теории хаоса. Суть метода состоит в обучении нейро-нечёткой сети точками - векторами фазового пространства, в котором реконструируется аттрактор динамической системы, соответствующей временному ряду. Реконструкция аттрактора осуществляется с помощью временных задержек. Описаны основные формализмы, необходимые для понимания метода. Приведены результаты компьютерных экспериментов с двумя временными рядами, иллюстрирующие возможность повышения точности моделирования за счёт выбора оптимальной размерности фазового пространства и времени задержки.

Следует заметить, что ограничением системы ANFIS является возможность работы с небольшим числом входов (не более 6-ти). Поэтому для временных рядов высокой размерности рекомендуется применение нечётких моделей с нейро-генетической настройкой [14].

СПИСОК ЛИТЕРАТУРЫ

1. Chatfield C. The Analysis of Time Series: An Introduction, Sixth Edition. CRC Press, 2009. - 352 p.
2. Zadeh L. Fuzzy sets. Information and Control-1965- 8 (3)- C.338–353.
3. Roger Jang, J.-S. ANFIS: Adaptive-network-based fuzzy inference system. IEEE Transactions on System, Man, and Cybernetics- May 1993- No. 5, Vol. 23- C. 665-685.
4. Lorenz E.N. Deterministic nonperiodic flow. Journal of Atmospheric Science-1963- vol. 20- C. 130–141.
5. Андронов А.А., Витт А.А., Хайкин С.Э. Теория колебаний. - М.:Наука.- 1981. - 918 с.
6. Малинецкий Г.Г. Хаос. Структуры. Вычислительный эксперимент. Введение в нелинейную динамику. 3-е изд. — М.: «УРСС», 2002.-256 с.

7. Takens F. Detecting strange attractor in turbulence, ed. D. A. Rand and L. S. Young, Lect. Notes Math. Berlin:Springer- 1981- 366p.
 8. Tim Sauer, James A. Yorke, and Martin Casdagli , Embedology J. Stat Phys – 1991 - Vol 65- C. 579-616.
 9. Takagi T., Sugeno M. Fuzzy identification of systems and its applications to modeling and control. IEEE Trans. System, Man and Cybernetics-1985- Vol. 15(1)- C. 116–132.
 10. Packard N. H., Crutchfield J. P., Farmer J. D., Shaw R. S. Geometry from a Time Series, Phys. Rev. Let.- 1980- 45- C.712-716.
 11. Fraser A. M., Swinney H. L. Independent coordinates for strange attractors from mutual information. Phys. Rev- Feb. 1986- A, Vol 33- C. 1134-1140.
 12. Matthew B Kennel, Reggie Brown, Henry DI Abarbanel. Determining embedding dimension for phase-space reconstruction using a geometrical construction. Phys. Rev-1992- A 45- C.3403-3411.
 13. Rössler, O. E. An Equation for Continuous Chaos, Physics Letters-1976- 57A (5)- C.397–398.
- Rotshtein, A. Rakytyanska, H. Fuzzy Evidence in Identification, Forecasting and Diagnosis, Springer, Berlin: Heidelberg, 2012.-314 p.

Надійшла до редакції 22.06.2014р.

РОТШТЕЙН А.П. – д.т.н., професор Ієрусалимського політехнічного інститута Махон Лев, Ізраїль.

КАТЕЛЬНИКОВ Д.И. – к.т.н., доцент кафедри програмного забезпечення, Вінницький національний технічний університет, г. Вінниця, Україна.