

УДК 681.3

DOI: 10.26102/2310-6018/2019.25.2.023

Я.Е. Львович, А.В. Питолин, Г.П. Сапожников
**МНОГОМЕТОДНЫЙ ПОДХОД К МОДЕЛИРОВАНИЮ СЛОЖНЫХ
СИСТЕМ НА ОСНОВЕ АНАЛИЗА МОНИТОРИНГОВОЙ
ИНФОРМАЦИИ**

*Воронежский институт высоких технологий
Воронежский государственный технический университет
Российский новый университет*

В статье обоснована необходимость построения разных классов математических моделей сложных систем и актуальности многометодного подхода к обработке и моделированию мониторинговой информации, обусловленного разнообразием задач оптимизации управления на примере некоммерческой образовательной организации (НОО) в сочетании с рейтинговым управлением. Исходными являются предварительно редуцированные множества входных показателей, влияющих на выходные показатели функционирования объекта управления. В основу положено прогнозирование временных рядов на основе аддитивных и элементарных функций. Зависимость выходных показателей от входных определяются регрессионной моделью с включением в число переменных времени. Для повышения точности прогнозирования с целью принятия управленческих решений при определенном горизонте планирования осуществлен переход от регрессионной модели к нейросетевой. Предложена процедура трансформации в статистические выборки исходных временных рядов их прогностических оценок с последующим рандомизированным формированием обучающей выборки. Показано, что многометодный подход к моделированию обеспечивает решение комплекса задач управления ресурсоэффективностью сложных систем.

Ключевые слова: прогнозирование, моделирование, управление, ресурсоэффективность, рандомизация.

Введение.

Одной из главных целей управления в социальных и экономических системах является повышение ресурсоэффективности их функционирования. Достижение этой цели традиционно стремятся обеспечить в рамках административного управления. При административном управлении, основанном на экспертном анализе предыдущего опыта, логических и интуитивных заключениях, не удастся учесть все возникающие взаимосвязи факторов, которые влияют на целевые установки. Тем более возникает неопределенность в достижении наилучшего показателя результата по комплексному показателю ресурсоэффективности. Возникает риск принятия решений, далеких от оптимальных.

Современные механизмы цифровизации, основанные на информационном мониторинге показателей деятельности сложных систем,

создают предпосылки для интеллектуализации процесса принятия управленческих решений. При этом первичной является задача трансформации цифровых данных мониторинга путем идентификации структуры и параметров моделей, характеризующих зависимость ресурсоэффективности от мониторируемых показателей и времени наблюдения. Обычно для решения указанной задачи выбирается один из классов моделей: прогностических на основе анализа временных рядов [1,2], регрессионные [3], нейросетевые [4,5]. Однако, необходимость решения комплекса задач управления, которые связаны как с перспективным планированием повышения ресурсоэффективности, так и с распределением ресурса между управляющими факторами, способствующим такому повышению, определяет потребность в использовании всего спектра перечисленных моделей. В связи с этим возникает необходимость в развитии многометодного подхода к моделированию сложных систем на основе анализа мониторинговой информации с ориентацией на интеллектуализацию принятия управленческих решений. При этом требуется обеспечить радикальное сочетание ретроспективной, прогностической и экспертной информации, что влияет не только на особенности выбора структуры и параметров моделей, но и методов их идентификации. Предлагается следующая этапность реализации многометодного подхода.

Постановка задачи.

Первоочередной задачей в достижении интеллектуализации управления является разработка процедур обработки данных мониторингового оценивания. Возможность фиксации данных за период наблюдения $t = \overline{1, T}$ позволяет рассматривать их как случайные процессы и провести редукцию показателей по значимости для оптимизации ресурсоэффективности.

Предварительная редукция показателей мониторингового оценивания по значимости для оптимизации ресурсоэффективности ($E(t)$) позволяет в качестве исходной информации для последующей обработки и построения зависимостей, необходимых при постановке оптимизационных задач использовать следующие случайные процессы:

показателей, влияющих на изменения доходов НОО $C(t)$

$$y_{j_1^*}(t), j_1^* = \overline{1, J_1^*}; \quad (1)$$

показателей, влияющих на изменения расходов НОО $Z(t)$

$$y_{j_2^*}(t), j_2^* = \overline{1, J_2^*}. \quad (2)$$

Важную роль в принятии оптимальных управленческих решений играют объемы затрат, способствующие увеличению доходов и повышению ресурсоэффективности

$$z'_{j_3}, j_3 = \overline{1, J_3}, \quad (3)$$

где $j_3 = \overline{1, J_3}$ – направления, которые способствуют увеличению доходов и повышению ресурсоэффективности (маркетинговая деятельность, поисковые научные исследования, создание стартапов и т.п.).

При этом $\sum_{j_3}^{J_3} z'_{j_3} = z'$ – дополнительные затраты.

Эти же показатели влияют на положение вуза в рейтинге $r_l, l = \overline{1, L}$.

Для исследуемого объекта управления случайные процессы (1) – (3) будут входными процессами, а выходными $C(t), Z(t), E(t), l = \overline{1, L}$ (Рисунок 1). На основе случайных процессов вычисляются значения ресурсоэффективности в моменты времени $t = \overline{1, T}$

$$E(t) = \Psi_E(C(t), Z(A)). \quad (4)$$

Рассматривая случайные процессы (1)-(3), (4) как временные ряды [1] построим для них прогностические модели:

$$y_{j_1}^*(t) = f_{j_1}^*(t); y_{j_2}^*(t) = f_{j_2}^*(t); z_{j_3}^*(t) = f_{j_3}^*(t); \quad (5)$$

$$C(t) = f_c(t); Z(t) = f_z(t); E(t) = f_E(t); r_e(t) = f_{r_e}(t). \quad (6)$$

Успешность решения задачи прогнозирования с использованием моделей (5), (6) зависит от обоснованности выбора метода ее решения с учетом объема и качества информации о прогнозируемом процессе [2].

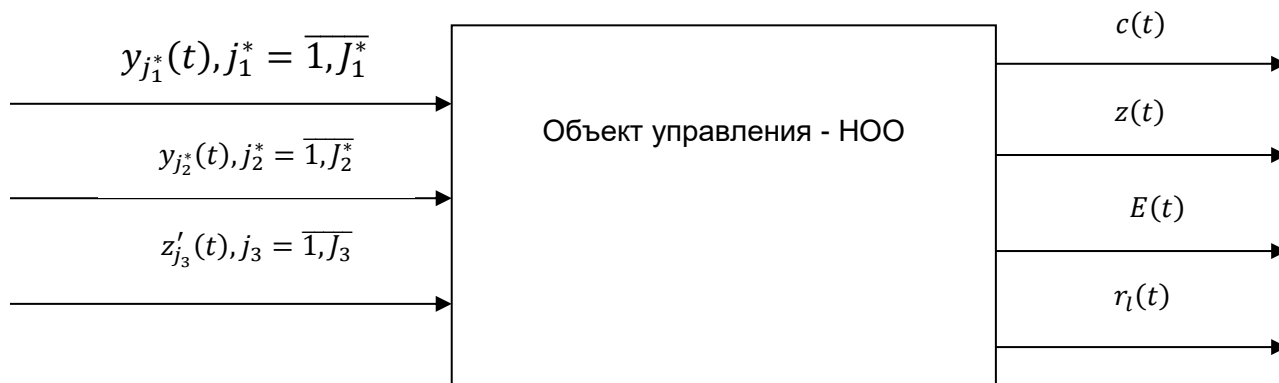


Рисунок 1- Временные ряды редуцированной мониторинговой информации, определяющие входные и выходные показатели функционирования объекта управления – НОО

Многометодный метод построения моделей сложных систем на основе мониторинговой информации

Предлагается применить многометодный подход, который позволяет использовать для построения моделей $f(y, t)$ целый ряд способов выбора их

структуры и определения параметров с целью обеспечения компромисса между точностью и вычислительной трудоемкостью прогнозирования. В рамках этого подхода остановимся на анализе отмеченных выше показателей в случае применения следующих структур моделей.

1. Аддитивная функция

$$f(y, t) = \sum_{g=1}^G a_g \varphi_g(t), \quad (7)$$

где $\varphi_g(t)$ – временные функции простейшего вида;

a_g – неизвестные параметры.

При сравнении показателей прогнозирования используем степенные временные функции

$$\varphi_g(t) = t^{gp},$$

где $p \geq 0$ – параметр, который выбирается из набора положительных чисел, целых или дробных, задаваемых при проведении сравнительного анализа. При этом параметры $a_g, g = \overline{1, G}$ целесообразно определять методом наименьших квадратов [2].

2. В виде элементарных функций:

линейная

$$f(y, t) = at; \quad (8)$$

квадратичная

$$f(y, t) = a_0 + a_1 t + a_2 t^2; \quad (9)$$

показательная

$$f(y, t) = a_1 e^{a_2 t}. \quad (10)$$

Параметры этих функций определяются методом экспоненциального сглаживания [2]. Полученные прогностические модели используются совместно с моделями (7) при проведении сравнительного анализа по показателям точности и трудоемкости. В результате выбирается окончательная прогностическая модель для каждого временного ряда (5), (6).

Многометодный подход предусматривает не только выбор структуры и параметров прогностических моделей (7)-(10), которые представляют собой функции времени на интервале $t = \overline{1, T}$, и позволяют определять их значения при заданном горизонте планирования деятельности НОО $T + t_1, t_1 = \overline{1, T_1}$. Кроме этого требуются представить зависимость временных

рядов (6) от временных рядов (5). С этой целью используем уравнения регрессии с включением в число переменных времени t [3]:

$$c = \varphi_c(y_{j^*1}, z'_{j_3}, t), \quad (11)$$

$$z = \varphi_z(y_{j^*2}, z'_{j_3}, t), \quad (12)$$

$$E = \varphi_E(c, z) = \varphi_E(y_{j^*1}, y_{j^*2}, z'_{j_3}, t), \quad (13)$$

$$r_l = \varphi_{rl}(y_{j^*1}, y_{j^*2}, z'_{j_3}, t). \quad (14)$$

Модели (11-14) позволяют вычислять для заданного горизонта планирования $t_1 = \overline{1, T_1}$ значения $C(t_1), z(t_1), E(t_1)$, предварительно вычисляя по моделям (5) $y_{j^*1}(t_1), y_{j^*2}(t_1), z'_{j_3}(t_1)$. Однако, при таком подходе точность прогнозирования снижается при расширении горизонта планирования, так как регрессионные уравнения с заданной точностью описывают зависимости (11)-(14) только на интервале $t = \overline{1, T}$.

Для преодоления этого недостатка регрессионного прогнозирования предлагается перейти к процедуре прогнозирования на основе нейросетевой модели [4] с рандомизацией исходных данных на интервале $t = \overline{1, T}$ и данных прогноза на интервале $T + t_1, t_1 = \overline{1, T_1}$ при выборе обучающей и верификационной выборок случайных величин $C, Z, E, r_l, y_{j^*1}, y_{j^*2}, z'$ [5].

Указанная процедура предусматривает выполнение следующих шагов применительно к зависимостям:

$$C = \varphi_c(y_{j^*1}, z'), z = \varphi_z(y_{j^*2}, z'), E = \varphi_E(y_{j^*1}, y_{j^*2}, z'), \quad (15)$$

$$r_l = \varphi_{rl}(y_{j^*1}, y_{j^*2}, z').$$

1. Трансформация исходных значений временных рядов на интервале $t = \overline{1, T}$, объединенных с прогностическими оценками на интервале $t = T + t_1, t_1 = \overline{1, T_1}$ в рамках общего интервала $t = \overline{1, T + T_1}$ в статистические выборки случайных величин:

$$\tilde{y}_{j_1^*} = (y_{j_1^*}(1), \dots, y_{j_1^*}(T), \dots, y_{j_1^*}(T + t_1)), j_1^* = \overline{1, J_1} \quad (16)$$

$$\tilde{y}_{j_2^*} = (y_{j_2^*}(1), \dots, y_{j_2^*}(T), \dots, y_{j_2^*}(T + t_1)), j_2^* = \overline{1, J_2} \quad (17)$$

$$\tilde{z}_{j_3^*} = (z'_{j_3}(1), \dots, z'_{j_3}(T), \dots, z'_{j_3}(T + t_1)), \quad (18)$$

$$\tilde{C} = (C(1), \dots, C(T), \dots, C(T + t_1)), \quad (19)$$

$$\tilde{Z} = (Z(1), \dots, Z(T), \dots, Z(T + t_1)), \quad (20)$$

$$\tilde{E} = (E(1), \dots, E(T), \dots, E(T + t_1)), \quad (21)$$

$$\tilde{r}_l = (r_l(1), \dots, r_l(T), \dots, r_l(T + t_1)), \quad (22)$$

где \sim – обозначение выборки значений случайного числа.

2. Выбор рандомизированным способом из общего интервала $t = \overline{1, T + T_1}$ значений t , для которых соответствующие им значения из выборок (16) – (22) включаются в обучающую выборку для построения нейросетевых моделей (15).

Заменим дискретные значения t на случайные дискретные значения \tilde{t} с равномерным законом распределения:

$$P(\tilde{t} = t) = p_t = \frac{1}{T + T_1},$$

где $P(\cdot)$ – обозначение вероятности.

Далее генерируем случайное число $\tilde{\xi}$ равномерно распределенное на интервале $[0,1]$ [6].

Сравниваем p_1 с $\tilde{\xi}$:

если $\tilde{\xi} \leq p_1$, то в обучающую выборку включаются значения из (16)-(22) при $t = 1$, в противном случае осуществляется сравнение $p_1 + p_2$ с $\tilde{\xi}$:

если $\tilde{\xi} \leq p_1 + p_2$, то в обучающую выборку включается значения из (16)-(22) при $t = 2$, в противном случае осуществляется сравнение $p_1 + p_2 + p_3$ с $\tilde{\xi}$ и т.д.

В том случае, когда при генерации выпадает значение случайного дискретного числа \tilde{t} , для которого значения (16) – (22) уже включены в обучающую выборку, этот результат пропускается. Шаг 2 продолжается до тех пор, пока не будет достигнут заданный объем обучающей выборки ($\sim 0,8(T + T_1)$). Оставшиеся выборочные значения включаются в верификационную выборку для тестирования.

3. Проведение нескольких параллельных опытов по рандомизированному выбору обучающей выборки путем последовательной реализации п.2 без возвращения к новому запуску генератора псевдослучайных чисел $\tilde{\xi}$.

4. Формирование нейронной сети, связывающей выборки выходных показателей (19) – (22) с выборками входных показателей (16) – (18) с использованием модуля Neural Networks пакета STATISTICA [7]. Этот модуль включает в себя процедуру, которая организует поиск нужной конфигурации сети за счет построения по обучающей выборке и тестирования на верификационной выборке большого количества сетей с разными

архитектурами и последующего выбора из них сети с минимальной ошибкой предсказаний [7].

5. Проведение процедуры модуля Neural Networks для каждого параллельного опыта и окончательный выбор конфигурации с минимальной ошибкой предсказания.

Структурная схема реализации многометодного подхода к обработке редуцированной мониторинговой информации приведена на Рисунке 2.

Заключение

Многометодный подход к моделированию сложных систем на основе анализа мониторинговой информации целесообразно использовать в следующей последовательности:

анализ ретроспективных данных как случайных процессов с целью формирования временных рядов редуцированной мониторинговой информации с привлечением экспертных оценок для снижения размерности оптимизационных задач управления;

выбора структуры и идентификации параметров прогностических моделей сложной системы с использованием временных рядов для задачи управления, связанной с перспективным планированием повышения ресурсоэффективности;

идентификации структуры и параметров регрессионных моделей с включением в число переменных времени для верификации управленческих решений перспективного планирования;

построения нейросетевых моделей для решения задачи управления по распределению ресурсного обеспечения.

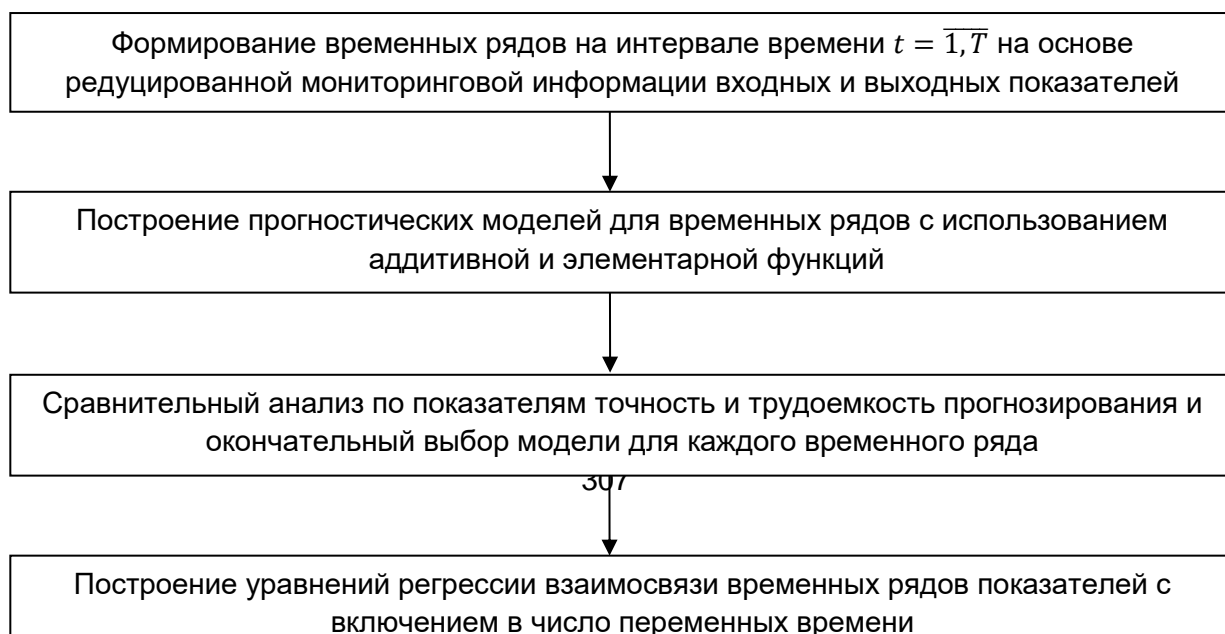


Рисунок 2 - Структурная схема реализации многометодного подхода к обработке редуцированной мониторинговой информации

ЛИТЕРАТУРА

1. Бокс Дж. Анализ временных рядов. Прогноз и управление / Дж. Бокс, Г. Дженкис. – Вып.1. – М:Мир, 1974.
2. Гаскаров Д.В. Прогнозирование технического состояния и надежности радиоэлектронной аппаратуры / Д.В. Гаскаров, Т.А. Голинкевич, А.В. Мозгалевский. – М.:Советское радио, 1974. – 224 с.

3. Фролов В.Н. Принципы идентификации и управления объектами с неоднородными характеристиками / В.Н. Фролов, Я.Е. Львович. – Воронеж: ИПЦ «Научная книга». – 159 с.
4. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М.: Горячая линия. – Телеком, 2013. – 384 с.
5. Основы проектирования искусственных нейронных сетей: учеб. Пособие / Науч.ред. Я.Е. Львович. – Воронеж: ВГТУ, 2001. – 105 с.
6. Соболев И.М. Численные методы Монте Карло / И.М. Соболев. – М.: Наука, 1973. – 312 с.
7. Стукач О.В. Программный комплекс Statistica в решении задач управления качеством / О.В. Стукач.– Томск. Из-во Томского политехнического университета, 2011. – 163 с.

Y.E. Lvovich, A.V. Pitolin, G.P. Sapozhnikov
**MULTI-METHOD APPROACH TO THE MODELING OF
COMPLEX SYSTEMS BASED ON MONITORING DATA ANALYSIS**
*Voronezh Institute of High Technologies
Voronezh State Technical University
Russian New University*

The article justifies the necessity of building various classes of mathematical models of complex systems as well as the relevance of a multi-method approach to the processing and modeling of monitoring and rating information, due to the variety of management tasks and resource efficiency optimization management of a non-profit educational organization in combination with rating management. The starting points are tentatively reduced sets of input indicators influencing the output indicators of a management unit functioning. It is based on time series forecasting on the base of additive and elementary functions. The dependence of the output performance on the input ones is determined by the regression model with the inclusion of time variables. The transition from a regression model to a neural network model is carried out, to improve the accuracy of forecasting for the purpose of managerial decision making at a certain planning horizon. The transformation procedure of initial time series into statistical samples of their prognostic estimates followed by randomized training sample development is proposed. The paper also demonstrates that the multi-method approach to the modelling provides a solution to a number of tasks concerning complex systems resource efficiency management.

Keywords: forecasting, modeling, management, resource efficiency, randomization.

REFERENCES

1. Boks Dzh. Analiz vremennykh ryadov. Prognoz i upravlenie / Dzh. Boks, G. Dzhenskis. – Вып.1. – М: Mir, 1974.
2. Gaskarov D.V. Prognozirovanie tekhnicheskogo sostoyaniya i nadezhnosti radioelektronnoy apparatury / D.V. Gaskarov, T.A. Golinkevich, A.V. Mozgalevskiy. – М.: Sovetskoe radio, 1974. – 224 p.
3. Frolov V.N. Printsipy identifikatsii i upravleniya ob"ektami s neodnorodnymi kharakteristikami / V.N. Frolov, Ya.E. L'vovich. – Voronezh: IPTs «Nauchnaya kniga». – 159 p.
4. Rutkovskaya D. Neyronnye seti, geneticheskie algoritmy i nechetkie sistemy / D. Rutkovskaya, M. Pilin'skiy, L. Rutkovskiy. – М.: Goryachaya liniya. – Telekom, 2013. – 384 p.
5. Osnovy proektirovaniya iskusstvennykh neyronnykh setey: ucheb. Posobie / Nauch.red. Ya.E. L'vovich. – Voronezh: VGTU, 2001. – 105 p.
6. Sobol' I.M. Chislennyye metody Monte Karlo / I.M. Sobol'. – М.: Nauka, 1973. – 312 p.
7. Stukach O.V. Programmnyy kompleks Statistica v reshenii zadach upravleniya kachestvom / O.V. Stukach. – Tomsk. Iz-vo Tomskogo politekhnicheskogo universiteta, 2011. – 163 p.