

СРАВНЕНИЕ МНОГОМОДЕЛЬНОГО И ФАЗЗИ-НЕЙРО ПОДХОДОВ К ПРОГНОЗИРОВАНИЮ СОСТОЯНИЙ НЕСТАЦИОНАРНЫХ ДИНАМИЧЕСКИХ СИСТЕМ

Введение. Прогнозирование поведения нестационарных динамических систем остается по-прежнему актуальной задачей для исследования. При этом, несмотря на большое разнообразие подходов к прогнозированию, остается открытым вопрос о выборе структуры предсказателей поведения нестационарных динамических систем. Широко известны алгоритмы Бокса-Дженкинса, Р. Брауна [2], основывающиеся на знании достаточно большого объема априорной информации о структуре динамической системы и характеристиках воздействующих на нее помех. В то же время при небольшом объеме априорной информации о системе и при наличии текущей неопределенности в ее поведении применение указанных методов проблематично для класса нестационарных динамических систем. В последнее время для целей предсказания поведения динамических систем все чаще применяются искусственные нейронные сети (ИНС), большое внимание уделяется развитию нечетких нейросетевых (гибридных) систем, позволяющих прогнозировать поведение систем, характеризующихся высоким уровнем нелинейности и “зашумленности”. Рассматривается сравнение двух подходов к задаче прогнозирования выходов нестационарных динамических систем в реальном времени в случае, когда структура и параметры модели, описывающей временной ряд, не определены.

При первом (многомодельном) подходе в соответствии прогнозируемому поведению системы предлагается ставить набор моделей различной структуры, параметры которых настраиваются адаптивно, а конечный прогноз строится в виде линейной комбинации прогнозов с учетом синергии локальных моделей.

При втором (фаззи-нейро) подходе применяется гибридная сеть типа Такаги-Сугено, которая обучается на известном множестве выходных данных, а затем используется для предсказания дальнейшего поведения системы.

1. Алгоритмы прогнозирования, основанные на одновременной настройке N APCC моделей. В [1] предлагается осуществлять прогнозирование с использованием нескольких моделей по следующей схеме:

Группа испытываемых моделей состоит из моделей типа AP, CC, APCC и более простых.

В общем случае рассматриваются модели вида:

$$A(q^{-1})y(k) = B(q^{-1})u(k) + C(q^{-1})v(k), \quad (1)$$

© А.И. Михалев, Н.В. Лысяя, 2002

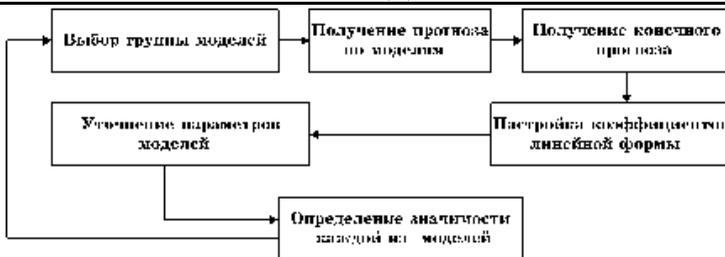


Рис. 1 – Общая схема прогнозирования с использованием множества моделей

где

$$\begin{aligned}
 A(q^{-1}) &= 1 + a_1(k)q^{-1} + \dots + a_n(k)q^{-n}, \\
 B(q^{-1}) &= b_0(k) + b_1(k)q^{-1} + \dots + b_m(k)q^{-m}, \\
 C(q^{-1}) &= 1 + c_1(k)q^{-1} + \dots + c_l(k)q^{-l}.
 \end{aligned}$$

q^{-1} — оператор сдвига назад, $\{y(k)\}$, $\{u(k)\}$, $\{v(k)\}$ – входная, выходная и "шумовая" последовательности, k — дискретное время.

Этап вычисления конечного прогноза и определения коэффициентов линейной формы представляется в виде схемы:



Рис. 2 – Схема этапа вычисления конечного прогноза

Для настройки параметров моделей и коэффициентов линейной формы в [1] используется алгоритм Качмажа.

2. Идентификация системы N синергированными моделями.

Алгоритм многомодельного прогноза с использованием схемы, представленной на рис. 1 в [3, 4], дополняется адаптивными моделями, настраиваемыми по принципу синергии. Такой алгоритм идентификации нестационарных динамических систем обладает более высокими по сравнению с известными и ранее уже рассмотренными алгоритмами скоростными характеристиками и помехоустойчивостью. В качестве адаптивных моделей используются N моделей, работающих по методу экспоненциального сглаживания [2]:

$$\hat{y}_i(k) = \alpha_i y(k) + (1 - \alpha_i) \hat{y}_i(k - 1), \tag{2}$$

где α_i — параметры сглаживания, настраиваемые синергийно.

Начальные значения настраиваемых коэффициентов выбираются в соответствии с имеющейся априорной информацией об ограничениях параметров идентифицируемого объекта.

Критериями процесса настройки моделей выступают четные функции ошибок $e_i(k) = y(k) - \hat{y}(k)$:

$$F_i(k) = -\gamma e_i^2(k) \text{ или } \hat{F}_i(k) = e^{F_i(k)} \quad (3)$$

где $y(k)$ — наблюдаемая выходная координата идентифицируемого объекта, γ — весовой коэффициент.

Рабочие шаги при поиске экстремумов функций $F_i(k)$ вычисляют в соответствии с комбинированным алгоритмом одновременной настройки N адаптивных моделей, включающим в себя поисковую и синергичную компоненты. При этом поисковая компонента алгоритма предназначена для организации автоматического вычисления рабочего шага в процессе адаптивной настройки моделей, синергичная компонента алгоритма реализует игровой подход к выбору наилучшего рабочего шага из совокупности вычисленных для каждой из N моделей при одновременной настройке всех коэффициентов $\alpha_i (i = \overline{1, N})$. Отсюда следует, что если наилучшей моделью в момент k оказалась, например, модель с индексом $i = p$, то в соответствии с синергичной стратегией в этот момент произойдет переключение всех моделей на модель с индексом p :

$$\alpha_i = \alpha_p, \quad \hat{y}_i(k-1) = \hat{y}_p(k-1), \quad i = \overline{i, N_i} \quad (4)$$

Таким образом, в алгоритме синергичной настройки реализованы, с одной стороны, возможности независимого поиска, который может совершать каждая из N моделей в процессе настройки коэффициентов, а с другой - возможности эффективного взаимодействия всех N моделей. Все это обеспечивает достаточно высокую скорость настройки коэффициентов и тем самым позволяет прогнозировать выходы существенно нестационарных динамических систем в условиях скачков входных сигналов.

3. Стратегия настройки коэффициентов линейной формы.
Представим конечный прогноз в виде линейной формы:

$$\hat{y}'(k) = \sum_{i=1}^m c_i(k) \hat{y}_i(k), \quad (5)$$

где $\hat{y}'(k)$ — значение прогноза по i -той модели на k -м шаге,
 c_i — коэффициент при прогнозе по i -той модели.

Это выражение можно представить в векторном виде:

$$\hat{y}'(k) = C^T(k)Y(k),$$

где $\hat{y}(k) = (\hat{y}_1(k), \hat{y}_2(k), \dots, \hat{y}_m(k))^T$ - $m \times 1$ вектор прогнозов, $C(k) = (c_1(k), c_2(k), \dots, c_m(k))^T$ - $m \times 1$ вектор коэффициентов линейной формы.

Для получения процедуры расчета значений коэффициентов линейной формы используем модель (5) и ограничения на несмещенность прогнозов в виде:

$$C^T I = 1, \tag{6}$$

где $I - m \times 1$ вектор, состоящий из единиц.

Коэффициенты линейной формы определяются для каждой модели в отдельности на каждом шаге прогноза в соответствии с условиями (5) и (6). При этом модель с минимальной ошибкой прогноза на предыдущем шаге будет иметь максимальный коэффициент веса и наоборот.

Коэффициенты участия каждой из моделей в линейной форме предлагается определять в виде:

$$C_i(k) = k_1 + k_2 \times e_i^{-|e_i/\max|} \tag{7}$$

где k_1 – коэффициент, задаваемый произвольно, например, $k_1 = 0.1$, k_2 – коэффициент учитывающий несмещенность прогноза, вычисляется по формуле

$$k_2 = \frac{1 - m \times k_1}{\sum_{i=1}^m e_i^{-|e_i/\max|}}, \tag{8}$$

\max – максимальная ошибка прогноза по моделям на предыдущем шаге, e_i – ошибка прогноза на предыдущем шаге.

4. Идентификация систем с помощью нечеткой нейросетевой модели. Для моделирования поведения динамических систем используется фаззи-нейро сеть на основе механизма нечеткого вывода Такаги-Сугено с x_{N_i} входами, N_R правилами и одним выходом.

Здесь x_1, x_2 – входы сети, $\mu_{11} - \mu_{22}$ функции принадлежности входов, Π – блоки вычисления степеней срабатывания правил (произведений значений функций принадлежности, входящих в правило), w_1, w_2 – степени срабатывания правил, f_1, f_2 – линейные модели, описывающие зависимость выхода сети от входов для каждого правила (консеквенты правил), \hat{y} – выход сети.

В 1-м слое сети выполняется фаззификация входов (вычисляются значения функций принадлежности); во 2-м слое вычисляются степени выполнения правил; в 3-м слое выполняется нормализация степеней выполнения правил; в 4-м слое вычисляются значения консеквентов и значения выходов правил; в 5-м слое выполняется дефаззификация (суммирование значений выходов правил) и вычисляется значение выхода сети.

Сеть реализует правила вида:

$$\text{If } x_1 \text{ is } A_1 \text{ and } \dots \text{ and } x_{N_i} \text{ is } A_{N_i} \text{ then } y = f_i,$$

где x_i -й вход, A_i - лингвистическое значение i -го входа, f_i – линейная модель в консеквенте i -го правила, $i = 1, \dots, N_i$, N_i – количество входов.

В качестве функций принадлежности входных переменных используется функция Гаусса:

$$\mu_i = \exp\left(-\frac{(x_i - c_i)^2}{2\sigma_i^2}\right), \quad (9)$$

где x_i – вектор входов, c_i , σ_i – центр и ширина функции принадлежности входов.

5. Алгоритмы обучения сети. Настройку параметров сети предлагается осуществлять с помощью алгоритма Марквардта, который обладает более высокой степенью сходимости, чем широко используемый метод обратного распространения ошибки. При этом параметры функций принадлежности входных переменных (антецедентов) настраиваются по алгоритму:

$$\begin{cases} \Omega(k) = \Omega(k-1) + q^{-1}(k)J(k)e_i(k), \\ q(k) = \alpha q(k-1) + \|J(k)\|^2, 0 \leq \alpha \leq 1. \end{cases} \quad (10)$$

где $\Omega(k)$ – вектор параметров функций принадлежности входов, $J(k)$ – вектор, содержащий градиенты сети по настраиваемым параметрам антецедентов всех правил в момент времени k , $e_i(k) = y(k) - \hat{y}(k)$ – ошибка идентификации на итерации k . Параметры консеквентов настраиваются по аналогичной процедуре:

$$\begin{cases} \Theta(k) = \Theta(k-1) + r^{-1}(k)e_i(k)\Phi(k), \\ r(k) = \beta r(k-1) + \|\Phi(k)\|^2, 0 \leq \beta \leq 1. \end{cases} \quad (11)$$

где $\Theta(k)$ – вектор настраиваемых параметров консеквентов, $\Phi(k) = (\bar{w}_1(x(k))\tilde{x}(k), \dots, \bar{w}_R(x(k))\tilde{x}(k))^T$ – дополнительный вектор входов, $\tilde{x} = (x^T, 1)^T$ – расширенный вектор входов.

6. Тестирование алгоритмов. Описанные методы применялись для прогнозирования относительных изменений котировки фьючерса на евродоллар. В качестве входов использовались следующие значения: $y(k)$ – значения дневных доходностей;

$y_{ср\text{ед}}(k)$ – значения дневных доходностей, усредненные за последние 3 дня.

Использование усредненных значений было необходимо в связи с высокой шумовой компонентой в данных. Выходом является прогноз сглаженного 3-дневного среднего на один день в будущее.

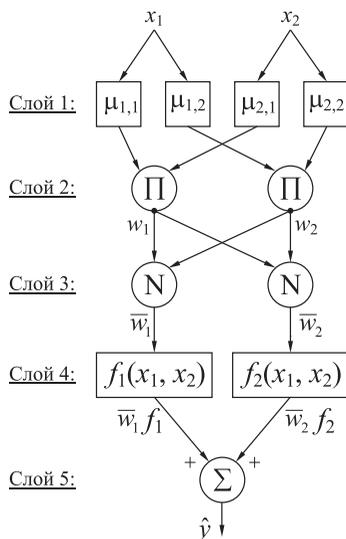


Рис. 3 – Система нечеткого вывода Такаги-Сугено в виде пятислойной нечеткой нейросети с 2 входами, 2 правилами и 1 выходом

Для прогнозирования с использованием многомоделльного подхода использовалось шесть моделей:

$M1(AP(2)):$

$$y_{1\text{сред}}(k) = a_{11}y(k-1) + a_{12}y_{\text{сред}}(k-1)$$

$M2(CC(2)):$

$$y_{2\text{сред}}(k) = a_{21}(y(k-1) + v) + a_{22}(y_{\text{сред}}(k-1) + v)$$

где v – нормально распределенная случайная величина, зависящая от значений временного ряда.

$M3(APCC(3, 1)):$

$$y_{3\text{сред}}(k) = a_{31}(y(k-1) + v) + a_{32}y_{\text{сред}}(k-1) + a_{33}y_{\text{сред}}(k-2) + a_{34}y_{\text{сред}}(k-3)$$

$M4(AP(3)):$

$$y_{4\text{сред}}(k) = a_{41}y(k-1) + a_{42}y_{\text{сред}}(k-1) + a_{43}y_{\text{сред}}(k-2)$$

$M5$ и $M6$ (модели экспоненциального сглаживания, настраивающиеся синергично):

$$y_{5\text{сред}}(k) = \alpha_1 y_{\text{сред}}(k) + (1 - \alpha_1)y_5(k-1)$$

$$y_{6\text{сред}}(k) = \alpha_2 y_{\text{сред}}(k) + (1 - \alpha_2)y_6(k-1)$$

Прогнозирование по моделям 1 - 4 ведется с использованием алгоритма Качмажа с учетом ограничений на несмещенность прогнозов, прогноз по синергичным моделям 5-6 строится следующим образом:

а) из прогнозного значения каждой модели делается случайный разброс возможных направлений будущего члена ряда;

б) определяется среднее значение углов наклона прямых, лежащих выше и ниже прогнозов, выдаваемых каждой моделью;

в) среднее арифметическое этих углов будет определять направление, на котором находится прогнозируемый член временного ряда.

Начальные значения коэффициентов линейной формы принимаются равными 0.2. Настройка коэффициентов линейной формы проводится по формуле (8).

Для прогнозирования с использованием системы нечеткого вывода использовалась фаззи-нейро сеть с 2 входами, 1 выходом, 3 функциями принадлежности на каждый вход и 9 правилами. На один из входов подавались значения дневных доходностей, нормированные следующим образом [6]: $x_i^{\text{norm}} = (x_i - \bar{x}) / \sigma_x$, где \bar{x} – математическое ожидание, σ_x – дисперсия ряда. На другой вход подавались нормированные значения дневных доходностей, усредненные за последние 3 дня.

Сеть обучалась с использованием алгоритма Марквардта для настройки параметров antecedентов и консеквентов. В качестве функций принадлежности входов была выбрана функция Гаусса со следующими исходными параметрами: ширина функции принадлежности 0.225, интервалы входов от -1.5 до 1.5, $\alpha = 0.999$, $\beta = 0.999$, $q(0) = 1$, $r(0) = 1$. Параметры консеквентов инициализировались нулевыми значениями.

Оценки результатов прогнозирования приведены в табл. и . Данные получены в результате одношагового прогноза, проведенного в течение 100 дней

Табл. 1 – Оценки качества предсказания. Количество данных в обучающей выборке=500

	M_1	M_2	M_3	M_4	M_5 и M_6	Лин.форма	Фаззи-нейро
arv^*	0.048	0.335	0.166	0.032	0.091	0.035	0.0107
% сов-падения знака	64	55	58	66	76	62	72

Табл. 2 – Оценки качества предсказания. Количество данных в обучающей выборке=300.

	M_1	M_2	M_3	M_4	M_5 и M_6	Лин.форма	Фаззи-нейро
arv^*	0.048	0.335	0.166	0.032	0.091	0.005	0.017
% сов-падения знака	66	55	60	71	69	64	71

*- нормированная среднеквадратичная ошибка [6], определяется выражением:

$$arv = \frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} .$$

Для сравнения методов приведены графики:

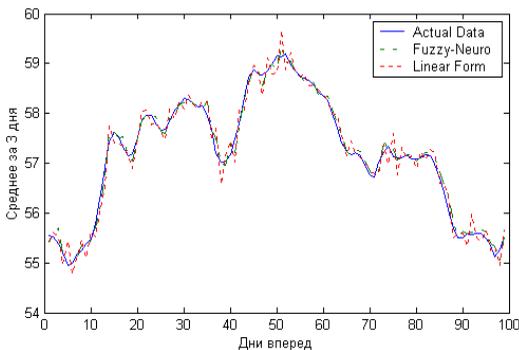


Рис. 4 – Прогнозирование фьючерса на евродоллар на 100 дней вперед, количество обучающих данных=500

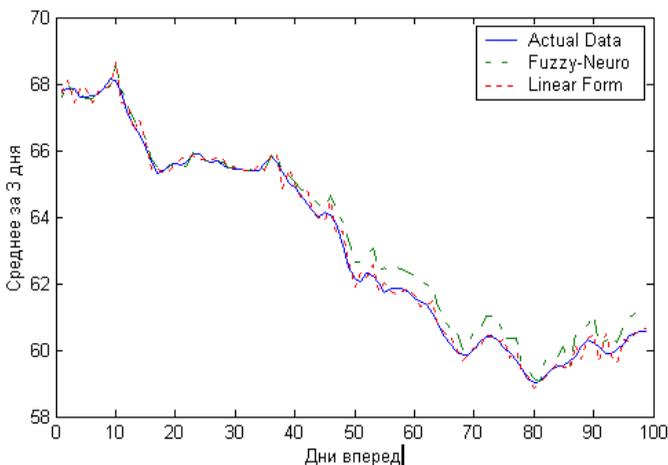


Рис. 5 – Прогнозирование фьючерса на евродоллар на 100 дней вперед, для обучения использовались 300 предыдущих значений ряда

Заключение. При сравнении многомодельного и фаззи-нейро подходов к рассмотрению задач прогнозирования нестационарных дискретных последовательностей в реальном времени выявилось, что: коэффициенты моделей, входящих в линейную форму, не зависят от количества

данных в обучающей выборке, поэтому многомодельный подход лучше использовать при небольшом количестве обучающих данных. Если же количество данных в обучающей выборке 500, лучше прогнозировать ряд с помощью нечеткой сети, которая, хотя и требует некоторых затрат времени на обучение, показывает тем лучшее качество предсказания, чем больше размер обучающей выборки.

Для иллюстрации предлагаемых методов приведены примеры прогнозирования относительных изменений котировки фьючерса на евро-доллар в течение 100 дней по многомодельному подходу и с использованием фаззи-нейро сети.

Литература

1. Бодянский Е.В., Воробьев С.А. Об одном подходе к адаптивному прогнозированию временных рядов. - Харьков, 1994. - 17 с. - Деп. в ГНТБ Украины 03.06.94, N 1067 - Уж94.
2. Лукашин Ю.П. Адаптивные методы краткосрочного прогнозирования. - М.:Статистика, 1979. - 254 с.
3. Михалев А.И. Алгоритм поисковой идентификации с синергизованными моделями существенно нестационарных динамических систем.//Респ. межвед. науч.-техн. сб. - 1992. - Вып.20. - с. 35-40.
4. Михалев А.И., Власова Н.В. Синергизованная стратегия настройки в прогнозирующих системах.//Тез. докл. 2-ой Укр. конф. по автомат. управл. (Автоматика-95), 24-30 сент. 1995 г. - Львов. - т.3, - с.36.
5. Бодянский Е.В., Колодяжный В.В. Об одном алгоритме обучения фаззи-нейро-предиктора, АСАУ, Днепропетровск: Системные технологии, 2000. Вып.3. - с.29-36.
6. Tomasz J. Cholewo, Jacek M. Zurada. Sequential Network Construction for Time Series Prediction // in Proceedings of the IEEE International Joint Conference of Neural Networks, p. 2034-2039, Houston, Texas, USA, June 9-12, 1997.
7. Tanaka K., Wang H.O. “Fuzzy Control Systems Design and Analysis: A Linear Matrix Inequality Approach”, New York: John Wiley & Sons, Inc., 2001. – 306 p.

Получено: 07.12.2002