

УДК 004.67

Е.В. Мантула, Е.С. Сакало

Харьковский национальный университет радиоэлектроники, Харьков

ПРОГНОЗИРУЮЩИЕ МГУА-ПОЛИНОМИАЛЬНЫЕ МОДЕЛИ В ЗАДАЧАХ ЭКОЛОГИЧЕСКОГО МОНИТОРИНГА

В статье проведен анализ использования в задачах экологического мониторинга традиционных нейронных сетей с фиксированной архитектурой и МГУА-сетей (метод группового учета аргументов), которые имеют переменную структуру с возможностью изменения во время обучения, что позволяет обеспечить высокую точность аппроксимации в условиях достаточно короткой выборки.

Ключевые слова: прогнозирование, нейронная сеть, нейросетевая NARX – модель, МГУА-нейронная сеть, синаптические веса.

Введение

Задача прогнозирования временных рядов произвольной природы часто встречается во множестве промышленных, финансово-экономических, медико-биологических и других приложений, т.е. там, где особенно важно знать поведение исследуемой системы в будущие моменты времени. Арсенал используемых здесь методов также практически необозрим: от простейших интуитивных и статистических методов до искусственных нейронных сетей, включающих в себя как громоздкие универсальные нейропредикторы [1] на основе, так называемых, NARMAX – MIMO – моделей, так и упрощенные архитектуры на основе ANARX- и SANARX – моделей [2, 3].

Процесс прогнозирования постоянно присутствует и в задачах экологического мониторинга [4], причем одной из наиболее характерных здесь задач является прогнозирование уровня загрязнения воздуха, описываемого целым рядом таких показателей, как концентрации взвешенных частиц PM10 и PM2,5, содержание SO₂, NH₃, O₃, CO и тому подобных вредных примесей.

Таким образом, предметом данного анализа и предсказания является многомерная стохастическая или хаотическая последовательность

$$y(k) = (y_1(k), \dots, y_i(k), \dots, y_n(k))^T,$$

где $y_i(k)$ – значение i -го контролируемого показателя в момент контроля $k = 1, 2, \dots$

При этом значение каждого из показателей $y_i(k)$ в значительной мере определяется не только самим источником загрязнения, но и текущими метеорологическими условиями такими, как скорость и направление ветра, уровень осадков, атмосферное давление, влажность, температура воздуха и множество других факторов, также формирующих многомерную последовательность

$$x(k) = (x_1(k), \dots, x_p(k), \dots, x_q(k))^T.$$

Таким образом, задача прогнозирования сводится к построению многомерной нелинейной математической модели

$$\hat{y}(k) = f(x(k)),$$

связывающей с помощью некоторого априори неизвестного нелинейного преобразования $f(\circ)$ экзогенный многомерный ряд $x(k)$ с оценкой $\hat{y}(k)$ контролируемого текущего вектора параметров загрязнения воздуха $y(k)$.

Основная часть

1. Прогнозирующая нейронная сеть

В принципе, задача синтеза многомерной (MIMO) модели достаточно эффективно может быть решена с помощью таких традиционных нейронных сетей, как многослойный персептрон (MLP) или радиально-базисная нейронная сеть (RBFN) [5]. Здесь, однако, возникает целый ряд существенных проблем, связанных с характером обрабатываемых данных. Дело в том, что временные ряды, характеризующие загрязнение воздуха, как правило, существенно нестационарны, содержат нелинейные нерегулярные тренды, резкие скачки и выбросы.

Поэтому данных, характеризующих стационарные участки, просто недостаточно, чтобы обучить достаточно большой набор синаптических весов многослойного персептрона или радиально-базисной сети.

Сократить количество настраиваемых синаптических весов можно, используя метод группового учета аргументов (МГУА), предложенный А.Г. Ивахненко [6, 7] и положенный в основу, так называемой МГУА-нейроной сети (GMDH-NN) [8].

На рис. 1 приведен пример МГУА-нейронной сети с четырьмя входами, одним выходом и нейронами N-A, являющимися по сути нелинейными адальфинами (N-Adaline).

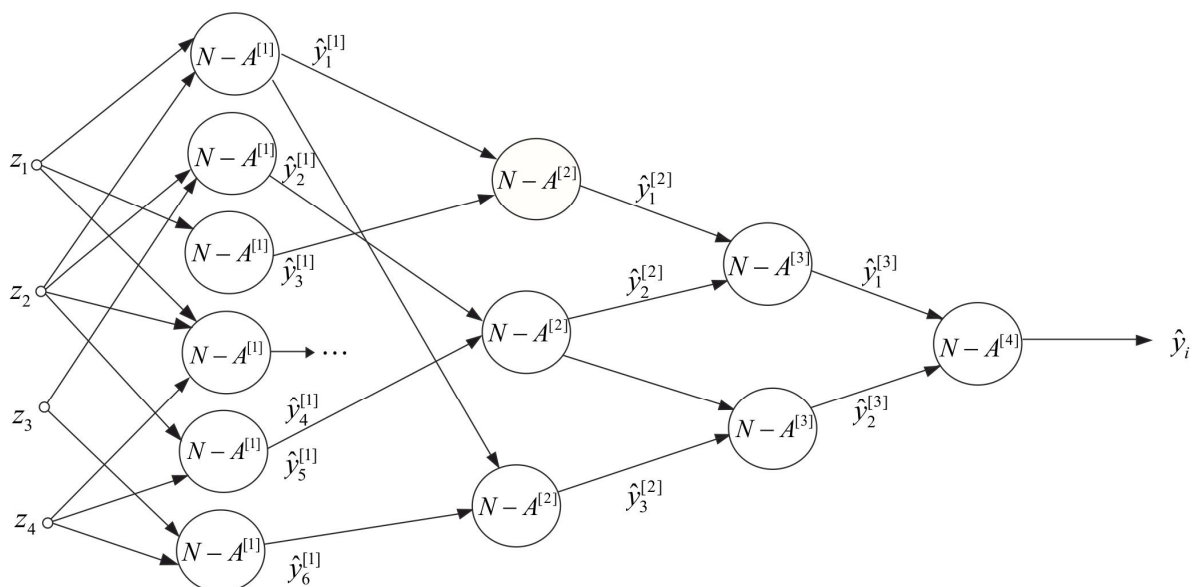


Рис. 1. МГУА-нейронная сеть

В отличие от традиционных нейронных сетей с фиксированной архитектурой МГУА-сеть имеет переменную структуру, которая может изменяться в процессе обучения.

Каждый нейрон сети – N-адалина представляет собой адаптивный линейный ассоциатор с двумя входами и нелинейным препроцессором, образованным тремя блоками умножения, и вычисляет квадратичную комбинацию входов вида

$$\hat{y}_{gh} = f_{gh}(z_g, z_h) = w_{gh0} + w_{gh1}z_g + w_{gh2}z_g^2 + w_{gh3}z_gz_h + w_{gh4}z_h^2 + w_{gh5}z_h = w_{gh}^T z_{gh},$$

где $w_{gh} = (w_{gh0}, w_{gh1}, w_{gh2}, w_{gh3}, w_{gh4}, w_{gh5})^T$,

$$z_{gh} = (1, z_g, z_g^2, z_gz_h, z_h^2, z_h)^T.$$

Процесс обучения МГУА-нейронной сети состоит в ее конфигурировании, начиная с первого скрытого слоя, независимой настройке синаптических весов каждой нелинейной адалины и наращивании количества слоев для достижения необходимой точности прогнозирования.

Количество нейронов первого скрытого слоя сети определяется размерностью входного вектора n и не превышает значение $n(n-1)/2$ – количества сочетаний из n по 2.

Так, для i -го контролируемого показателя $y_i(k)$, чья прогнозирующая модель имеет вид:

$$\hat{y}_i(k) = f_i(y_i(k-1), \dots, y_i(k-n_{A,i}), x_1(k-1), \dots, x_1(k-n_{B,1}), x_2(k-1), \dots, x_2(k-n_{B,2}), \dots, x_p(k-1), \dots, x_q(k-n_{B,q})),$$

где $n_{A,i}$, $n_{B,q}$ – порядки авторегрессии и запазды-

вания экзогенных переменных, соответственно), или, что тоже самое:

$$\hat{y}_i(k) = f_i(z_1(k), \dots, z_{n_{A,i}}(k), z_{n_{A,i}+1}(k), \dots, z_{n_{A,i}+n_{B,i}}(k), \dots, z_{n_{A,i}+n_{B,i}+\dots+n_{B,q}}(k)).$$

Количество нейронов первого скрытого слоя определяется значением $c_{n_{A,i}+n_{B,1}+\dots+n_{B,q}}^2$.

Поскольку это число может быть достаточно велико, для обучения обычных нейронных сетей может потребоваться слишком большая по объему обучающая выборка, в то время как в МГУА-нейронной сети одновременно и независимо настраиваются наборы из шести синаптических весов.

2. Обучение нейронной сети

Каждый из нейронов первого скрытого слоя настраивается с помощью любого из линейных алгоритмов обучения [5] или идентификации [9], однако, в нестационарных условиях целесообразно воспользоваться методом наименьших квадратов на скользящем окне из s наблюдений, имеющим вид

$$w_{gh}(k) = \left(\sum_{\chi=k-s+1}^k z_{gh}(\chi)z_{gh}^T(\chi) \right)^{-1} \times \sum_{\chi=k-s+1}^k z_{gh}(\chi)y_i(\chi).$$

При этом на каждом такте обучения необходимо обращать (6×6) – матрицу, что очень просто с вычислительной точки зрения.

После предъявления нейронам первого слоя всей обучающей выборки оценивается точность,

наприклад, с помощью дисперсии ошибки предсказания, каждого нейрона

$$\hat{y}_1^{[1]}, \hat{y}_2^{[1]}, \dots, \hat{y}_{c_{n_A, i+n_B, j^+ \dots + n_B, q}}^{[1]}$$

и формируется группа из нейронов, дающих ошибку ниже некоторого априорно заданного порога. Именно выходы этой группы $\hat{y}_1^{[1]}$ являются входами второго скрытого слоя.

Далее с помощью того же обучающего сигнала $y_i(k)$ настраиваются нейроны второго слоя при “замороженных” синаптических весах первого и опять формируется группа, характеризующаяся наилучшей точностью.

Процесс наращивания слоев и настройки синаптических весов продолжается до достижения хотя бы одним нейроном очередного слоя требуемой точности.

Наилучший же нейрон последнего слоя полагается выходным нейроном сети в целом.

МГУА-нейронная сеть обеспечивает высокую точность аппроксимации в условиях достаточно короткой обучающей выборки, при этом интересно заметить, что три слоя такой сети обеспечивают «подгонку» данных с помощью полиномов шестой степени, а именно такие аппроксимирующие полиномы используются в реальной системе прогнозирования качества воздуха (US National Air Quality Forecasting System) [10], эксплуатирующейся в настоящее время в США.

Заключение

Рассмотрена задача нелинейного текущего прогнозирования показателей уровня загрязнения воздуха на основе нейросетевой NARX – модели.

Показано, что в условиях дефицита и нестационарности исходной информации целесообразно

использование многослойных МГУА-нейронных сетей, обеспечивающих высокое качество аппроксимации и экстраполяции и характеризующихся простотой численной реализации.

Список литературы

1. Mandic D.P. *Recurrent neural networks for prediction*. / D.P. Mandic, J.A. Chambers. – Chichester: John Wiley & Sons, Ltd., 2001. – 285 p.
2. Chowdhury F.N. *Input-output modeling of nonlinear systems with time-varying linear models*. / F.N. Chowdhury // *IEEE Trans. on Automatic Control*. 2000. – Vol. 7. – P. 1355-1358.
3. Vassiljeva K. *State-space control on nonlinear systems identified by ANARX and neural network based SANARX models* / K. Vassiljeva, E. Petrenkov, J. Belikov // *Proc. WCCI 2010 IEEE World Congress on Computational Intelligence*. – Barcelona, Spain, 2010. – P. 2816-3823.
4. Zanetti P. *Air Pollution Modeling*. / P. Zanetti – N.-Y.: Van Nostrand Reinhold, 1990. – 302 p.
5. Haykin S. *Neural networks: a comprehensive foundation*. / S. Haykin – Upper Saddle River, N. J.: Prentice-Hall, Inc., 1999. – 842 p.
6. Ивахненко А.Г. *Системы эвристической самоорганизации в технической кибернетике*. / А.Г. Ивахненко – К.: Техника, 1971. – 372 с.
7. Ивахненко А.Г. *Помехоустойчивость моделирования*. / А.Г. Ивахненко, В.С. Степанко – К.: Наук. Думка, 1985. – 216 с.
8. Pham D.T. *Neural Networks for Identification, Prediction and Control*. / D.T. Pham, X. Liu – London: Springer – Verlag, 1995. – 238 p.
9. Льюнг Л. *Идентификация Систем. Теория для пользователя*. / Л. Льюнг – М.: Наука, 1991. – 432 с.
10. Pouliot G. *Emission processing for an air quality forecasting model* / G. Pouliot, T. Pierce. – *Proc. 12th Int. Conf. on Emission Inventories, San Diego, CA, 2003*. – P. 1-9.

Поступила в редколлегию 19.03.2013

Рецензент: д-р. техн. наук, проф. Е.В. Бодянский, Харьковский национальный университет радиоэлектроники, Харьков.

ПРОГНОЗОВАНІ МГОА-ПОЛІНОМІАЛЬНІ МОДЕЛІ В ЗАДАЧАХ ЕКОЛОГІЧНОГО МОНІТОРІНГУ

О.В. Мантула, Є.С. Сакало

У статті наведено аналіз використання у задачах екологічного моніторингу традиційних нейронних мереж з фіксованою архітектурою та МГОА-мереж (метод групового обліку аргументів), які мають змінну структуру з можливістю змінювання під час навчання, що дозволяє забезпечити високу точність апроксимації в умовах досить короткої вибірки.

Ключові слова: прогнозування, нейронна мережа, нейромережева NARX – модель, МГОА-нейронна мережа, синаптичні ваги.

GMDH-POLYNOMIAL PREDECTIVE MODELS IN ENVIROMENTAL MONITORING

O.V. Mantula, I.S. Sakalo

In article GMDH - neural networks for solving nonlinear current prediction indicators of air pollution, which are characterized by simplicity of numerical implementation and provide a high accuracy of the approximation in relatively short training set are considered.

Keywords: prediction, neural network, neural network NARX – model, GMDH-neural network, synaptic weights.