



## ІНФОРМАЦІЙНІ СИСТЕМИ І ТЕХНОЛОГІЇ

УДК 004.032.26

### ОПЕРАТИВНОЕ ПРОГНОЗИРОВАНИЕ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ НА ОСНОВЕ НЕЙРОСЕТЕВОГО АНАЛИЗА ГАРМОНИЧЕСКИХ КОМПОНЕНТ

**Бодянский Е.В., Попов С.В., Рыбальченко Т.В.**

*Проблемная научно-исследовательская лаборатория автоматизированных систем  
управления, Харьковский национальный университет радиоэлектроники,  
пр. Ленина, 14, г. Харьков.*

*E-mail: [bodya@kture.kharkov.ua](mailto:bodya@kture.kharkov.ua)*

#### **Введение**

Оперативное и краткосрочное прогнозирование процессов потребления электроэнергии играет важную роль в обеспечении эффективной и надежной работы энергосистем, определяя в значительной мере качество управления ими. Сложный нелинейный характер этих процессов, высокая изменчивость и нестационарность, существенная стохастическая неопределенность не позволяют достичь требуемого качества предсказания с помощью традиционных (аналитических, адаптивных, экспертных и т.п.) методов. Разумной, а возможно, и единственной альтернативой этим методам являются методы интеллектуального анализа данных, основанные на мощном математическом аппарате вычислительного интеллекта и, прежде всего, на искусственных нейронных сетях. Нейронные сети, благодаря своим универсальным аппроксимирующим и экстраполирующим возможностям, способности обучения и возможности работы в существенной неопределенности, получили широкое распространение для решения задач прогнозирования процессов различной природы, в том числе и процессов потребления электрической энергии [1-8]. При этом в процессе прогнозирования не формируется никаких априорных предпосылок о внутренней структуре исследуемого сигнала, т.е. задача решается в условиях априорной структурной неопределенности.

В то же время существует широкий класс случайных процессов, содержащих в себе так называемые скрытые периодичности [9; 10], число которых и частоты априори неизвестны. Такие сигналы достаточно часто присутствуют в приложениях, связанных с энергетикой, медициной и вибродиагностикой, задачами контроля промышленных объектов. Конечно, существует мощный аппарат спектрального анализа, позволяющий анализировать сигналы произвольной природы, однако разложение при этом производится по кратным гармоникам, в то время как многие реальные процессы содержат колебательные компоненты произвольных частот, которые необходимо выявить. На наш взгляд, наиболее эффективным аппаратом для решения этой задачи могут служить искусственные нейронные сети, благодаря достоинствам, отмеченным выше.

В связи с этим в настоящей работе предлагается подход, основанный на использовании нейронных сетей, позволяющий выявить и восстановить параметры произвольного количества периодических компонент, возможно, некратных частот в контролируемой стохастической последовательности и на этой основе решить задачу прогнозирования этого сигнала.

#### **Алгоритм решения задачи**

Пусть контролируемая стохастическая последовательность может быть представлена в форме



$$y(k) = \sum_{j=1}^m (a_j \cos \omega_j k + b_j \sin \omega_j k) + \xi(k) = \sum_{j=1}^m d_j \sin(\omega_j k + \theta_j) + \xi(k), \quad (1)$$

где  $m$  – возможное количество гармоник в сигнале, априори неизвестное;  $a_j, b_j, d_j, \theta_j$  – неизвестные параметры отдельных гармоник;  $0 < \omega_j = 2\pi f_j T_0 < \pi$  – неизвестные возможно изменяющиеся во времени частоты, подлежащие определению;  $T_0$  – период квантования сигнала;  $\xi(k)$  – стохастическая компонента типа белого шума с нулевым первым и ограниченным вторым центральным моментами;  $k = 0, 1, 2, \dots$  – дискретное время.

Поставим в соответствие (1) математическую модель вида

$$\begin{aligned} \hat{y}_1(k) &= \hat{a}_1 \cos \hat{\omega}_1 k + \hat{b}_1 \sin \hat{\omega}_1 k = \\ &= 2 \cos \hat{\omega}_1 y(k-1) - y(k-2) = 2\hat{\beta}_1 y(k-1) - y(k-2), \end{aligned} \quad (2)$$

описывающую моногармонические колебания с параметрами  $\hat{a}_1, \hat{b}_1, \hat{\omega}_1$ . Неизвестные параметры модели (2) могут быть оценены с помощью простой двухэтапной процедуры. На первом этапе вводится критерий оценивания

$$E_1^\beta = \sum_{k=3}^N (y(k) + y(k-2) - 2\hat{\beta}_1 y(k-1))^2,$$

путем минимизации которого находится оценка частоты в виде

$$\left\{ \begin{aligned} \hat{\beta}_1(N) &= \frac{\sum_{k=3}^N (y(k) + y(k-2))y(k-1)}{2 \sum_{k=3}^N y^2(k-1)}, \\ \hat{\omega}_1(N) &= \arccos \hat{\beta}_1(N). \end{aligned} \right. \quad (3)$$

На втором этапе вводится критерий оценивания

$$E_1^\omega = \sum_{k=3}^N (y(k) - \hat{a}_1 \cos \hat{\omega}_1(N)k - \hat{b}_1 \sin \hat{\omega}_1(N)k)^2,$$

путем минимизации которого находятся оценки параметров  $\hat{a}_1$  и  $\hat{b}_1$  в виде

$$\left\{ \begin{aligned} \hat{a}_1(N) &= \frac{\sum_{k=3}^N y(k) \cos \hat{\omega}_1(N)k \sum_{k=3}^N \sin^2 \hat{\omega}_1(N)k - \sum_{k=3}^N y(k) \sin \hat{\omega}_1(N)k \sum_{k=3}^N \cos \hat{\omega}_1(N)k \sin \hat{\omega}_1(N)k}{\sum_{k=3}^N \cos^2 \hat{\omega}_1(N)k \sum_{k=3}^N \sin^2 \hat{\omega}_1(N)k - \left( \sum_{k=3}^N \cos \hat{\omega}_1(N)k \sin \hat{\omega}_1(N)k \right)^2}, \\ \hat{b}_1(N) &= \frac{\sum_{k=3}^N y(k) \sin \hat{\omega}_1(N)k \sum_{k=3}^N \cos^2 \hat{\omega}_1(N)k - \sum_{k=3}^N y(k) \cos \hat{\omega}_1(N)k \sum_{k=3}^N \cos \hat{\omega}_1(N)k \sin \hat{\omega}_1(N)k}{\sum_{k=3}^N \cos^2 \hat{\omega}_1(N)k \sum_{k=3}^N \sin^2 \hat{\omega}_1(N)k - \left( \sum_{k=3}^N \cos \hat{\omega}_1(N)k \sin \hat{\omega}_1(N)k \right)^2}, \end{aligned} \right. \quad (4)$$



или в матричной форме

$$\begin{pmatrix} \hat{a}_1(N) \\ \hat{b}_1(N) \end{pmatrix} = \begin{pmatrix} \sum_{k=3}^N \cos^2 \hat{\omega}_1(N)k & \sum_{k=3}^N \cos \hat{\omega}_1(N)k \sin \hat{\omega}_1(N)k \\ \sum_{k=3}^N \cos \hat{\omega}_1(N)k \sin \hat{\omega}_1(N)k & \sum_{k=3}^N \sin^2 \hat{\omega}_1(N)k \end{pmatrix}^{-1} \begin{pmatrix} \sum_{k=3}^N y(k) \cos \hat{\omega}_1(N)k \\ \sum_{k=3}^N y(k) \sin \hat{\omega}_1(N)k \end{pmatrix}.$$

Поскольку характеристики контролируемой последовательности (1) могут меняться с течением времени, вместо пакетной процедуры оценивания (3), (4) целесообразно использовать адаптивные алгоритмы обучения, позволяющие отслеживать дрейф нестационарных параметров в реальном времени. Для этого целесообразно использовать экспоненциально взвешенную процедуру стохастической аппроксимации [11], обеспечивающую компромисс между следящими (оценки дрейфа) и фильтрующими (сглаживание возмущения  $\xi(k)$ ) свойствами процесса адаптивной настройки параметров модели (2). В этом случае если по  $k$  наблюдениям были получены оценки  $\hat{a}_1, \hat{b}_1, \hat{\omega}_1$ , то в момент текущего времени  $k+1$  производится уточнение модели согласно рекуррентным соотношениям

$$\begin{cases} \hat{\beta}_1(k+1) = \hat{\beta}_1(k) + r_1^{-1}(k+1)(y(k+1) - y(k-1) - 2\hat{\beta}_1(k)y(k))2y(k), \\ r_1(k+1) = \alpha r_1(k) + 4y^2(k), \\ \hat{\omega}_1(k+1) = \arccos \hat{\beta}_1(k+1), \\ (\hat{a}_1(k+1), \hat{b}_1(k+1))^T = (\hat{a}_1(k), \hat{b}_1(k))^T + R_1^{-1}(k+1)(y(k+1) - \hat{a}_1(k) \cos \hat{\omega}_1(k+1)(k+1) - \\ - \hat{b}_1(k) \sin \hat{\omega}_1(k+1)(k+1))(\cos \hat{\omega}_1(k+1)(k+1), \sin \hat{\omega}_1(k+1)(k+1))^T, \\ R_1(k+1) = \alpha R_1(k) + 1, \end{cases} \quad (5)$$

где  $0 \leq \alpha \leq 1$  – параметр сглаживания, определяющий компромисс между следящими и фильтрующими свойствами алгоритма.

Введем далее в рассмотрение обновляющую последовательность  $\mathcal{Y}_1(k)$  путем исключения из исходного сигнала первой гармоники

$$\mathcal{Y}_1(k) = y(k) - \hat{y}_1(k)$$

и поставим ей в соответствие моногармоническую модель

$$\begin{aligned} \hat{y}_2(k) &= \hat{a}_2 \cos \hat{\omega}_2 k + \hat{b}_2 \sin \hat{\omega}_2 k = 2 \cos \hat{\omega}_2 \mathcal{Y}_1(k-1) - \\ &- \mathcal{Y}_1(k-2) = 2\hat{\beta}_2 \mathcal{Y}_1(k-1) - \mathcal{Y}_1(k-2). \end{aligned}$$

Минимизируя критерии оценивания

$$\begin{cases} E_2^\beta = \sum_{k=3}^N (\mathcal{Y}_1(k) + \mathcal{Y}_1(k-2) - 2\hat{\beta}_2 \mathcal{Y}_1(k-1))^2, \\ E_2^\omega = \sum_{k=3}^N (\mathcal{Y}_1(k) - \hat{a}_2 \cos \hat{\omega}_2(N)k - \hat{b}_2 \sin \hat{\omega}_2(N)k)^2 \end{cases}$$



с помощью рекуррентной процедуры

$$\left\{ \begin{aligned} \hat{\beta}_2(k+1) &= \hat{\beta}_2(k) + r_2^{-1}(k+1)(\mathcal{Y}_1(k+1) - \mathcal{Y}_1(k-1) - 2\hat{\beta}_2(k)\mathcal{Y}_1(k))2\mathcal{Y}_1(k), \\ r_2(k+1) &= \alpha r_2(k) + 4\mathcal{Y}_1^2(k), \\ \hat{\omega}_2(k+1) &= \arccos \hat{\beta}_2(k+1), \\ (\hat{a}_2(k+1), \hat{b}_2(k+1))^T &= (\hat{a}_2(k), \hat{b}_2(k))^T + R_2^{-1}(k+1)(\mathcal{Y}_1(k+1) - \hat{a}_2(k) \cos \hat{\omega}_2(k+1)(k+1) - \\ &\quad - \hat{b}_2(k) \sin \hat{\omega}_2(k+1)(k+1))(\cos \hat{\omega}_2(k+1)(k+1), \sin \hat{\omega}_2(k+1)(k+1))^T, \\ R_2(k+1) &= \alpha R_2(k) + 1, \end{aligned} \right.$$

получаем сигнал второй гармоники

$$\hat{y}_2(k+1) = \hat{a}_2(k+1) \cos \hat{\omega}_2(k+1)(k+1) + \hat{b}_2(k+1) \sin \hat{\omega}_2(k+1)(k+1).$$

Вводя далее второе обновление

$$\mathcal{Y}_2(k) = \mathcal{Y}_1(k) - \hat{y}_2(k),$$

можно получить оценки третьей гармоники  $\hat{\beta}_3, \hat{\omega}_3, \hat{a}_3, \hat{b}_3$  и т.д.

И, наконец, для  $m$ -й гармоники

$$\begin{aligned} \hat{y}_m(k) &= \hat{a}_m \cos \hat{\omega}_m k + \hat{b}_m \sin \hat{\omega}_m k = 2 \cos \hat{\omega}_m \mathcal{Y}_{m-1}(k-1) - \mathcal{Y}_{m-1}(k-2) = \\ &= 2\hat{\beta}_m \mathcal{Y}_{m-1}(k-1) - \mathcal{Y}_{m-1}(k-2) \end{aligned}$$

(здесь  $\mathcal{Y}_{m-1}(k) = \mathcal{Y}_{m-2}(k) - \hat{y}_{m-1}(k)$ )

можно записать рекуррентную процедуру

$$\left\{ \begin{aligned} \hat{\beta}_m(k+1) &= \hat{\beta}_m(k) + r_m^{-1}(k+1)(\mathcal{Y}_{m-1}(k+1) - \mathcal{Y}_{m-1}(k-1) - 2\hat{\beta}_m(k)\mathcal{Y}_{m-1}(k))2\mathcal{Y}_{m-1}(k), \\ r_m(k+1) &= \alpha r_m(k) + 4\mathcal{Y}_{m-1}^2(k), \\ \hat{\omega}_m(k+1) &= \arccos \hat{\beta}_m(k+1), \\ (\hat{a}_m(k+1), \hat{b}_m(k+1))^T &= (\hat{a}_m(k), \hat{b}_m(k))^T + R_m^{-1}(k+1)(\mathcal{Y}_{m-1}(k+1) - \hat{a}_m(k) \cos \hat{\omega}_m(k+1)(k+1) - \\ &\quad - \hat{b}_m(k) \sin \hat{\omega}_m(k+1)(k+1))(\cos \hat{\omega}_m(k+1)(k+1), \sin \hat{\omega}_m(k+1)(k+1))^T, \\ R_m(k+1) &= \alpha R_m(k) + 1. \end{aligned} \right. \quad (6)$$

Используя одновременно все  $m$  синтезированных гармоник, можно сформировать многомодельный обобщенный сигнал [12; 13]

$$\hat{y}(k) = \sum_{j=1}^m c_j \hat{y}_j(k) = c^T \hat{y}(k),$$

где  $c = (c_1, c_2, \dots, c_m)^T$  – вектор настраиваемых весов, отвечающих условию несмещенности прогноза



$$\sum_{j=1}^m c_j = c^T I_m \quad (7)$$

и определяющий вклад каждой из гармоник в последовательность  $y(k)$ ,  $I_m$  –  $(m \times 1)$ -вектор, образованный единицами,  $\hat{y}(k) = (\hat{y}_1(k), \hat{y}_2(k), \dots, \hat{y}_m(k))^T$  –  $(m \times 1)$ -вектор, образованный выделенными гармониками  $\hat{y}_j(k)$ .

Настройка вектора весов  $c$  производится с помощью адаптивного алгоритма обучения [14]

$$\begin{cases} \hat{c}(k+1) = \hat{c}(k) + \frac{v(k+1)(2v(k+1)\hat{y}(k+1) - \lambda(k)I_m)}{2v(k+1)\|\hat{y}(k+1)\|^2 - \lambda(k)\hat{y}^T(k+1)I_m}, \\ \lambda(k+1) = \lambda(k) + \eta_\lambda(k+1)(\hat{c}^T(k+1)I_m - 1), \\ v(k+1) = y(k+1) - \hat{c}^T(k)\hat{y}(k+1), \end{cases} \quad (8)$$

где  $\lambda(k)$  – настраиваемый неопределенный множитель Лагранжа;  $\eta_\lambda(k)$  – параметр шага настройки.

Алгоритм (8) обладает высокой скоростью сходимости, обеспечивает в процессе обучения выполнение условия (7), а при  $\lambda(k) = 0$  автоматически приобретает форму оптимального по быстродействию одношагового алгоритма Качмажа–Уидроу–Хоффа, широко используемого в задачах обучения искусственных нейронных сетей.

### Архитектура нейронной сети

Архитектура искусственной трехслойной нейронной сети прямого распространения для анализа гармонических компонент приведена на рис. 1 и является модификацией нейросетевого спектрального анализатора, предложенного в [15].

Во входном слое, образованном элементами чистого запаздывания  $z^{-1}$ , формируются задержанные относительно входного сигнала  $y(k+1)$  значения  $y(k)$ ,  $y(k-1)$ , а также обновления  $\mathcal{Y}_1(k)$ ,  $\mathcal{Y}_1(k-1)$ ,  $\mathcal{Y}_2(k)$ ,  $\mathcal{Y}_2(k-1)$ , ...,  $\mathcal{Y}_{m-1}(k)$ ,  $\mathcal{Y}_{m-1}(k-1)$ , которые далее подаются на  $m$  нейронов первого скрытого слоя, каждый из которых содержит один настраиваемый синаптический вес  $\hat{\beta}_j$ , уточняемый на каждом такте обучения с помощью первых двух соотношений рекуррентной процедуры (6). На выходах нейронов первого скрытого слоя появляются вычисленные оценки  $\hat{\beta}_j(k+1)$ , а также значения обновляющих последовательностей  $\mathcal{Y}_1(k+1)$ ,  $\mathcal{Y}_2(k+1)$ , ...,  $\mathcal{Y}_m(k+1)$ . Активационные функции нейронов первого слоя, в отличие от традиционных сигмоидальных, имеют форму арккосинуса, благодаря чему на выходе первого слоя появляются оценки частот  $\hat{\omega}_1(k+1)$ ,  $\hat{\omega}_2(k+1)$ , ...,  $\hat{\omega}_m(k+1)$ .

Эти оценки поступают на входы второго скрытого слоя, каждый из которых имеет два настраиваемых синаптических веса  $\hat{a}_j, \hat{b}_j$ , которые уточняются с помощью двух последних соотношений рекуррентной процедуры (6). В этом же слое на основании полученных оценок вычисляются выделенные гармоники с помощью элементарного выражения



$$\hat{y}_j(k+1) = \hat{a}_j(k+1) \cos \hat{\omega}_j(k+1)(k+1) + \hat{b}_j(k+1) \sin \hat{\omega}_j(k+1)(k+1).$$

Эти сигналы подаются на вход выходного слоя, образованного единственным адаптивным линейным ассоциатором с  $m$  синаптическими весами  $\hat{c}_j$ . В отличие от традиционных алгоритмов обучения типа Качмажа–Уидроу–Хоффа или метода наименьших квадратов с различными его модификациями, в предлагаемой нейронной сети выходной слой обучается с помощью алгоритма (8), являющегося по сути процедурой нелинейного программирования Эрроу–Гурвица–Удзавы, оптимизированной по быстрдействию [14].

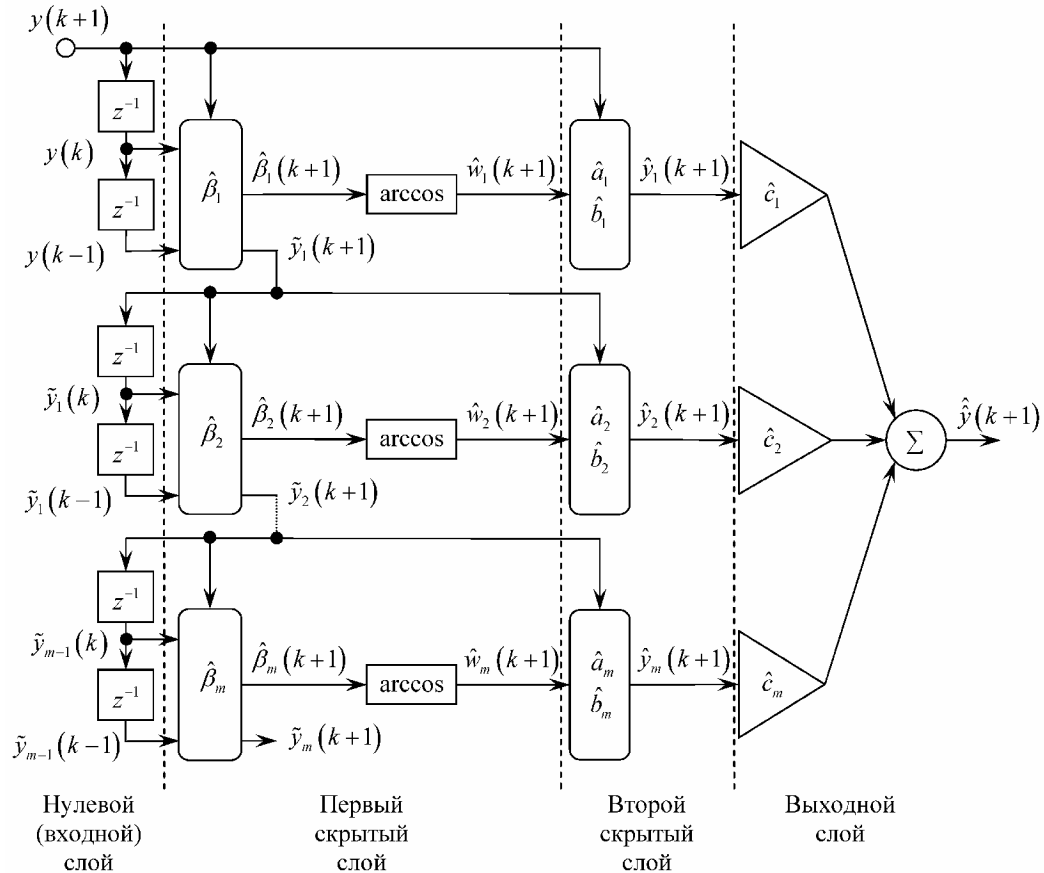


Рис. 1. Нейронная сеть для анализа гармонических компонент

На выходе сети появляется многомодельный обобщенный сигнал  $\hat{y}(k+1)$ , образованный  $m$  гармоническими компонентами, наилучшим образом аппроксимирующий входную последовательность  $y(1), y(2), \dots, y(k), y(k+1), \dots$

### Заключение

Предложена архитектура трехслойной нейронной сети прямого распространения и алгоритм ее обучения, предназначенные для прогнозирования сигналов, содержащих априори неизвестное число скрытых колебательных компонент с некрратными частотами. Введенная нейронная сеть может найти применение в задачах оперативного контроля, анализа и предсказания потребления электроэнергии на разных уровнях управления энергосистемами.



### Литература

1. Papalexopoulos A.D., Hao S., Peng T.M. An implementation of a neural network based load forecasting model for the EMS // *IEEE Trans. Power Systems.* – 1994. – V. 9. – № 4. – P. 1956-1962.
2. Piras A., Germond A., Buchenel B., Imhof K., Jaccard Y. Heterogeneous artificial neural network for short term electrical load forecasting // *IEEE Trans. Power Systems.* – 1996. – V. 11. – № 2. – P. 397-402.
3. Kiartzis S.J., Zoumas C.E., Theocharis J.B., Bakirtzis A.G., Petridis V. Short-term load forecasting in an autonomous power system using artificial neural networks // *IEEE Trans. Power Systems.* – 1997. – V. 12. – № 4. – P. 1591-1596.
4. Drezga I., Rahman S. Input variable selection for ANN-based short-term load forecasting // *IEEE Trans. Power Systems.* – 1998. – V. 13. – № 4. – P. 1238-1244.
5. Mueller H., Petrisch G. Energy and load forecasting by fuzzy-neural networks // *Proc. EUFTT'98.* – 1998. – September 7-10. – P. 1925-1929.
6. Hippert H.S., Pedreira C.E., Souza R.C. Neural networks for short-term load forecasting: a review and evaluation // *IEEE Trans. Power Systems.* – 2001. – V. 16. – № 1. – P. 44-55.
7. Ling S.H., Leung F.H.F., Lam H.K., Tam P.K.S. Short-term electric load forecasting based on a neural fuzzy network // *IEEE Trans. Industrial Electronics.* – 2003. – V. 50. – № 6. – P. 1305-1316.
8. Bodyanskiy Y., Popov S., Rybalchenko T. Multilayer neuro-fuzzy network for short term electric load forecasting // *Lecture Notes in Computer Science – Berlin, Heidelberg : Springer-Verlag, 2008.* – V. 5010. – P. 339-348.
9. Серебренников М.Г. Выявление скрытых периодичностей / М.Г. Серебренников, А.А. Первозванский. – М. : Наука, 1965. – 244 с.
10. Рабинер П. Теория и применение цифровой обработки сигналов / П. Рабинер, Б. Гоулд. – М. : Мир, 1978. – 848 с.
11. Бодянский Е.В., Плисс И.П., Соловьева Т.В. Многошаговые оптимальные упредители многомерных нестационарных стохастических процессов // *Доклады АН УССР.* – 1986. – Сер. А. – № 12. – С. 47-49.
12. Бодянский Е.В., Плисс И.П., Соловьева Т.В. Адаптивное обобщенное прогнозирование многомерных случайных последовательностей // *Доклады АН УССР.* – 1989. – Сер. А. – № 9. – С. 73-75.
13. Bodyanskiy Y., Pliss I. Adaptive generalized forecasting of multivariate stochastic signals // *Proc. Latvian Signal Processing Int. Conf.* – Riga, 1990. – V. 2. – P. 80-83.
14. Бодянский Е.В., Михальов О.І., Плисс І.П. Адаптивне виявлення розладнань в об'єктах керування за допомогою штучних нейронних мереж. – Дніпропетровськ: Системні технології, 2000. – 140 с.
15. Bodyanskiy Y., Popov S., Stephan A. Harmonic components detection in stochastic sequences using artificial neural networks // *Computational Intelligence and Applications / Ed. by N.E. Mastorakis.* – Piraeus : WSES Press, 1999. – P. 162-166.

### Інформація

**Ульянов М.В. Ресурсно-эффективные компьютерные алгоритмы. Разработка и анализ. – М. : Физматлит, 2008. – 304 с.**

В пособии полно и на современном уровне изложены вопросы выбора рациональных алгоритмических решений, в том числе и комбинированных, важные в практическом плане и актуальные при проектировании информационных и программных систем. Пособие может использоваться в качестве практически удобного и современного дополнения к существующей учебной литературе по данной проблематике.