

# ПРОГНОЗИРОВАНИЕ ДИНАМИКИ ВРЕМЕННОГО РЯДА АТМОСФЕРНЫХ ТЕМПЕРАТУР НА ОСНОВЕ ИЕРАРХИЧЕСКИХ МНОГОСЛОЙНЫХ НЕЙРОННЫХ СЕТЕЙ

Е. А. Сирота, М. Г. Матвеев

*Воронежский государственный университет*

Поступила в редакцию 16.10.2015 г.

**Аннотация.** В настоящей работе проведен анализ возможности применения методики построения иерархической нейронной сети для прогнозирования динамики процессов изменения атмосферной температуры, а также сравнение полученных результатов с ранее полученными прогностическими моделями.

**Ключевые слова:** иерархическая нейронная сеть, нестационарная временная последовательность, прогнозирование, точность прогноза, векторная авторегрессия, нестационарный метеорологический процесс.

**Annotation.** In the present work analyzed the possibility of using the technique of hierarchical neural network to predict the dynamics of the processes of change in atmospheric temperature, and comparing the results with previously obtained predictive models.

**Keywords:** hierarchical neural network, non-stationary time sequence, forecasting, forecast accuracy, vector autoregressive, non-stationary meteorological process.

## ВВЕДЕНИЕ

Одной из основных задач метеорологии является анализ и прогнозирование динамики процессов изменения атмосферной температуры. При этом рассматриваются скалярные поля атмосферной температуры, представленные на заданных уровнях геопотенциала двухмерной сеткой с постоянными шагами по меридианам и параллелям. Рассматриваются ежедневные значения среднесуточной температуры в узлах сетки. Изменение температуры представляет собой случайный процесс, порождающий временной ряд температур. В работах [1, 2] представлены результаты сравнения различных прогностических моделей описания динамики процессов изменения атмосферной температуры, среди них модель в виде многослойного персептрона, модель Сугено с векторной авторегрессией, а также модель Сугено с многослойным персептроном [2]. В ходе выполненных исследований было выявлено, что одним из факторов, ограничи-

вающих точность прогноза, является сезонный, т. е. существенно нестационарный, характер динамики анализируемых процессов.

Для большинства реальных процессов, описываемых как нестационарные случайные последовательности, характерно изменение основных статистических параметров таких как, например, математическое ожидание или дисперсия, с течением времени. Необходимо отметить, что изменение этих параметров происходит достаточно медленно относительно динамики изменения самого процесса. В этом случае одним из возможных подходов к задаче прогнозирования является использование иерархических нейросетевых архитектур, что позволяет учитывать как динамику изменения статистических параметров случайного процесса, так и динамику изменения самого процесса.

В работе [3] было показано, что применение иерархически организованных нейронных сетей позволяет повысить точность прогноза при решении задач подобного типа.

Целью настоящей работы явился анализ возможности применения методики постро-

ения иерархической нейронной сети [3] для прогнозирования динамики процессов изменения атмосферной температуры, а также сравнение полученных результатов с ранее полученными прогностическими моделями.

### МЕТОДИКА ЭКСПЕРИМЕНТА

Динамика температуры в каждом узле сетки с конкретными пространственными координатами может быть описана в следующем виде

$$x_{ij}(t+1) = a_{ij} x_{ij}(t) + a_{i-1j} x_{i-1j}(t) + a_{i+1j} x_{i+1j}(t) + a_{ij-1} x_{ij-1}(t) + a_{ij+1} x_{ij+1}(t),$$

где  $x(t) = (x_{i-1j}, x_{ij}, x_{i+1j}, x_{ij-1}, x_{ij+1})$  – вектор значений температуры в окрестности узла  $ij$  в момент времени  $t$ ,  $a_{i-1j}$ ;  $a_{ij}$ ;  $a_{i+1j}$ ;  $a_{ij-1}$ ;  $a_{ij+1}$  – неизвестные параметры модели ВАР, подробно представленной в [2].




Рис. 1. Фрагмент схемы измерения метеорологических показателей, шаг сетки по параллелям и меридианам составляет  $2,5^\circ$

В самом общем случае может рассматриваться задача прогнозирования нестационарной временной последовательности вида

$$y_{t+1} = F(y_t, u_t) + \xi_t, \quad t = 1, 2, \dots, \quad (1)$$

где  $y_{t+1}$  – состояния рассматриваемого процесса в момент времени  $t+1$ ;  $u_t$  – вектор известных дополнительных управляющих параметров, позволяющий конкретизировать условия проведения наблюдений на каждом шаге;  $\xi_t$  – вектор, учитывающий воздействие случайных факторов.

Часто управляющий параметр меняется существенно медленнее, чем основной (таким

параметром, например, может быть коэффициент корреляции случайного процесса), поэтому модель (1) можно представить в виде

$$y_t = F(y_{t-1}, u_{s-1}) + \xi_t, \quad s = \phi(t) = [t/\Delta N] + 1, \quad (2)$$

$$t = 1, 2, \dots$$

$$u_s \cong u_i = \text{const}, \quad s = i, \quad (i-1)\Delta N \leq t < i\Delta N,$$

где символ [...] означает целую часть числа;  $\Delta N$  – шаг изменения управляющего параметра.

Относительно переменной  $u_s$  во многих случаях можно предположить, что

$$u_s = \Phi(u_{s-1}) + \tilde{\xi}_s, \quad s = \phi(t),$$

$$s = 1, 2, \dots, \quad t = 1, 2, \dots \quad (3)$$

где  $\tilde{\xi}_s$  – вектор, учитывающий воздействие случайных факторов.

Таким образом, математическая модель исходного процесса может быть представлена как модель двух иерархически вложенных процессов [3].

Для нашей задачи модель (1–3) в каждом узле  $ij$  температурной сетки можно переписать в следующем виде

$$y_{ij}^t = F(y_{ij}^{t-1}, y_{i-1j}^{t-1}, y_{i+1j}^{t-1}, y_{ij+1}^{t-1}, y_{ij-1}^{t-1}, u_{kl}^{t-1}) + \xi_{ij}^{t-1}, \quad t = 1, 2, \dots$$

$$k = [i/\Delta N] + 1, \quad l = [j/\Delta N] + 1,$$

$$u_{kl} \cong u_{rp} = \text{const}, \quad k = r, \quad l = p,$$

$$(r-1)\Delta N \leq i < r\Delta N, \quad (p-1)\Delta N \leq j < p\Delta N.$$

Параметр  $u_{kl}^{t-1}$  – среднее значение температуры, посчитанное в квадрате нового масштаба

$$u_{kl}^{t-1} = \sum_{i=1}^{\Delta N} \sum_{j=1}^{\Delta N} x_{ij} / (\Delta N + 1)^2,$$

$\Delta N$  – шаг изменения управляющего параметра, т. е. по сути – это размер ячейки в укрупненном масштабе. Схемы исходного и укрупненного масштаба представлены на рис. 2.

В случае решения задачи прогнозирования для модели (2) будем использовать двухуровневую иерархическую нейронную сеть, архитектура которой представлена на рис. 3.

Первый иерархический уровень (так называемая «медленная нейронная сеть») предназначен для прогнозирования параметра  $u$ , который является управляющим для векторов входа второго иерархического уровня.




Рис. 2. Схема исходного и укрупненного масштаба




Рис. 3. Структура двухуровневой иерархической нейронной сети

В общем случае, каждый иерархический уровень сети может иметь несколько скрытых слоев. В нашей задаче каждый иерархический уровень имеет два слоя нейронов.

Для первого иерархического уровня сети вектор входа имеет длину  $m = L$ , то есть вектор входных значений определяется как  $u = (u_{s-L}, u_{s-L+1}, \dots, u_{s-1})^T$ ,  $s > L$ . Вектор выхода имеет длину  $m = 1$ , и, соответственно выходной вектор определяется как  $u = u_s$ .

Выходное значение сети первого иерархического уровня  $u = u_s$  является управляющим параметром для сети второго иерархического уровня (так называемой «быстрой

нейронной сети»). Таким образом, вектор входа второго иерархического уровня имеет длину  $m = M + 1$ , а вектор входных значений сети второго уровня или «быстрой нейронной сети» формируется следующим образом:

$$\bar{x} = (y_{t-M}, y_{t-M+1}, \dots, y_{t-1}, u)^T.$$

Вектор выхода имеет длину  $m = 1$ , и, соответственно выходной целевой вектор определяется как  $x = x_t$ .

Таким образом, сеть второго иерархического уровня осуществляет прогнозирование с учетом полученного на выходе сети первого уровня управляющего параметра [3].

Методика обучения иерархической нейронной сети заключается в реализации независимых процедур обучения на каждом уровне при известной математической модели иерархически вложенных процессов. На первом этапе происходит обучение «медленной нейронной сети». Формируем представительные по объему обучающие примеры для построения модели прогнозирования на основе «медленной нейронной сети». Обучающее множество формируется следующим образом. Для фиксированных значений  $t$  и  $L$  формируются входные векторы  $u^{(i)} = (u_{s-L}, u_{s-L+1}, \dots, u_{s-1})^T$ ,  $s > L$  и требуемые им выходные целевые векторы  $u^{(i)} = u_s^{(i)}$ ,  $i = 1 \dots K$ , где  $K$  – число обучающих примеров.

На втором этапе происходит обучение второго иерархического уровня или «быстрой нейронной сети». Формирование обучающего множества происходит следующим образом.

Независимо для каждого значения  $u$  ( $u = u_s$ ,  $s = 1, 2, \dots, S$ ), для фиксированных  $t$  и  $M$  формируем входные векторы  $x^{(j)} = (y_{t-M}, y_{t-M+1}, \dots, y_{t-1}, u)^T$ ,  $t > M$  и требуемые им выходные целевые векторы  $x^{(j)} = x_t^{(j)}$ ,  $j = 1 \dots J$ , где  $J$  – число обучающих примеров.

Вариант методики обучения иерархической нейронной сети в случае, когда модель управляющего параметра неизвестна подробно представлена в [3].

В нашей задаче входным вектором для сети первого уровня является вектор средних значений температур, посчитанных в восьми смежных областях, окружающих центральную,  $X = (X_1, X_2, \dots, X_8)^T$ , где  $X_i$ ,  $i = 1 \dots 8$  – среднее значение температуры в  $i$ -й области (т. е. среднее значение в укрупненном масштабе, в нашем случае вся координатная сетка была разбита на квадраты по 25 точек в каждом, размер может варьироваться), схема исходного и укрупненного масштаба на примере восьми смежных областей представлена на рис. 4. Количество выходных нейронов равно единице. На выход сети первого уровня подается среднее значение температуры центральной области. Выходное значение сети первого иерархического уровня является управляющим параметром для сети второго иерархического уровня (так называемой «быстрой нейронной сети»). Таким образом, вектор входных значений сети второго уровня состоит из значения температур в точках  $ij$ ,  $ij+1$ ,  $ij-1$ ,  $i-1j$ ,  $i+1j$ , а также управляющего параметра  $u$  – среднего значения температуры в этом (центральном) квадрате. Таким образом, сеть второго иерархического уровня осуществляет прогнозирование значения температуры в узле  $ij$  на следующий день с учетом полученного на выходе сети первого уровня дополнительного параметра – среднего значения температуры в этом квадрате на следующий день. Архитектура двухуровневой иерархической нейронной




Рис. 4. Схема исходного и укрупненного масштаба на примере восьми смежных областей




Рис. 5 Архитектура двухуровневой иерархической нейронной сети в обозначениях для задачи прогнозирования динамики изменения процессов атмосферной температуры

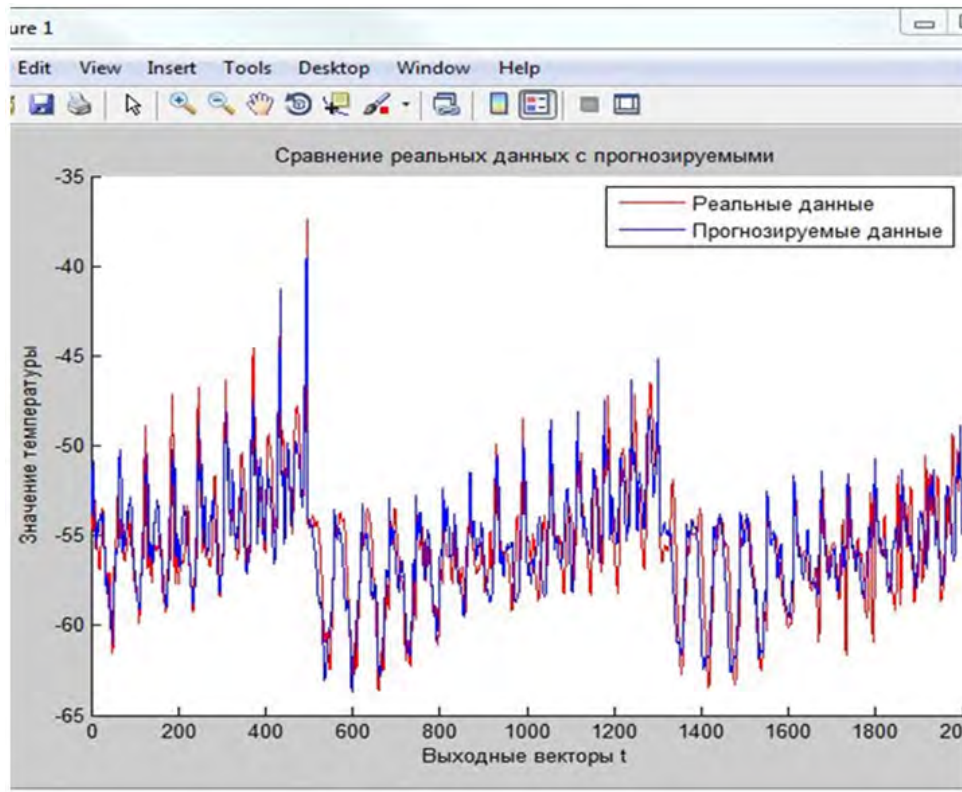


Рис. 6. Результаты работы иерархической нейронной сети

сети в обозначениях для задачи прогнозирования динамики изменения процессов атмосферной температуры представлена на рис. 5.

Для экспериментальной апробации использовались статистические данные реанализа параметров атмосферы за 2008 год, приведенные к среднесуточным значениям [4]. Рассматривались процессы изменения температуры при геопотенциале 300 ГПа в узле сетки с координатами  $-70^\circ$  северной широты;  $2,5^\circ$  восточной долготы.

Для обучения сети использовалась инструментальная среда MATLAB 10. В качестве функций активации входного и скрытого слоя использовалась сигмоидальная функция «logsig», для выходного слоя линейная функция «purelin». Обучение ИНС производилось с помощью алгоритма Levenberg-Marquardt («trainlm»).

Для обучения второго иерархического уровня была также выбрана сеть многослойный персептрон с четырьмя скрытыми слоя-

ми. В качестве функций активации входного и скрытых слоев использовалась сигмоидальная функция «logsig», для выходного слоя линейная функция «purelin». Обучение ИНС производилось с помощью алгоритма Levenberg-Marquardt («trainlm»). На рис. 6 представлена работа иерархической нейронной сети.

### ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

В качестве показателя эффективности каждой модели использовался коэффициент детерминации [5]

$$R^2 = 1 - \frac{\sum_{t=1}^T (x(t) - \hat{x}(t))^2}{\sum_{t=1}^T (x(t) - \bar{x})^2}, \quad (4)$$

$x(t)$ ,  $\hat{x}(t)$  – фактические и расчетные значения уровней ряда соответственно,  $\bar{x}$  – среднее значение уровня ряда.

Также для сравнения использовался показатель процентной погрешности прогноза MAPE [6]

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{x(t) - \hat{x}(t)}{x(t)} \right| \cdot 100\%, \quad (5)$$

MAPE не должен превышать 10–12 %.

Результаты сравнения работы иерархической ИНС, обычной ИНС, а также прогнозной модели метеорологической системы на базе уравнения векторной авторегрессии с переменными параметрами [1, 2] представлены в табл. 1.

Таблица 1  
Сравнительный анализ работы различных моделей

Вид модели	$R^2$	MAPE
Иерархическая ИНС	0,93	2,2 %
Обычная ИНС	0,86	2,5 %
Модель метеорологической системы на базе уравнения векторной авторегрессии с переменными параметрами	0,82	2,48 %

### ЗАКЛЮЧЕНИЕ

Результаты сравнения моделей, представленные в табл. 1 показывают работоспособность и очевидное преимущество работы иерархической нейронной сети.

В качестве итога, подчеркнем тот факт, что использование иерархической нейронной сети в данном случае повышает качество прогнозирования и позволяет модели в целом стать более устойчивой к случайным воздействиям.

### СПИСОК ЛИТЕРАТУРЫ

1. Матвеев М. Г. Разработка и исследование статистических моделей нестационарного многомерного временного ряда атмосферных температур в условиях неоднородности / М. Г. Матвеев, Е. А. Сирота // Информационные технологии. – 2014. – № 12. – с. 20–24.
2. Матвеев М. Г. Модель анализа динамики векторного метеорологического процесса / М. Г. Матвеев, В. В. Михайлов, М. Е. Семенов, Е. А. Сирота // Вестник Воронеж. гос. ун-та. Сер. Системный анализ и информационные технологии. – 2013. – № 1. – С. 89–95.
3. Сирота Е. А. Прогнозирование нестационарных временных последовательностей на основе иерархических многослойных нейронных сетей / Е. А. Сирота // Журнал «Информационные технологии». – 2014. – № 1. – С. 67–71.
4. NCEP/DOEAMIP II Reanalysis. URL: <http://www.cdc.noaa.gov/cdc/data.ncep.reanalysis2.html>.
5. Айвазян С. А. Основы эконометрики / С. А. Айвазян // М. : ЮНИТИ. – 2001. – 656 с.
6. Лукашин Ю. П. Адаптивные методы краткосрочного прогнозирования временных рядов / Ю. П. Лукашин // М. : Финансы и статистика. – 2003. – 416 с.

**Сирота Е. А.** – кандидат физико-математических наук, доцент кафедры цифровых технологий, факультет компьютерных наук, Воронежский государственный университет.  
E-mail: sirota\_ea@sc.vsu.ru

**Матвеев М. Г.** – доктор технических наук, профессор, заведующий кафедрой информационных технологий управления, факультет компьютерных наук, Воронежский государственный университет.  
E-mail:mgmatveev@yandex.ru

**Sirota E. A.** – candidate of physics-math. sciences, assistant professor, the dept. of digital technologies Faculty of Computer Science, Voronezh State University.  
E-mail: sirota\_ea@sc.vsu.ru

**Matveev M. G.** – doctor of technical sciences, professor department of programming and information technologies, Voronezh State University.  
E-mail: mgmatveev@yandex.ru