

6. **MacQueen J.** Some methods for classification and analysis of multivariate observations, LeCam L. M., Neyman J., eds. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*. University of California Press, vol. 1, 1967. P. 281–297.
7. **Ramasubramanian V., Paliwal K. K.** A generalized optimization of the k-d tree for fast nearest – neighbour search, *Proceedings Fourth IEEE Region 10 International Conference (TENCON'89)*, 1990. P. 565–568.
8. **Moore A. W.** The anchors hierarch: using the triangle inequality to survive high dimensional data, *Proceedings of the Twelfth Conference on Uncertainty in Artificial Intelligence*, 2000, pp. 397–405.
9. **Hodgson M. E.** Reducing computational requirements of the minimum-distance classifier, *Remote Sensing of Environments*, 1998, vol. 25, pp. 117–128.
10. **Elkan C.** Using the triangle inequality to accelerate k-means, *Proceedings of the Twelfth International Conference on Machine Learning*, AAAI, 2003, pp. 147–153.
11. **Gaffney S., Smyth P.** Joint probabilistic curve clustering and alignment / Saul L., Weiss Y., Bottou L., eds. *Proceedings of Neural Information Processing Systems (NIPS 2004), December 13–18, 2004, Vancouver, British Columbia, Canada*. Advances in Neural Information Processing Systems. V. 17. Cambridge, MA: MIT Press, 2005, pp. 473–480.
12. **Kukhareno B. G., Solntseva M. O.** Klasterizacia upravlyayemykh objektov na osnove shodstva ih mnogomernykh trajektoriy, *Informacionnye tehnologii*, 2014, no. 5. P. 3–7.
13. **Anjum N., Cavallaro A.** Trajectory clustering for scene context learning and outlier detection, Schonfeld D., Shan C., Tao D., Wang L., eds., *Video Search and Mining*, Berlin, Studies in Computational Intelligence. V. 287. Heidelberg: Springer, 2010, pp. 33–51.
14. **Kukhareno B. G., Solntseva M. O.** Pokomponentnyi discriminantnyi analiz rezultatov klasterizatsii mnogomernykh trajektoriy, *Informacionnye tehnologii*, 2014, no. 11, pp. 3–7.
15. **Kukhareno B. G., Solntseva M. O.** Iterativnaya klasterizatsiya trajektoriy upravlyayemykh objektov v mnogomernom prostranstve harakteristik, *Informacionnye tehnologii*, 2014, no. 8, pp. 11–16.
16. **Chen G., Lerman G.** Spectral curvature clustering (SCC), *International Journal on Computer Vision*, 2009, vol. 81, no. 3, pp. 317–330.
17. **Kukhareno B. G., Solntseva-Chalei M. O.** Spectralnyi metod s ispolzovaniem polyarnoi krivizny dlya analiza rezultatov klasterizatsii mnogomernykh trajektoriy, *Informacionnye tehnologii*, 2015, vol. 21, no. 12, pp. 901–905.
18. **Kukhareno B. G., Solntseva M. O.** Analiz rezultatov klasterizatsii mnogomernykh trajektoriy posredstvom modelei lineinykh dinamicheskikh sistem, *Informacionnye tehnologii*, 2015, no. 2, pp. 104–109.
19. **Kukhareno B. G., Solntseva-Chalei M. O.** Primenenie modelei nelineinykh dinamicheskikh sistem dlya analiza rezultatov klasterizatsii mnogomernykh trajektoriy, *Informacionnye tehnologii*, 2015, vol. 21, no. 5, pp. 341–345.
20. **Listgarten J., Neal R. M., Roweis S. T., Emili A.** Multiple alignment of continuous time series, Saul L. K., Weiss Y., Bottou L., eds. *Proceedings of Neural Information Processing Systems (NIPS 2004), December 13–18, 2004, Vancouver, British Columbia, Canada*. Advances in Neural Information Processing Systems. V. 17. Cambridge, MA: MIT Press, 2005. P. 5–13.
21. **Kukhareno B. G., Solntseva-Chalei M. O.** Primenenie modelei nepreryvnogo profilya dlya analiza rezultatov klasterizatsii mnogomernykh trajektoriy, *Informacionnye tehnologii*, 2015, vol. 21, no. 8, pp. 585–590.
22. **Galanin M. P., Scheglov I. A.** *Razrabotka i realizatsiya algoritmov trehmernoi triangulyatsii slognykh prostranstvennykh oblastei: pryamyie metody*, Preprint, Moscow M. V. Keldysh Institute of Applied Mathematics of the RAS, 2006.
23. **Torr P. H. S., Zisserman A.** MLESAC: A new robust estimator with application to estimating image geometry, *Journal of Computer Vision and Image Understanding*, 2000, vol. 78, no. 1, pp. 138–156.
24. **Kukhareno B. G.** Algoritmy analiza izobrazheniy dlya opredeleniya lokalnykh osobennosti i raspoznavaniya objektov i ponoram, *Informacionnye tehnologii*, 2011, no. 7, Prilogenie, pp. 1–32.
25. **Dempster A., Laird N. M., Rubin D. B.** Maximum likelihood from incomplete data via the EM algorithm, *Journal of the Royal Statistical Society B*, 1977, vol. 39, no. 1, pp. 1–38.

УДК 330.43

М. Г. Матвеев, д-р техн. наук, проф., зав. каф., e-mail: mgmatveev@yandex.ru,

Воронежский государственный университет,

В. В. Михайлов, д-р техн. наук, проф., нач. факультета, e-mail: VladimirMihailov36@gmail.com,
ВУНЦ ВВС "Военно-воздушная академия им. профессора Н. Е. Жуковского и Ю. А. Гагарина",

Е. А. Сирота, канд. физ.-мат. наук, доц. каф. цифровых технологий, e-mail: atoris@list.ru,

Воронежский государственный университет

Комбинированная прогностическая модель нестационарного многомерного временного ряда для построения пространственного профиля атмосферной температуры

Предлагается обоснование, построение и анализ комбинированной прогностической модели нестационарного многомерного временного ряда в целях построения пространственного профиля атмосферной температуры. Результаты моделирования показывают, что использование комбинированной модели с выделением кластеров однородной статистики для построения прогноза профиля атмосферной температуры может обеспечить приемлемые характеристики прогноза, а также может служить для построения вертикальных температурных профилей и, в конечном итоге, для составления рекомендаций при выполнении полетов авиации.

Ключевые слова: нестационарный многомерный временной ряд, прогностическая модель, метеорология, векторная авторегрессия, профиль атмосферной температуры, моделирование, классы однородной статистики

Введение и постановка задачи

Большинство количественных прогнозов в метеорологии, экономике, социологии, медицине основывается на моделях временных рядов, отражающих динамику переменных соответствующей предметной системы. Временные ряды, как правило, нестационарны, при этом нестационарность нельзя представить устойчивым систематическим изменением (линейным или нелинейным трендом) математического ожидания уровней ряда в течение длительного периода. Изменение характера тренда принято называть структурными разрывами [1] или разладкой [2]. Возникновение структурного разрыва может происходить скачкообразно или относительно медленно с явным переходным процессом, и обуславливается трудно контролируемым изменением состояния системы. Если механизм возникновения тренда имеет стохастический характер, т. е. рассматриваемый стохастический процесс относится к DS-процессам [1] и для моделирования используются "безфакторные" модели типа ARMA, то проблема построения прогностической модели становится нетривиальной.

Для решения этой проблемы в последние годы сложился подход, основанный на комбинировании моделей различных типов, что дает возможность компенсировать недостатки одних моделей достоинствами других, и повысить, в конечном счете, возможности прогнозирования. Одной из первых работ в этом направлении является работа [3], где предлагается выделять однородные в определенном смысле группы (кластеры) данных временного ряда и строить модели прогнозирования для каждой группы отдельно, что существенно повышает точность прогноза. Обзор различных комбинаций моделей предлагается в работе [4], где отмечается, что часто для кластеризации используют искусственные нейронные сети (ИНС), а для построения модели внутри кластера — модели типа ARMA. Действительно, авторегрессионные (AR) модели, при простоте и удобстве идентификации, не могут отображать нелинейные и нестационарные эффекты поведения временного ряда. Модели ИНС, наоборот, прекрасно справляются с отображением различных нелинейностей. От комбинации этих моделей можно ожидать хороших результатов.

Конкретная структура комбинированной модели определяется особенностями анализируемой предметной области и всегда является результатом соответствующего исследования. Цель предлагаемой статьи — построение комбинированной прогностической модели многомерного временного ряда атмосферной температуры для построения прогноза пространственного температурного профиля в горизонтальных слоях атмосферы. Динамика изменения атмосферной температуры во многом определяется состоянием атмосферы, характеризующимся множеством плохо контролируемых факторов и способным резко изменяться, обуславливая возникновение структурных разрывов.

Базовая идея построения комбинированной модели предполагает, что адекватное описание динамики температурных изменений можно представить модификацией модели векторной авторегрессии с переменными параметрами, характеризующими изменения состояний атмосферы. Нелинейные закономерности изменения параметров векторной авторегрессии могут быть описаны ИНС, входами которых являются какие-либо индикаторы состояний атмосферы.

Необходимая статистика обеспечивается данными реанализа, находящимися в открытом доступе в сети Интернет [5].

1. Основные допущения и методика построения комбинированной модели

В соответствии с данными реанализа [5] представим схему измерения температуры в виде сетки с нумерацией узлов $i = 1, \dots, n; j = 1, \dots, m$, показанной на рис. 1.

Временные ряды температур в узлах сетки коррелированы между собой. Корреляционный анализ показывает, что для большинства узлов статистически значимые оценки коэффициентов корреляции имеют временные ряды только в смежных узлах [6, 7]. Такие ряды целесообразно рассматривать как многомерный временной ряд, представленный в виде вектора температур смежных узлов сетки в момент времени t , например, $y(t) = (y_{i-1,j}(t); y_{i+1,j}(t); y_{i,j}(t); y_{i,j-1}(t); y_{i,j+1}(t))$. Тогда временной ряд температур в узле ij сетки взаимодействует со смежными рядами в узлах: $i-1, j; i+1, j; i, j-1; i, j+1$. В таком случае прогнозное значение температуры в $(t+1)$ -й момент времени — $y_{ij}^m(t+1)$ можно представить как взвешенное среднее компонент вектора $y(t)$ [8], т. е. для произвольного, но не граничного узла $ij, i = 2, \dots, n-1; j = 2, \dots, m-1$, можно записать следующее выражение:

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




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

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

Уравнения вида (1) можно записать для $d = n \times m - 2(n + m - 2)$ узлов сетки. Нетрудно заметить, что эти уравнения не образуют векторной авторегрессии в классическом понимании, они описываются следующим матричным уравнением: $y_{d \times 1}(t+1) = a_{d \times 1} + A_{d \times s} y_{s \times 1}(t)$, где $s = n \times m$.

Наличие нестационарности и структурных разрывов будем учитывать, рассматривая в модели (1) коэффициенты a_{ij} , $\forall i, j$ как переменные, изменяющиеся со временем t по некоторой изменяющейся закономерности. При этом нестационарность должна отражаться как закономерность изменения коэффициентов, а структурные разрывы — как изменения этой закономерности. Для того чтобы оценить эти закономерности необходимо на множестве статистических температурных данных научиться строить сегменты квазиоднородных температур, соответствующие определенному квазипостоянному состоянию атмосферы. В каждом из этих сегментов будет определяться свой тип нестационарности, задаваемый соответствующими постоянными значениями a_{ij} .

Для сегментации уровней ряда необходим, по крайней мере, один измеримый информационный индикатор, рассматриваемый как характеристика состояния атмосферы. Будем считать, что состояние атмосферы характеризуется динамикой ее переходных процессов, это очевидно находит отражение в динамике изменения атмосферной температуры. Тогда, в качестве информационного индикатора или критерия однородности можно принять изменения температуры по координатам сетки, вычисляемые как вектор центральных разностей в каждом узле пространственной сетки $\Delta_{ij} = (\delta_i; \delta_j)$, где $\delta_i = y_{i+1,j} - y_{i-1,j}$; $\delta_j = y_{i,j+1} - y_{i,j-1}$. Задача состоит в выделении таких сегментов временного ряда (1), у которых значения критерия Δ примерно равны, а значит сохраняются основные динамические закономерности в атмосфере. Такая задача относится к классу задач апостериорной сегментации [9]. Каждой измеренной температуре $y_{ij}(t)$ в однозначное соответствие ставится значение критерия $\Delta_{ij}(t)$. Будем понимать под качественной однородностью совокупности данных сходство всех элементов этой совокупности по какому-либо признаку и несходство по всем остальным. Тогда можно говорить, что уровни $y_{ij}(t_n)$ и $y_{kl}(t_m)$ качественно однородны, если им соответствуют близкие значения $\Delta_{ij}(t_n)$ и $\Delta_{kl}(t_m)$.

На длинных рядах температурная динамика претерпевает изменения с многократными повторами состояний. Сегменты, соответствующие таким повторам, могут объединяться в однородные кластеры. Необходимо учитывать, что четких границ у сегментов быть не может в силу приблизительности наших представлений о неизменности закономер-

ностей динамики, следовательно априори неизвестно и число сегментов. Поэтому от задачи сегментации, где время выполняет функцию упорядочения данных в узлах сетки и присутствует в явном виде, мы переходим к задаче построения кластеров температур неупорядоченных как по времени, так и по узлам сетки и однородных в смысле критерия Δ , на множестве измерений в различные моменты времени t во всех узлах регулярной сетки. Однако в каждом узле и в каждый момент времени соответствия, определяемые уравнением (1), запоминаются, т. е. запоминается соответствие

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

Для построения кластеров воспользуемся алгоритмом многомерной классификации [10], основанном на выделении областей с локальной "плотностью" точек признакового пространства Δ . В качестве меры "локальной плотности" предлагается функция принадлежности $f(\Delta_{ij}, \Delta, R) = |\eta(\Delta_{ij}, \Delta, R)|$ — число точек, попавших в гиперсферу заданного радиуса R с центром в точке Δ_{ij} ; η — множество точек гиперсферы заданного радиуса R с центром в точке Δ_{ij} . В соответствии с алгоритмом [8] определяются локальные максимумы функции принадлежности и соответствующие точки объявляются модами классов локальной "плотности". Полученное разбиение является оптимальным в том смысле, что выделяются все унимодальные множества и полностью реализуется их разделение.

Каждый кластер с номером k можно рассматривать как статистическую совокупность значений температур y_i^k , $i = 1, \dots, n_k$, где n_k — объем совокупности с качественной однородностью, наличием вариаций и возможностью нахождения статистических оценок. В частности, можно найти оценку среднего совокупности $\bar{y}^k = \frac{\sum y_i^k}{n_k}$ и ввести центрированную случайную переменную

$$x^k = \{x_i^k\} = \{y_i^k - \bar{y}^k\} \quad (2)$$

с нулевым средним.

На основании запомненного соответствия S и замены переменных (2) для каждого кластера k можно записать новые соответствия

$$SC: \{x_{ij}^k(t+1)\} \rightarrow \{(x_{ij}^k(t); x_{i-1,j}^k(t); x_{i+1,j}^k(t); x_{i,j-1}^k(t); x_{i,j+1}^k(t))\}$$

между центрированными переменными в виде следующих уравнений:

$$x_{ij}^k(t+1) = b_1^k x_{ij}^q(t) + b_2^k x_{i-1,j}^r(t) + b_3^k x_{i+1,j}^p(t) + b_4^k x_{i,j-1}^s(t) + b_5^k x_{i,j+1}^d(t) + \xi_{ij}^k(t+1), \quad (3)$$

**Оценки параметров модели (3)
для кластеров с однородной статистикой**

Но- мер клас- тера	b_1^k	b_2^k	b_3^k	b_4^k	b_5^k	R^2
K_1	-9,29824	1,01641	0,0991023	5,34475	3,8321	0,890
K_2	-7,1782	1,03939	-0,0143984	4,25046	2,90878	0,901
K_3	-2,80172	0,840422	0,026325	2,37757	0,554852	0,911
K_4	-5,95311	1,05258	0,146581	3,20532	2,54854	0,899
K_5	-8,37952	1,03208	0,141075	4,8547	3,34873	0,888
K_6	-5,92641	0,916967	0,0381898	3,57287	2,40352	0,908
K_7	-4,68736	0,851404	0,0612615	3,14575	1,62743	0,911
K_8	-8,69499	0,702887	0,149402	5,07142	3,77392	0,880
K_9	-5,28913	0,970231	0,0810225	3,13149	2,1009	0,919
K_{10}	-6,07191	0,925191	0,0958082	3,62117	2,42331	0,910

где $x_{ij}^k(t) = y_{ij}^k(t) - \bar{y}^k$, $k = 1, \dots, m$; m — число кластеров; $k, q, r, p \in N$ — множество номеров кластеров. Следует обратить внимание на то, что центрированные уровни ряда в правой части уравнения (3), вообще говоря, необязательно принадлежат кластеру с номером k .

Оценки коэффициентов b^k в уравнении (3) можно находить с помощью метода наименьших квадратов: $b^k = (X^{kT} X^k)^{-1} X^{kT} x^k$, где X^k — матрица наблюдений факторов, которая формируется на основе запомненных соответствий SC; x^k — вектор наблюдений объясняемой переменной.

Каждому кластеру в функциональное соответствие можно поставить вектор коэффициентов уравнения (3) $b^k = (b_1^k; b_2^k; b_3^k; b_4^k; b_5^k)$, $k = 1, \dots, m$:

$$F: \{\bar{\Delta}^k(x^k)\} \rightarrow \{b^k\}, \quad (4)$$

где $\{\bar{\Delta}^k(x^k)\}$ — среднее значение классификационного критерия в k -м кластере. Дискретное соответствие F в каждом кластере можно аппроксимировать непрерывной зависимостью $b(x) = (b_1, \dots, b_5)$ и построить систему моделей

$$x_{ij}(t+1) = b_1(x)x_{ij}(t) + b_2(x)x_{i-1,j}(t) + b_3(x)x_{i+1,j}(t) + b_4(x)x_{i,j-1}(t) + b_5(x)x_{i,j+1}(t) + \xi_{ij}^k(t+1), \\ i = 2, \dots, n-1; j = 2, \dots, m-1, \quad (5)$$

описывающую многомерный нестационарный временной ряд со структурными разрывами. Если в качестве аппроксиматора принять искусственную нейронную сеть (ИНС) $F_{\text{ИНС}} = b(x)$, то получим искомую комбинированную модель.

2. Экспериментальное исследование комбинированной модели

Для построения и экспериментальной апробации комбинированной модели использовали статистические данные реанализа параметров атмосферы [5], приведенные к среднесуточным значениям. Рассматривали процессы изменения температуры при геопотенциале 300 ГПа в узлах регулярной сетки от 0 до 180° восточной долготы и от 40 до 70° северной широты с шагом 2,5°.

Согласно алгоритму кластеризации было выделено 1800 кластеров однородных данных в смысле критерия Δ , 1118 из которых оказались репрезентативны. Основная сложность формирования кластеров заключалась в построении и запоминании взаимных соответствий внутри каждой пары точек на большом объеме входных данных (284 284 точки). Для осуществления таких объемов вычислений использовали 24-процессорный параллельный компьютерный кластер высокой производительности.

Параметры модели (5) определяли с использованием МНК. Было построено 1118 авторегрессионных уравнений, номера которых соответствуют номерам кластеров. Оценки соответствующих векторов параметров b^k , например, для первых 10 кластеров представлены в таблице, где кластеры обозначены номерами K_1 — K_{10} , R^2 — коэффициент детерминации.

Оценку характера изменения параметров отдельно для каждого класса выполнял универсальный аппроксиматор — многослойный перцептрон, с вектором входа $x = (x_{i-1,j}; x_{i+1,j}; x_{j-1}; x_{j+1})$ и вектором выхода $b(x)$. Для обучения был использован трехслойный перцептрон с четырьмя нейронами входного слоя, четырьмя нейронами скрытого слоя и пятью нейронами выходного слоя. Для обучения сети использовали инструментальную среду MATLAB 10. В качестве функций активации входного и скрытого слоев использовалась сигмоидальная функция "logsig", для выходного слоя — линейная функция "purelin". Обучение ИНС проводилось с помощью алгоритма Levenberg-Marquardt ("trainlm").

Результаты моделирования оценивали на контрольной выборке температурных данных. На рис. 2 (см. третью сторону обложки) представлены результаты работы нейронной сети — график прогноза и реальных температурных наблюдений.

По оси абсцисс — номера 800 узлов, расположенные в линейном порядке, по оси ординат — значения прогноза и реальных температурных наблюдений.

Если расположить те же точки в соответствии с их географическими координатами, получим графики поверхностей реальных температурных показаний (рис. 3, см. третью сторону обложки) и результатов моделирования (рис. 4, см. третью сторону обложки). На рис. 3 плоскость XOY соответствует значениям географических координат, по оси Z отложены значения реальных температурных показаний (°C).

На рис. 4 плоскость XOY соответствует значениям географических координат, по оси Z отложены

значения результатов моделирования температурных показаний ($^{\circ}\text{C}$).

В качестве показателя эффективности модели использовали коэффициент детерминации R^2 и показатель процентной погрешности прогноза MAPE:

$$\text{MAPE} = \frac{1}{T} \sum_{t=1}^T \left| \frac{x(t) - \hat{x}(t)}{x(t)} \right| \cdot 100 \%, \quad (6)$$

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

В нашем случае R^2 получился равным 0,9105, MAPE — 3,4 %.

Заключение

Результаты моделирования показали, что использование комбинированной модели с выделением кластеров однородной статистики для построения прогноза профиля атмосферной температуры может обеспечить приемлемые характеристики прогноза. Ранее проведенные исследования при моделировании поведения временного ряда в одном узле, результаты сравнительного анализа которых представлены в работе [7], позволяют сделать вывод о возможности построения прогноза температурного профиля по множеству узлов пространственной сетки с точностью не ниже точности прогнозирования атмосферной температуры в одном, отдельно моделируемом узле. Полученные результаты могут быть использованы для построения вертикальных

температурных профилей и, в конечном итоге, для составления рекомендаций при выполнении полетов авиации.

Список литературы

1. Гребенюк Е. А. Методы анализа нестационарных временных рядов с неявными изменениями свойств // Автоматика и телемеханика. 2005. № 12. С. 3—29.
2. Орлов Ю. Н., Шагов Д. О. Индикативные статистики для нестационарных временных рядов / Препринты ИПМ им. М. В. Келдыша. 2011. № 53. 20 с.
3. Fogler H. R. A pattern recognition model for forecasting // Management science. 1974. N. 8. P. 1178—1189.
4. Alfarcos H. K., Nazeeruddin M. Electric load forecasting: literature survey and classification of methods // International Journal of Systems Science. 2002. Vol. 33. P. 23—34.
5. NCEP/DOE AMIP II Reanalysis [Электронный ресурс]. URL: <http://www.cdc.noaa.gov/cdc/data.ncep.reanalysis2.html>.
6. Матвеев М. Г., Михайлов В. В., Семенов М. Е., Сирота Е. А. Модель анализа динамики векторного метеорологического процесса // Вестник ВГУ. Серия "Системный анализ и информационные технологии". 2013. № 1. С. 89—94.
7. Матвеев М. Г., Сирота Е. А. Разработка и исследование статистических моделей нестационарного многомерного временного ряда атмосферных температур в условиях неоднородности // Информационные технологии. 2014. № 12. С. 20—24.
8. Лукашин Ю. П. Адаптивные методы краткосрочного прогнозирования временных рядов. М.: Финансы и статистика, 2003. 415 с.
9. Тищенко А. К., Плисс И. П. Сегментация многомерных нестационарных временных рядов с помощью метода нечеткой кластеризации // Восточно-Европейский журнал передовых технологий. 2012. Т. 4. № 4 (58). С. 22—25.
10. Буховец А. Г. Последовательное применение алгоритмов многомерной классификации. Многомерный анализ социологических данных (методические указания, алгоритмы и описание программ). М.: ИСИ АН СССР, 1981. С. 24—73.

M. G. Matveev, Ph. D., Professor, Voronezh State University;

V. V. Mihailov, Ph. D., Professor, Air Force Academy

named after Professor N. E. Zhukovsky and U. A. Gagarin,

E. A. Sirota, Ph. D. Associate Professor, atoris@list.ru, Voronezh State University

Combined Forecasting Model of Non-Stationary Multivariate Time Series for the Construction of the Spatial Profile of Atmospheric Temperature

In this paper we study, construction and analysis of a combined forecast model of non-stationary multivariate time series in order to build the spatial profile of atmospheric temperature.

The basic idea of constructing a combined model suggests that an adequate description of the dynamics of changes in temperature can be represented by modifying vector autoregression model with variable parameters characterizing changes in the state of the atmosphere. Non-linear patterns of change in the parameters of vector autoregression can be described by the INS, the inputs of which are any indication states of the atmosphere.

The simulation results showed that the use of combined model with the release of clusters of homogeneous statistics for the forecast profile of atmospheric temperature can provide acceptable performance forecast.

Earlier studies in modeling the behavior of the time series in one unit suggest the possibility of constructing the forecast temperature profile across multiple nodes of spatial grid with an accuracy of not less than the prediction of atmospheric temperature in one, separately simulated node. The results can be used to construct vertical temperature profiles and, ultimately, to make recommendations in the performance of aviation.

Keywords: multi-dimensional non-stationary time series forecasting model, meteorology, vector autoregression, profile atmospheric temperature, modeling classes homogeneous statistics

References

1. Grebenyuk E. A. Metody analiza nestacionarnykh vremennykh ryadov s neyavnymi izmeneniyami svoystv, *Avtomatika i telemekhanika*, 2005, no. 12, pp. 3–29.
2. Orlov Yu. N., Shagov D. O. *Indikativnye statistiki dlya nestacionarnykh vremennykh ryadov*, Preprinty IPM im. M. V. Keldysha, 2011, no. 53, 20 p.
3. Fogler H. R. A pattern recognition model for forecasting, *Management science*, 1974, no. 8, pp. 1178–1189.
4. Alfares U. K., Nazeeruddin M. Electric load forecasting: literature survey and classification of methods, *International Journal of Systems Science*, 2002, vol. 33, pp. 23–34.
5. NCEP/DOE AMOP II Reanalysis [Elektronnyy resurs], URL: <http://www.cdc.noaa.gov/cdc/data.ncep.reanalysis2.html>.
6. Matveev M. G., Mihajlov V. V., Semenov M. E., Sirota E. A. Model' analiza dinamiki vektornogo meteorologicheskogo processa *Vestnik VGU, seriya "Sistemnyy analiz i informacionnye tekhnologii"*, 2013, no. 1, pp. 89–94.
7. Matveev M. G., Sirota E. A. Pazpabotka i issledovanie statisticheskikh modelej nestacionapnogo mnogomernogo vremennoy ryada atmosferynykh temperatuy v usloviyah neodnopolnosti, *Informacionnye tekhnologii*, 2014, no. 12, pp. 20–24.
8. Lukashin Yu. P. Adaptivnye metody kratkosrochnogo prognozirovaniya vremennykh ryadov, Moscow, Finansy i statistika, 2003, 415 p.
9. Tishchenko A. K., Pliss I. P. Segmentatsiya mnogomernykh nestacionarnykh vremennykh ryadov s pomoshch'yu metoda nechetkoj klasterizatsii, *Vostochno-Evropejskiy zhurnal peredovykh tekhnologii*, 2012, vol. 4, no. 4 (58). P. 22–25.
10. Buhovec A. G. *Posledovatel'noe primenenie algoritmov mnogomernoy klassifikatsii, Mnogomernyy analiz sociologicheskikh dannykh (metodicheskie ukazaniya, algoritmy i opisaniya programm)*, 1981, Moscow, ISI AN SSSR, pp. 24–73.

УДК 519.857

В. И. Струченков, д-р техн. наук, проф., e-mail: str1942@mail.ru,
Московский государственный университет информационных технологий,
радиотехники и электроники (МИРЭА)

Динамическое программирование в задачах планирования реализации частично возобновляемых ресурсов

Рассматривается задача составления оптимального поэтапного плана использования частично возобновляемого однородного ресурса в течение заданного времени. Анализируются различные модели целевой функции как разности дохода от использования ресурса или его части и сопутствующих затрат. Для простых моделей на основе анализа решения задачи с помощью метода динамического программирования получены расчетные формулы, что позволяет избежать перебора вариантов пошаговых решений.

Ключевые слова: ресурс, целевая функция, множество состояний, динамическое программирование, оптимальный путь

Введение

Для классической задачи оптимального распределения заданного количества некоторого однородного ресурса [1] известны метод динамического программирования [2] и его новые реализации, усовершенствованные за счет использования множеств Парето [3] и комбинации динамического программирования с методом ветвей и границ [4]. При этом заданное начальное количество ресурса на каждом этапе могло только уменьшаться.

Однако динамическое программирование можно применить и в задачах распределения частично возобновляемых ресурсов. Например, промысловая рыба, морские животные и вообще "население" лесов, морей, озер и рек являются частично возобновляемыми природными ресурсами. Возникает задача оптимального использования таких ресурсов, т. е. планирования их добычи на ряд лет вперед, с тем чтобы обеспечить максимальную прибыль за все время планирования и сохранить минимально необходимый объем ресурса. Если в начале планируемого периода объем ресурса несущественно превышает заданный минимум, то решение задачи может показаться тривиальным: ежегодно брать у

природы только прирост ресурса и не более того. Однако это решение не очевидно, если учесть, что при сохранении неприкосновенности ресурса через несколько лет можно взять больше, чем при ежегодном изъятии прироста.

Кроме возобновляемых природных ресурсов возможны и другие процессы, в которых ресурс не только расходуется, но и частично возобновляется.

Цель настоящей статьи состоит в анализе некоторых моделей подобной задачи и алгоритмов ее решения по методу динамического программирования.

Постановка задачи

Задача состоит в следующем: в начальный момент времени имеется заданное количество частично возобновляемого ресурса b_1 .

Заданный период планирования T (например, $T = 10$ лет) разбивается на этапы, например годы или месяцы. Для определенности примем годы и будем считать, что планирование начинается с года номер один. Тогда период планирования, номер последнего года и число лет — это одно и то же число T .

При реализации x единиц ресурса в течение года доход равен $d(x)$, а сопутствующие затраты в тече-