

КОМБИНИРОВАННЫЕ МОДЕЛИ НЕСТАЦИОНАРНЫХ ВРЕМЕННЫХ РЯДОВ С ИЗМЕНЯЮЩИМИСЯ СОСТОЯНИЯМИ

М. Г. Матвеев, Е. А. Сирота

Воронежский государственный университет

Поступила в редакцию 10.09.2016 г.

Аннотация. В рамках настоящей работы проводится анализ и исследование качества комбинированных моделей нестационарных временных рядов с изменяющимися состояниями в зависимости от способа их построения. Исследование указанных моделей производилось с использованием статистических данных атмосферной температуры, представляющих собой многомерные временные ряды с изменяющимися состояниями.

Ключевые слова: комбинированные модели, нестационарный временной ряд, изменяющиеся состояния, многомерный временной ряд, искусственная нейронная сеть.

Annotation. As part of this work the analysis and study of the quality of combined models of non-stationary time series with varying conditions depending on the method of their construction. The study of these models are made using statistical data of atmospheric temperature, which are multi-dimensional time series with the changing conditions.

Keywords: combined models, non-stationary time sequence, changing state, multivariate time series, neural network.

ВВЕДЕНИЕ И ПОСТАНОВКА ЗАДАЧИ

На сегодняшний день аппарат анализа и прогнозирования нестационарных временных рядов наиболее востребован в различных областях человеческой деятельности: метеорологии, социологии, медицине, исследовании финансовых рынков и ряда других. Учет нестационарности обычно реализуется путем поиска структурных разрывов, представляющих собой изменения свойств процесса, отражающиеся в изменениях коэффициентов параметрической модели процесса, параметров распределения случайной составляющей [1] или моментов разладки, характеризующих смену режима функционирования ряда, а именно переходом из одного квазистационарного состояния в другое [2].

Подход, сложившийся в рамках методологии поиска структурных разрывов или моментов разладки нестационарного временного ряда приведен в работах [1–3]. Он представляет собой выделение сегментов однородных статистических данных, разде-

ленных моментами разладки. На сегментах однородной статистики ведется построение моделей с постоянными параметрами. Однако возникновение структурного разрыва может происходить скачкообразно или относительно медленно с явным переходным процессом, и обуславливается трудно контролируемым изменением состояния системы, что в свою очередь существенно усложняет реализацию построения сегментов. В работах [1, 4] предлагается методика построения индикаторов разладки для нестационарных одномерных временных рядов. В случае же, когда рассматриваются многомерные временные ряды вводится еще одна или несколько переменных и построение индикаторов разладки не представляется возможным.

Другая современная тенденции построения прогнозных моделей нестационарных временных рядов основывается не на выделении сегментов однородных статистических данных, а на идеи классификации всего массива динамической информации по некоторым признакам. Предлагается выделять однородные в определенном смысле группы (классы или кластеры) данных временно-

го ряда и строить модели прогнозирования для каждой группы отдельно. Отметим, что внутри каждого кластера свойства процесса, характеризующиеся коэффициентами параметрической модели, сохраняются неизменными наряду с параметрами построенной прогнозной модели. Для решения проблемы кластеризации и построения прогнозных моделей внутри каждого кластера последнее время широко используются комбинированные модели, позволяющие компенсировать недостатки одних моделей достоинствами других, и повысить, в конечном счете, возможности прогнозирования. В ряде таких работ, как [5–8] проведен анализ и исследование различных типов комбинированных моделей для решения различного рода практических задач и установлено, что их использование является наиболее перспективным направлением анализа нестационарных временных рядов.

В рамках настоящей работы проводится анализ и исследование качества комбинированной модели в зависимости от способа выделения групп однородных статистических данных временного ряда, а также метода построения прогнозной модели внутри выделенных групп данных.

В качестве модели нестационарного временного ряда предлагается рассмотреть систему из двух уравнений. Уравнение, описывающее изменение уровней ряда y , имеет вид

$$y = F(t, s), \quad (1)$$

где t – время, s – численная характеристика внутреннего состояния системы, которое задает ту или иную модель поведения ряда. Если состояние системы остается неизменным, то уровни ряда могут меняться во времени по произвольной, но постоянной зависимости, если же состояние системы меняется, то обязательно изменяется поведение ряда. Изменение состояний происходит под воздействием неконтролируемых внешних факторов, поэтому будем считать, что действие внешних факторов находит свое отражение в изменении значений уровней ряда и смена состояний может описываться в виде зависимости от этих уровней. Часто в качестве характеристики состояния системы рассматривают пара-

метры модели F , что существенно облегчает построение прогнозных моделей в каждом кластере, так как внутри него параметры остаются неизменными.

Второе уравнение описывает непосредственно изменение состояний

$$s = \Phi(t) = \Phi(y(t)). \quad (2)$$

Изменение состояния системы во времени, в подавляющем большинстве случаев, не удастся связать с какими-либо феноменологическими законами, поэтому для построения непрерывной модели Φ предлагается использовать принцип «черного ящика», который, как известно, требует серии измерений входа и выхода моделируемого процесса для параметрической идентификации выбранной структуры модели. Возникает задача получения серии оценок состояния s , соответствующих измеряемым уровням ряда $y(t)$.

Целью нашего исследования является построение и анализ моделей F и Φ в следующих вариантах:

А. Структура модели F – авторегрессия; структура модели Φ – искусственная нейронная сеть (ИНС).

В. Структура модели F – ИНС; структура модели Φ – ИНС.

Исследование указанных моделей производилось с использованием статистических данных атмосферной температуры, полученных с открытого электронного ресурса [9]. Данные представляют собой временные ряды среднесуточной температуры за несколько лет в узлах плоской координатной сетки, построенной на заданной высоте от поверхности земли (см. рис.1). Шаг сетки по широте (координата i) и долготе (координата j) составляет $h = 2,5^\circ$.

Между временными рядами в соседних узлах сетки имеется корреляционная зависимость. Выбор атмосферной температуры в качестве объекта исследования объясняется доступностью большого количества качественных статистических данных в виде нестационарных многомерных временных рядов с изменяющимися свойствами. Гарантированное наличие изменяющихся свойств объясняется естественным изменением состояния атмосферы, влияющим на динами-

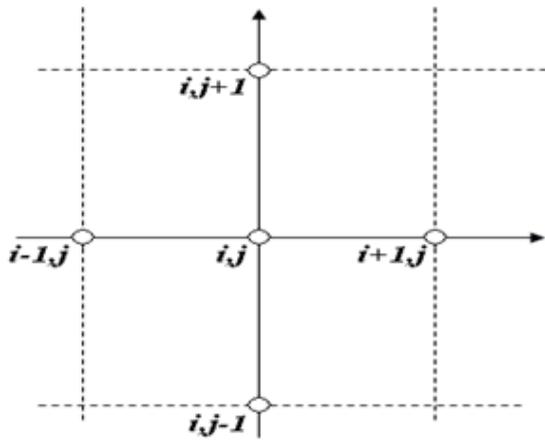


Рис. 1. Фрагмент схемы измерения атмосферной температуры

ку температуры, например, на сезонную динамику. Пример многомерного временного ряда атмосферной температуры в смежных узлах сетки приведен на рис. 2.

ИССЛЕДОВАНИЕ МОДЕЛЕЙ ВАРИАНТА А

Проведенный корреляционный анализ временных рядов температуры [10] показал, что смежные временные ряды температуры в узлах регулярной сетки на рис. 1 коррелированы между собой и коэффициенты корреляции имеют статистически значимые оценки (более 0,7). Поэтому такие ряды предлагается рассматривать как многомерный временной

ряд, представленный в виде вектора температур $y(t)$ смежных узлов сетки в момент времени t :

$$y(t) = (y_{i-1,j}(t); y_{i+1,j}(t); y_{i,j}(t); y_{i,j-1}(t); y_{i,j+1}(t)).$$

Значение температуры в узле ij в $(t+1)$ -й момент времени – $y_{ij}(t+1)$, можно представить как взвешенное среднее компонент вектора $y(t)$ [], т. е. для произвольного, но не граничного узла ij , $i = 2, \dots, n-1$; $j = 2, \dots, m-1$, можно записать следующее выражение:

$$y_{ij}(t+1) = \alpha_{ij}y_{ij}(t) + \alpha_{i-1,j}y_{i-1,j}(t) + \alpha_{i+1,j}y_{i+1,j}(t) + \alpha_{i,j-1}y_{i,j-1}(t) + \alpha_{i,j+1}y_{i,j+1}(t) + \xi_{ij}(t+1). \quad (3)$$

где α_{ij} – весовые коэффициенты; $\xi_{ij}(t+1)$ – серийно некоррелированные ошибки, о которых предполагается, что они имеют нулевое среднее и ковариацию $\sigma_{\xi\xi}$.

Нестационарность последовательности (3) обеспечивается переменными весовыми коэффициентами $\alpha_{ij}(t) = \alpha_{ij}(y_{ij}(t))$, изменение состояния отображается изменением зависимости $\alpha_{ij}(y_{ij}(t))$.

Уравнения вида (3) можно записать для $d = n \times m - 2(n + m - 2)$ узлов сетки:

$$y_{d \times 1}(t+1) = A_{d \times s}(t)y_{s \times 1}(t), \quad (4)$$

где $s = n \times m$; A – матрица оценок весовых коэффициентов.

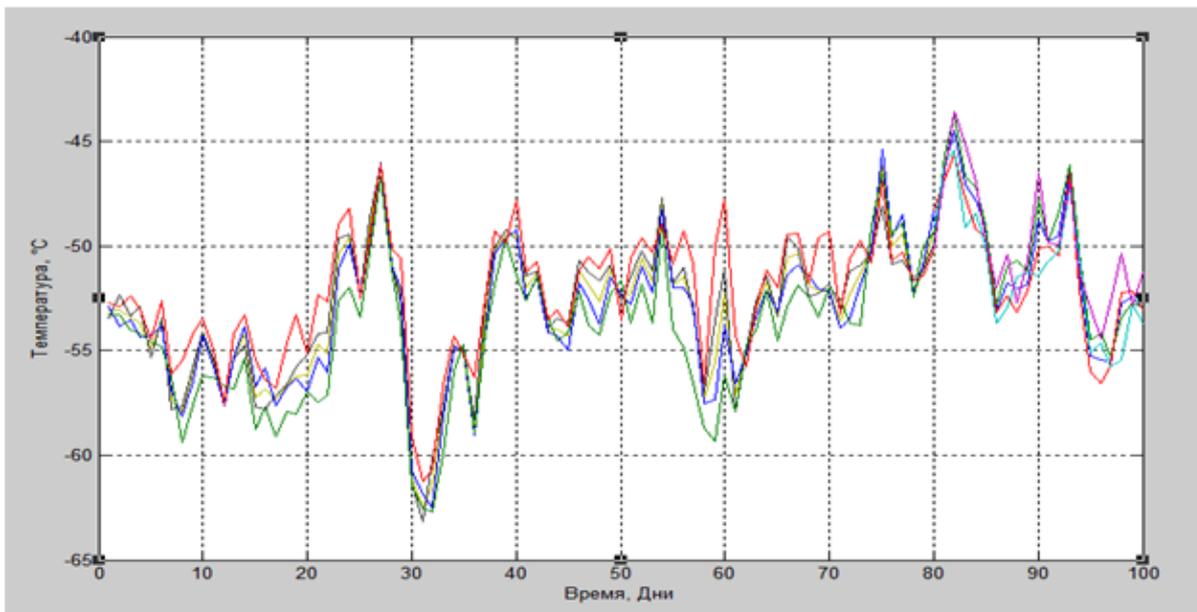


Рис. 2. Пример многомерного временного ряда атмосферной температуры в смежных узлах сетки

Для получения элементов матрицы A необходимо построить классы однородной статистики по выбранному заранее критерию, характеризующему состояние атмосферы. В качестве такого критерия предлагается использовать вектор центральных разностей, вычисляемый в узлах сетки (рис. 1) – $\Delta_{ij} = (\delta_i; \delta_j)$, где $\delta_i = y_{i+1,j} - y_{i-1,j}$, $\delta_j = y_{i,j+1} - y_{i,j-1}$. Выбор такого критерия обосновывается его естественной интерпретацией. Действительно, вектор Δ_{ij} обозначает направление и скорость перемещения воздушных масс, что, безусловно, определяет состояние атмосферы. Кроме того, наличие многомерного ряда предоставляет возможность вычисления вектора центральных разностей при фиксированном времени по пространственным координатам, что обеспечивает однозначность соответствия значения температуры и состояния атмосферы.

Классы однородной статистики будут представлять собой значения температуры уже неупорядоченные как по времени, так и по узлам сетки. Поэтому, для сохранения структуры связи данных с уравнением (4) необходимо запоминать соответствие

$$S: \{y_{ij}(t+1)\} \rightarrow \{(y_{ij}(t); y_{i-1,j}(t); y_{i+1,j}(t); y_{i,j-1}(t); y_{i,j+1}(t))\}. \quad (5)$$

Построение классов однородной статистики можно осуществлять, используя алгоритмы классификации или алгоритмы кластеризации.

Для построения классов можно применяться следующая процедура. Пусть длина и направление вектора Δ ограничены соотношениями:

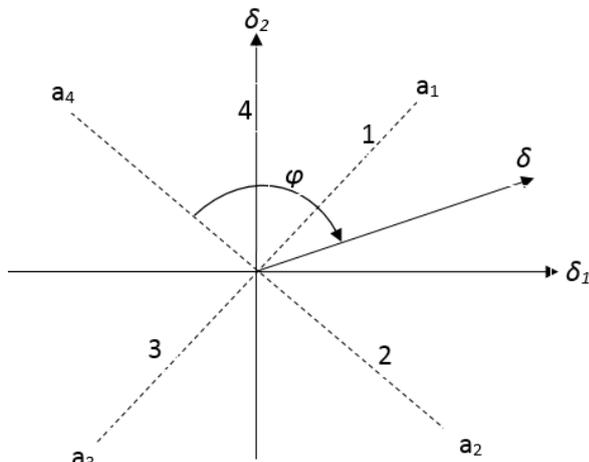


Рис. 3. Схема построения классов

$$|\Delta| \in [0, |\Delta_{\max}|], \quad (6)$$

$$\alpha \in [0^\circ, 360^\circ), \quad (7)$$

где α – угол между вектором Δ и вектором $(0, 1)$ как показано на рис. 3.

Разобьем промежутки в правой части соотношений (6) и (7) на несколько меньших, одинаковых промежутков Δy_i , $i = 1, \dots, k_1$; и $\Delta \alpha_j$, $j = 1, \dots, k_2$; таких, что $\bigcup_i \Delta y_i = [0, |\Delta_{\max}|]$; $\bigcap_i \Delta y_i = \emptyset$; $\bigcup_j \Delta \alpha_j = [0^\circ, 360^\circ)$; $\bigcap_j \Delta \alpha_j = \emptyset$, а значения k_1 и k_2 позволяют считать что значения вектора центральных разностей внутри этих промежутков примерно одинаковы. Получим два множества классов длин и направлений вектора Δ : $\{\Delta y_i\}$, $\{\Delta \alpha_j\}$. Прямое произведение этих множеств даст множество классов $(\Delta y_i, \Delta \alpha_j)$. Каждая пара значений длины вектора $|\nabla|$ и угла α внутри класса $(\Delta y_i, \Delta \alpha_j)$ определяется измеренными значениями температуры в смежных узлах сетки

$$|\nabla| = \sqrt{(y_{i+1,j} - y_{i-1,j})^2 + (y_{i,j+1} - y_{i,j-1})^2}; \quad (8)$$

$$\cos \alpha = \frac{\delta_j}{|\nabla|}. \quad (9)$$

Соотношения (8) и (9) позволяют устанавливать соответствие между значениями $y_{ij}(t)$ и классами значений выбранного критерия, а следовательно формировать классы однородных значений уровней ряда $\{y_{ij}\}_k \in K_1$, где K_1 – множество классов однородной, в смысле значения Δ , статистики. Для каждого класса $\{y_{ij}\}_k$ можно построить модель

$$y_{ij}^k(t+1) = a_{ij}^k y_{ij}^k(t) + a_{i-1,j}^k y_{i-1,j}^k(t) + a_{i+1,j}^k y_{i+1,j}^k(t) + a_{i,j-1}^k y_{i,j-1}^k(t) + a_{i,j+1}^k y_{i,j+1}^k(t) \quad (10)$$

с постоянными коэффициентами a^k , характеризующими стационарное состояние атмосферы. Оценки этих коэффициентов нетрудно получить с помощью метода наименьших квадратов.

Для экспериментальной апробации использовались статистические данные реанализа параметров атмосферы за 2008–2010 годы, приведенные к среднесуточным значениям. Рассматривались процессы изменения температуры при геопотенциале 300 гПа в

узле сетки с координатами -70° северной широты; $2,5^\circ$ восточной долготы. В рассматриваемом узле было выделено 16 классов однородной статистики, из них 14 оказались с представительным объемом выборки.

Результаты моделирования приведены в табл. 1, где классы обозначены как K_k , $k = 1, \dots, 14$.

Таблица 1
Параметры модели VAR для класса однородной статистики

№ кл.	$a_{i,j}$	$a_{i-1,j}$	$a_{i+1,j}$	$a_{i,j-1}$	$a_{i,j+1}$	R^2
K_1	0	0	-0,25	2,80	-1,61	0,76
K_2	0,40	7,55	9,32	0	-16,17	0,84
K_3	0,28	0,82	-1,70	-1,23	2,8	0,94
K_4	0,48	0,92	4,11	3,77	-8,32	0,85
K_5	0,50	0,92	3,68	7,74	-11,9	0,63
K_6	0	0	0,66	-0,40	0,63	0,82
K_7	1,9	0	0,83	0	-1,82	0,80
K_8	-0,7	0,15	2,98	3,78	-5,40	0,73
K_9	0	0,86	0	0	0,07	0,88
K_{10}	0	0	-1,74	1,79	0,77	0,84
K_{11}	0,31	0	0	0	0,71	0,87
K_{12}	0	0	0,46	0,47	-0,11	0,80
K_{13}	1,18	0	-0,26	7,06	-7,00	0,90
K_{14}	0,75	0,026	4,91	6,62	-11,26	0,92

Для подтверждения адекватности моделей в таблице также приводятся значения коэффициента детерминированности R^2 [11].

Модель F построена, теперь строим модель Φ . Построение модели Φ можно рассматривать как построение соответствия $\Phi: \Delta(y) \rightarrow A$, где A – матрица коэффициентов модели (4). Для обучения был использован трехслойный персептрон с четырьмя нейронами входного слоя, четырьмя нейронами скрытого и пятью нейронами выходного слоя. 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»).

На рис. 4 представлены результаты моделирования – высотный температурный про-

филь с проекцией на опорную плоскость в узле сетки с координатами -70° северной широты; $2,5^\circ$ восточной долготы и разными значениями геопотенциала (300 гПа, 400 гПа, 500 гПа, 600 гПа, 700 гПа, 850 гПа, 925 гПа, 1000 гПа).

На рис. 5 представлены результаты прогноза на всех геопотенциальных уровнях (в узле сетки с координатами -70° северной широты; $2,5^\circ$ восточной долготы) на 20 шагов вперед, а также для сравнения результаты фактических наблюдений.

Для анализа адекватности построенной модели было проведено дополнительное исследование оценки полученных остатков между фактическими измерениями атмосферной температуры и смоделированными значениями с помощью статистической гипотезы о равенстве нулю их математического ожидания, постоянстве дисперсии (критерий Голдфелда – Квандта) и отсутствии автокорреляции (критерий Дарбина – Уотсона).

На рис. 6 представлены графики остатков (разница между фактом и прогнозом) по прогнозам на всех геопотенциальных уровнях.

В табл. 2 представлены результаты проверки остатков с помощью критерия Голдфелда – Квандта и критерия Дарбина – Уотсона.

С целью повышения качества прогноза было проведено дополнительное исследование полученной модели Φ в зависимости от типа настройки нейронной сети. В качестве показателя эффективности каждой модели использовался коэффициент детерминации и показатель процентной погрешности прогноза MAPE

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{x(t) - \hat{x}(t)}{x(t)} \right| \cdot 100\%, \quad (11)$$

$x(t)$, $\hat{x}(t)$ – фактические и расчетные значения уровней ряда соответственно MAPE не должен превышать 10–12 %.

Сравнительный анализ работы различных нейронных сетей в зависимости от типа настройки сети представлен в табл. 3.

На рис. 7 и 8 соответственно представлены результаты работы нейронной сети (в узле сетки с координатами -70° северной широты; $2,5^\circ$ восточной долготы, значение геопо-

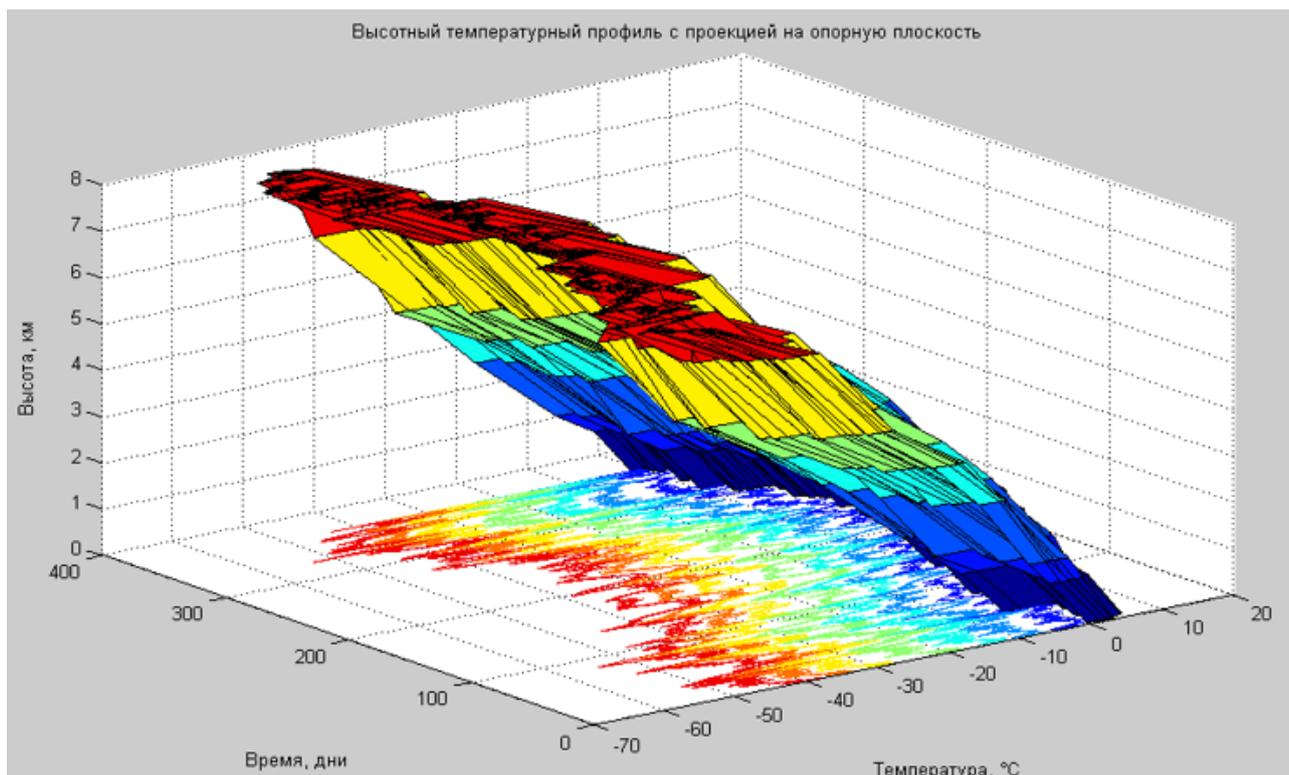


Рис. 4. Высотный температурный профиль с проекцией на опорную плоскость в узле сетки с координатами -70° северной широты; $2,5^\circ$ восточной долготы и разными значениями геопотенциала

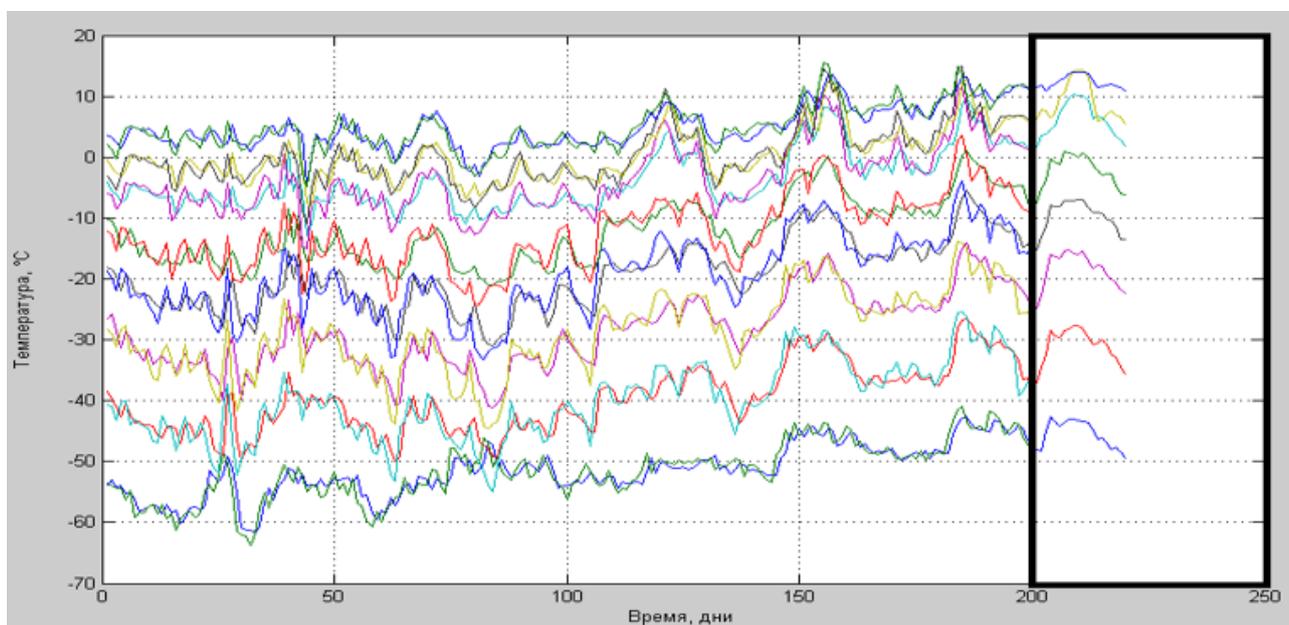


Рис. 5. Результаты прогноза на всех геопотенциальных уровнях

тенциала 300 гПа), где в первом случае в качестве функций активации входного и выходного использовалась линейная функция «purelin», сигмоидальная функция «logsig» для скрытого слоя, во втором – в ка-

честве функций активации входного слоя использовалась функция «tansig», сигмоидальная функция «logsig» для скрытого слоя, для выходного слоя – функция «purelin».

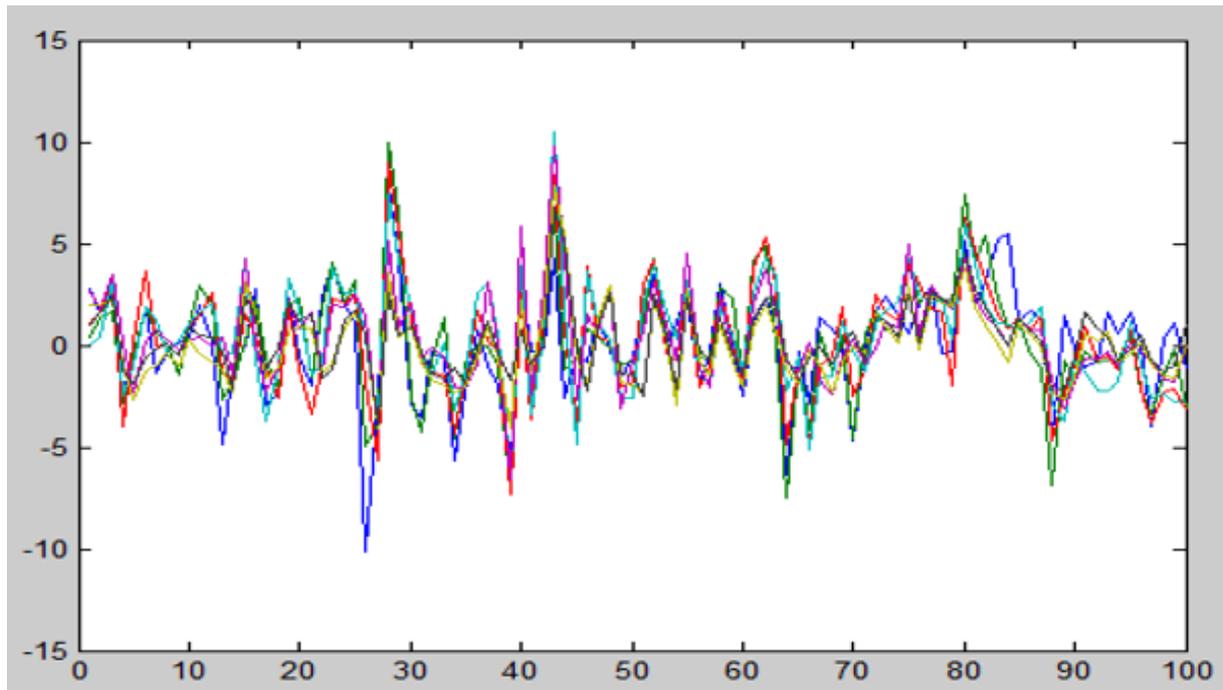


Рис. 6. Графики остатков (разница между фактом и прогнозом) по прогнозам на всех геопотенциальных уровнях

Таблица 2

Проверка остатков (критерий Голдфелда – Квандта, критерий Дарбина – Уотсона)

Значение геопотенциала H , гПа	Критерий Голдфелда – Квандта. Значение параметра F ($F < F_{кр} = 3.87$)	критерий Дарбина – Уотсона. Значение параметра DW ($1.5 < DW < 2.5$)
300	1.008	1.95
400	1.0095	2.05
500	1.005	1.98
600	1.186	1.8
700	1.950	2.01
850	1.0075	2.1
925	1.905	1.99
1000	2.05	1.95

ИССЛЕДОВАНИЕ МОДЕЛЕЙ ВАРИАНТА В

Модели варианта А потребуют большого количества информации для выделения классов однородных данных, процедуры их построения достаточно сложны и громоздки, особенно в части построения и запоминания соответствия (5). Рассмотрим модель В, которая позволит существенно упростить учет

изменения состояния системы в процессе ее функционирования. Модели варианта В представляют собой две последовательно включенные ИНС. Первая ИНС (модель Φ) отвечает за состояние, вторая (F) за прогноз. Рассмотрим построение моделей F и Φ варианта В подробно на примере нестационарной временной последовательности вида

$$y_{t+1} = F(y_t, s_t) + \xi_t, \quad t = 1, 2, \dots, \quad (12)$$

где y_{t+1} – значения рассматриваемого процес-

Сравнительный анализ работы различных нейронных сетей в зависимости от типа настройки

Номер нейросети	Функция активации нейронов (входной слой/скрытый/выходной)	Число нейронов в скрытом слое	R^2	Маре
1	Purelin/logsig/purelin	3	0.86	2.7
2		5	0.92	2.5
3		7	0.95	2.45
4		10	0.956	2.5
5		20	0.91	2.65
5	Tansig/logsig/purelin	3	0.92	2.5
6		5	0.95	2.495
7		7	0.96	2.3
8		10	0.967	2.2
9		20	0.945	2.5

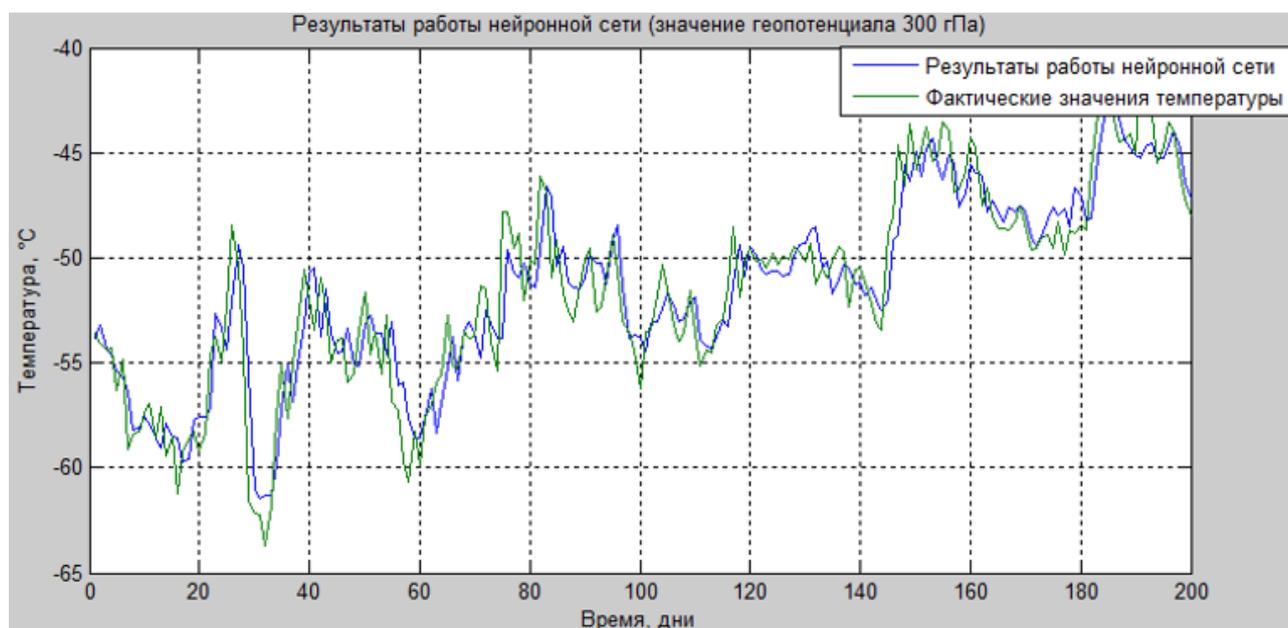


Рис. 7. Результаты работы нейронной сети (в узле сетки с координатами -70° северной широты; $2,5^\circ$ восточной долготы, значение геопотенциала 300 гПа). В качестве функций активации входного и выходного использовалась линейная функция «purelin», сигмоидальная функция «logsig» для скрытого слоя

са в момент времени $t + 1$; s_t – вектор известных дополнительных параметров, при котором состояние системы сохраняется неизменным; ξ_t – вектор, учитывающий воздействие случайных факторов.

Часто вектор дополнительных параметров меняется существенно медленнее, чем основной, поэтому модель (12) можно представить в виде

$$y_t = F(y_{t-1}, s_{\tau-1}) + \xi_t, \quad \tau = \phi(t) = [t / \Delta N] + 1, \quad (13)$$

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

$$s_\tau \cong s_i = const, \quad \tau = i, \quad (i-1)\Delta N \leq t < i\Delta N,$$

где символ [...] означает целую часть числа; ΔN – шаг изменения вектора дополнительных параметров.

Относительно вектора s_t во многих случаях можно предположить, что

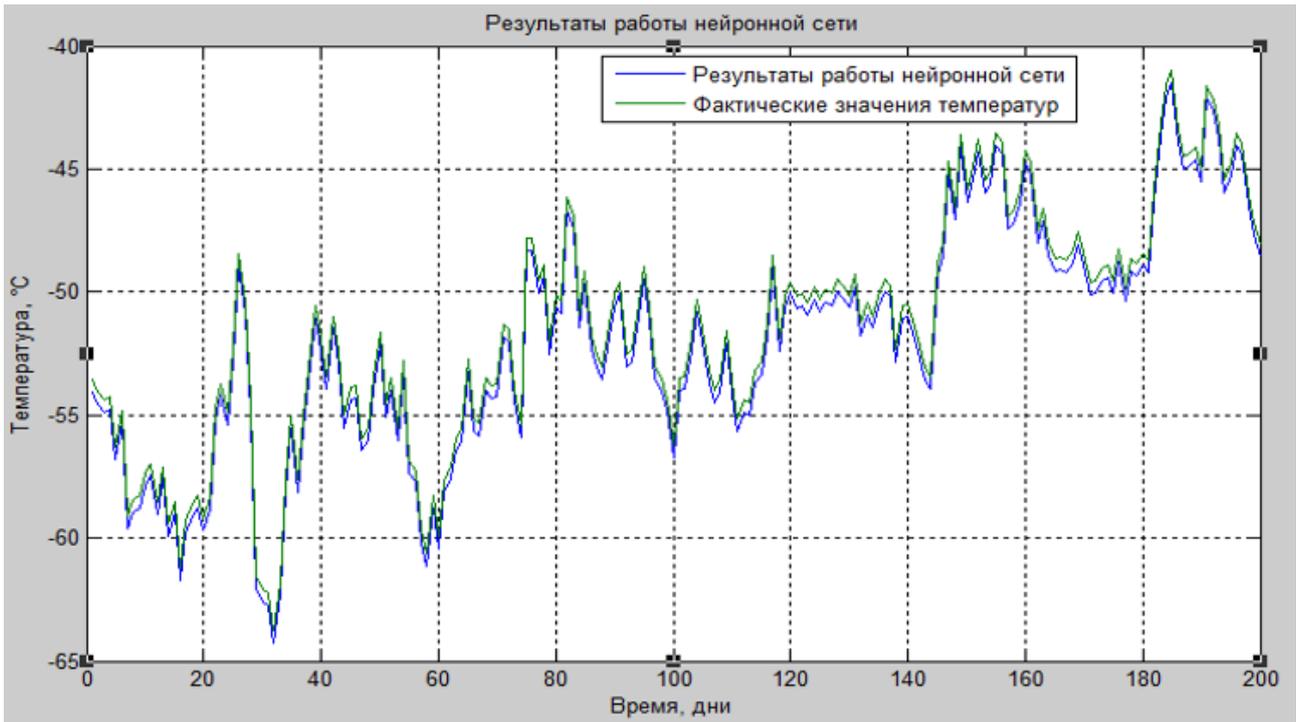


Рис. 8. Результаты работы нейронной сети (в узле сетки с координатами -70° северной широты; $2,5^\circ$ восточной долготы, значение геопотенциала 300 гПа). В качестве функций активации входного слоя использовалась функция «tansig», сигмоидальная функция «logsig» для скрытого слоя, для выходного слоя – функция «purelin»

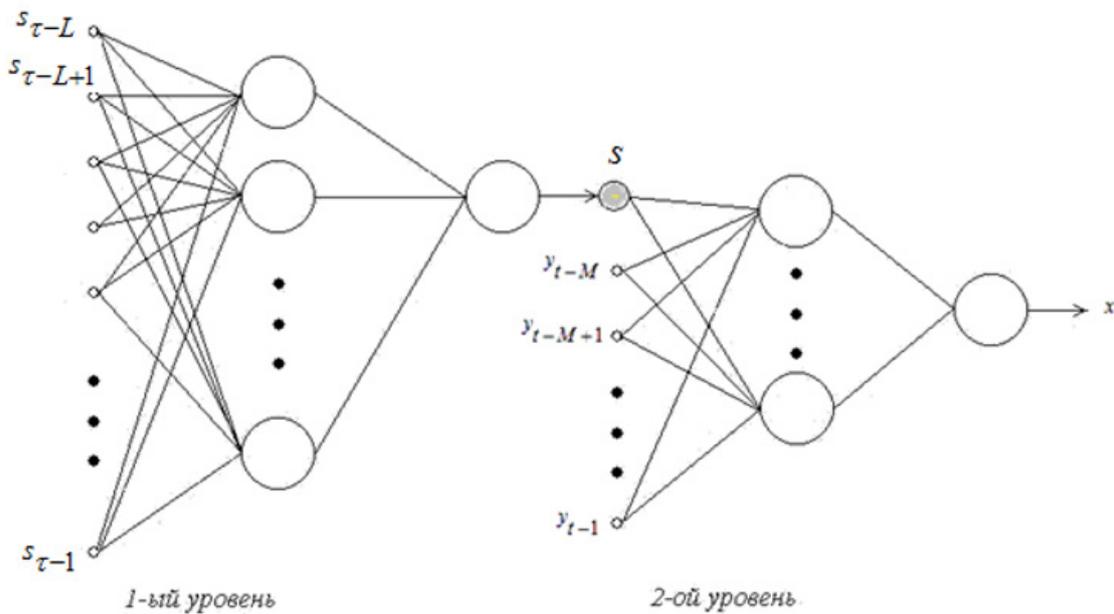


Рис. 9. Структура двухуровневой иерархической нейронной сети

$$s_\tau = \Phi(s_{\tau-1}) + \tilde{\xi}_\tau, \quad \tau = \varphi(t), \quad (14)$$

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

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

Таким образом, математическая модель исходного процесса может быть представле-

на как модель двух иерархически вложенных процессов. В случае решения задачи прогнозирования для модели (13) будем использовать двухуровневую иерархическую нейронную сеть, архитектура которой представлена на рис. 9.

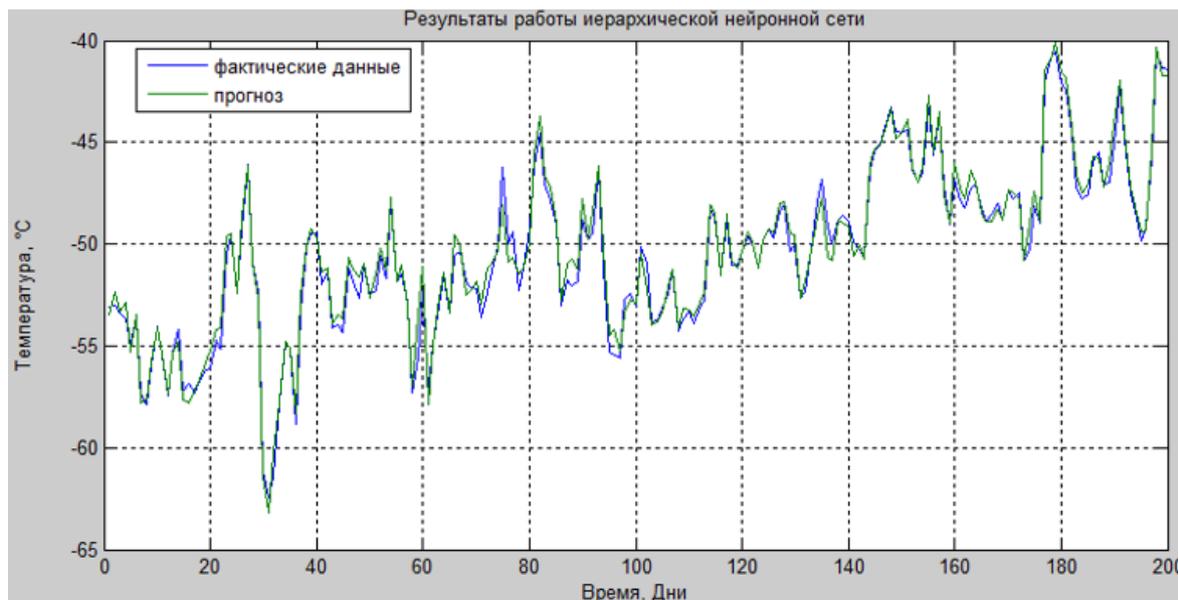


Рис. 10. Результаты работы иерархической нейронной сети

Первый иерархический уровень (так называемая «медленная нейронная сеть») предназначен для прогнозирования параметра s модели (14), который является корректирующим для векторов входа второго иерархического уровня. Таким параметром, например, в общем случае может быть коэффициент корреляции случайного процесса.

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 $s = (s_{\tau-L}, s_{\tau-L+1}, \dots, s_{\tau-1})^T$, $\tau > L$. Вектор выхода имеет длину $m = 1$, и, соответственно выходной вектор определяется как $s = s_{\tau}$.

Выходное значение сети первого иерархического уровня $s = s_{\tau}$ является дополнительным 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:

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

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 дополнительного параметра. Методика обучения иерархической нейронной сети, а также описание ее использования на примере метеоданных подробно представлено в [13].

Для экспериментальной апробации использовались те же статистические данные реанализа параметров атмосферы за 2008–2010 год, что и в случае исследования моделей варианта А. Рассматривались процессы изменения температуры при геопотенциале 300 ГПа в узле сетки с координатами -70° 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 слоями. 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. 10 представлена работа иерархической нейронной сети.

ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Таким образом, в результате построения и анализа моделей F и Φ в рассмотренных вариантах **A** (структура модели F – авторегрессия; структура модели Φ – искусственная нейронная сеть (ИНС)) и **B** (структура модели F – ИНС; структура модели Φ – ИНС) получились результаты, представленные в табл. 4. Для модели типа **A** был выбран «лучший» вариант из табл. 3.

Таблица 4

Сравнительный анализ работы моделей варианта **A** и **B**

Вид модели	R^2	MAPE
Вариант A (структура модели F – авторегрессия; структура модели Φ – искусственная нейронная сеть (ИНС))	0,96	2,2 %
Вариант B (структура модели F – ИНС; структура модели Φ – ИНС)	0,99	1,5 %

Результаты сравнения моделей, представленные в табл. 1 показывают небольшое преимущество работы иерархической нейронной сети.

В качестве итога, подчеркнем тот факт, что использование рассмотренных комбинированных моделей обоих вариантов является крайне эффективным инструментом моделирования нестационарных временных рядов с изменяющимися состояниями, а использование модели типа **B** повышает качество прогнозирования и позволяет модели в целом стать более устойчивой к случайным воздействиям.

СПИСОК ЛИТЕРАТУРЫ

1. Гребенюк Е. А. Методы анализа нестационарных временных рядов с неявными изменениями свойств / Е. А. Гребенюк // Автоматика и телемеханика, 2005. – №12. – С. 3–29.

2. Орлов Ю. Н. Моделирование и статистический анализ функционалов, заданных на выборках из нестационарного временного ряда / Ю. Н. Орлов, С. Л. Федоров // Препринты ИПМ им. М. В. Келдыша. – 2014. – № 43. – 26 с. URL: <http://library.keldysh.ru/preprint.asp?id=2014-43>

3. Макаренко А. В. Алгоритм сегментирования сигнала на квази-однородные фрагменты с использованием метода треугольно-призматического разложения / А. В. Макаренко // Известия вузов. Прикладная нелинейная динамика. – 2006. – № 4.

4. Орлов Ю. Н. Индикативные статистики для нестационарных временных рядов / Ю. Н. Орлов, Д. О. Шагов // Препринты ИПМ им. М. В. Келдыша. – 2011. – № 53. – 20 с. URL: <http://library.keldysh.ru/preprint.asp?id=2011-53>

5. Alfares H. K. Electric load forecasting: literature survey and classification of methods / H. K. Alfares, M. Nazeeruddin // International Journal of Systems Science. – 2002. – Vol 33. – P. 23–34.

6. Corduas M. Time series clustering and classification by the autoregressive metric / M. Corduas, D. Piccolo // Computational Statistics & Data Analysis. – 2008. – Vol. 52, no. 4. – P. 1860–1872.

7. Kini B. V. Large margin mixture of ar models for time series classification / B. V. Kini, C. C. Sekhar // Applied Soft Computing. – 2013. – Vol. 13, no. 1. – P. 361–371.

8. Kuznetsov M. P. Time series classification algorithm using combined feature description / M. P. Kuznetsov, N. P. Ivkin // Journal of Machine Learning and Data Analysis. – 2014. – Vol. 1, no. 11. – P. 1471–1483.

9. NCEP/DOEAMIPIIReanalysis. – URL: <http://www.cdc.noaa.gov/cdc/data.ncep.reanalysis2.html>.

10. 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.

11. Лукашин Ю. П. Адаптивные методы краткосрочного прогнозирования времен-

ных рядов / Ю. П. Лукашин. – М. : Финансы и статистика, 2003. – 415 с.

12. Буховец А. Г. Последовательное применение алгоритмов многомерной классификации / А. Г. Буховец // Многомерный анализ социологических данных (методические указания, алгоритмы и описания программ). – 1981. – М. : ИСИ АН СССР. – С. 24–73.

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

Сирота Е. А. – канд. физ.-мат. наук, доцент кафедры цифровых технологий, факультет компьютерных наук, Воронежский государственный университет.
E-mail: sirota_ea@sc.vsu.ru

13. Сирота Е. А. Прогнозирование нестационарных временных последовательностей на основе иерархических многослойных нейронных сетей / Е. А. Сирота // Журнал «Информационные технологии». – 2014. – № 1. – С. 67–71.

Matveev M. G. – doctor of technical sciences, professor department of programming and information technologies, Voronezh State University. 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