

УДК 004.032.26

И.П. Плисс, С.В. Попов, Т.В. Рыбальченко

ПРОГНОЗИРОВАНИЕ ТРЕНД-СЕЗОННЫХ ВРЕМЕННЫХ РЯДОВ ПОТРЕБЛЕНИЯ ЭЛЕКТРИЧЕСКОЙ ЭНЕРГИИ С ПОМОЩЬЮ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Введение

Задача оперативного, краткосрочного и долгосрочного прогнозирования потребления электрической энергии в настоящее время является предметом интенсивных исследований в электроэнергетике [1-3], а результаты ее решения лежат в основе процессов планирования и управления режимами энергосистем различного уровня. Сложный нелинейный стохастически-хаотический характер временных рядов, описывающих процессы энергопотребления, существенно снижает эффективность традиционных методов статистического анализа и вынуждает обратиться к более изощренным методам интеллектуального анализа данных и, прежде всего, к аппарату искусственных нейронных сетей [4-6].

Следует отметить, что искусственные нейронные сети достаточно широко используются в задачах прогнозирования энергопотребления [7-10], благодаря, прежде всего, своим универсальным аппроксимирующим свойствам. Вместе с тем, подавляющее большинство публикаций по данной проблематике связано с оперативным и краткосрочным прогнозированием, задача же долгосрочного прогнозирования (месяц – квартал – год) изучалась в меньшей степени, хотя, с теоретической точки зрения представляется более интересной, поскольку временные ряды с большими тактами квантования, кроме обычных стохастических компонент, содержат различного рода тренды и колебательные сезонные компоненты.

В общем случае задача прогнозирования нестационарных временных рядов с тренд-сезонной компонентой достаточно часто встречается на практике и, прежде всего, в экономических приложениях [11-17], при этом традиционно предполагается, что

анализируемая последовательность может быть представлена в виде модели

$$y(k) = \sum_{i=0}^p d_i k^i + \sum_{j=1}^m (a_j \cos \omega_j k + b_j \sin \omega_j k) + \xi(k) \quad (1)$$

или, используя оператор сдвига назад z^{-1} ,

$$(1 - z^{-1})^p \prod_{j=1}^m (1 - 2 \cos \omega_j z^{-1} + z^{-2}) y(k) = \xi(k).$$

Здесь p и m – порядок полиномиальной компоненты и количество гармоник в последовательности $y(k)$ соответственно, d_i, a_j, b_j – неизвестные параметры модели, подлежащие оцениванию, $0 < \omega_j = 2\pi f_j T_0 < \pi$ – неизвестные частоты периодических компонент, T_0 – период квантования, $k = 1, 2, \dots, N$ – дискретное время, $\xi(k)$ – стохастическая компонента типа «белого» шума с нулевым математическим ожиданием и ограниченным вторым моментом.

Идентификация параметров модели (1) d_i, a_j, b_j традиционно производится с помощью стандартного метода наименьших квадратов, при этом частоты ω_j полагают известными. Оценивание же частот значительно сложнее, поскольку они входят в описание (1) нелинейно. Если необходимо оценивать и эти параметры, то задача существенно усложняется, особенно, если параметры непредсказуемым образом меняются во времени. В данной работе решается задача оценивания всех нестационарных параметров и построения прогноза последовательности $y(k)$ по данным о ее предыстории.

1. Алгоритм решения задачи

Для решения задачи будем использовать многоэтапную [18-20] нейросетевую [21] модифицированную схему оценивания параметров полигармонических сигналов, которая для рассматриваемой здесь практической ситуации может быть представлена в виде последовательности этапов:

– исключение полиномиального тренда путем $(p+1)$ -кратного взятия разности исходной последовательности $y(k)$ либо вычитания

из $y(k)$ полинома $\sum_{i=0}^p \hat{d}_i k^i$, где \hat{d}_i – оценки, вычисляемые либо в

пакетном режиме с помощью метода наименьших квадратов, либо в процессе обучения искусственной нейронной сети;

- идентификация параметров полигармонической модели

$$\prod_{j=1}^m (1 - 2 \cos \omega_j z^{-1} + z^{-2}) \tilde{y}(k) = \tilde{\xi}(k) \quad (2)$$

либо с помощью метода наименьших квадратов, либо в процессе обучения нейронной сети (здесь $\tilde{y}(k)$ – исходный сигнал с исключенным полиномиальным трендом, $\tilde{\xi}(k)$ – преобразованное с учетом результатов предыдущего этапа стохастическое возмущение);

- нахождение оценок частот $\hat{\omega}_j$ колебательных компонент путем нахождения корней характеристического полинома m -й степени;

- нахождение оценок \hat{a}_j, \hat{b}_j в рамках модели (2) и пересчет их в оценки \hat{a}_j, \hat{b}_j для модели (1);

- дискретное интегрирование (дигрирование) сигнала $\tilde{y}(k)$ и восстановление исходного сигнала $y(k)$;

- построение прогноза $\hat{y}(k+1)$ с помощью специализированной искусственной нейронной сети.

Рассмотрим работу данной схемы для нескольких простых, но достаточно типичных ситуаций. Пусть в (1) $p=0$, то есть прогнозируемая последовательность $y(k)$ колеблется относительно некоторого неизвестного среднего уровня d_0 . Такая ситуация достаточно часто возникает при оперативном и краткосрочном прогнозировании с малыми тактами квантования. Исключить средний уровень можно путем взятия первой разности [11], то есть переходя к временному ряду $\tilde{y}(k)$ такому, что

$$\tilde{y}(k) = \sum_{j=1}^m (\tilde{a}_j \cos \omega_j k + \tilde{b}_j \sin \omega_j k) + \tilde{\xi}(k) \quad (3)$$

или

$$\prod_{j=1}^m (1 - 2 \cos \omega_j z^{-1} + z^{-2}) \tilde{y}(k) = \tilde{\xi}(k), \quad (4)$$

где $\tilde{y}(k) = y(k) - y(k-1)$, $\tilde{\xi}(k) = \xi(k) - \xi(k-1)$.

Между параметрами моделей (1) и (3) существует однозначная связь вида

$$\begin{cases} \tilde{a}_j = a_j(1 - \cos \omega_j) + b_j \sin \omega_j, \\ \tilde{b}_j = b_j(1 - \cos \omega_j) - a_j \sin \omega_j, \end{cases}$$

однако в силу того, что возмущение $\tilde{\xi}(k)$ не является «белым», дисперсия оценок \hat{a}_j, \hat{b}_j , полученных с помощью традиционного метода наименьших квадратов, существенно возрастает, что ведет, в свою очередь, к ухудшению качества получаемых прогнозов. В связи с этим следует, по возможности, избегать использования операции взятия разности, а просто вычитать из сигнала $y(k)$ средний уровень, полученный либо с помощью простой рекуррентной процедуры

$$\hat{d}_0(k) = \frac{1}{k} y(k) + \frac{k-1}{k} \hat{d}_0(k-1),$$

либо с помощью экспоненциального сглаживания нулевого порядка [12, 17]

$$\hat{d}_0(k) = \alpha y(k) + (1 - \alpha) \hat{d}_0(k-1),$$

где $0 < \alpha < 1$ – параметр сглаживания, выбираемый, как правило, из эмпирических соображений.

Для исключения полиномиального тренда p -го порядка исходный ряд $y(k)$ должен быть подвергнут операции взятия разности $p+1$ раз так, что дисперсия возмущения $\tilde{\xi}(k)$ может неконтролируемым образом расти. В связи с этим более целесообразно вычитать из $y(k)$ его экспоненциальное среднее p -го порядка, рассчитываемое с помощью достаточно простых рекуррентных соотношений [17]. Операцию же взятия разностей следует использовать в ситуациях с малым уровнем возмущений.

Далее рассмотрим случай, когда в ряде с исключенным полиномиальным трендом присутствует единственная гармоника частоты ω , то есть модель (4) имеет простейшую форму

$$\begin{aligned} (1 - 2 \cos \omega z^{-1} + z^{-2}) \tilde{y}(k) &= \tilde{\xi}(k), \\ (1 - 2\beta z^{-1} + z^{-2}) \tilde{y}(k) &= \tilde{\xi}(k), \\ \tilde{y}(k) &= 2\beta \tilde{y}(k-1) - \tilde{y}(k-2) + \tilde{\xi}(k) \end{aligned}$$

авторегрессии второго порядка.

Вводя квадратичный критерий идентификации (обучения в терминах нейронных сетей)

$$E_1^N = \sum_{k=1}^N \left(\tilde{y}(k) + \tilde{y}(k-2) - 2\hat{\beta}\tilde{y}(k-1) \right)^2$$

и минимизируя его по $\hat{\beta}$, несложно получить

$$\hat{\beta} = \frac{\sum_{k=3}^N (\tilde{y}(k) + \tilde{y}(k-2))\tilde{y}(k-1)}{2\sum_{k=3}^N \tilde{y}^2(k-1)}, \quad (5)$$

при этом, если $\tilde{y}(k)$ есть p -я разность $y(k)$, то суммирование в (5) начинается с $k = p + 3$.

Далее рассчитывается оценка частоты

$$\hat{\omega} = \arccos \hat{\beta}$$

отфильтрованного сигнала

$$\tilde{y}(k|N) = 2\hat{\beta}\tilde{y}(k-1) - \tilde{y}(k-2)$$

и одношаговый прогноз

$$\hat{y}(N+1) = 2\hat{\beta}\tilde{y}(N) - \tilde{y}(N-1).$$

Для нахождения оценок \hat{a} и \hat{b} вводится дополнительный критерий идентификации-обучения

$$\begin{aligned} E_2^N &= \sum_{k=3}^N \left(\tilde{y}(k) - \hat{a} \cos \hat{\omega}k - \hat{b} \sin \hat{\omega}k \right)^2 = \\ &= \sum_{k=3}^N \left(\tilde{y}(k) - \begin{pmatrix} \hat{a} \\ \hat{b} \end{pmatrix} \begin{pmatrix} \cos \hat{\omega}k \\ \sin \hat{\omega}k \end{pmatrix} \right)^2, \end{aligned} \quad (6)$$

минимизация которого ведет к результату

$$\begin{pmatrix} \hat{a} \\ \hat{b} \end{pmatrix} = \left(\begin{array}{cc} \sum_{k=3}^N \cos^2 \hat{\omega}k & \sum_{k=3}^N \cos \hat{\omega}k \sin \hat{\omega}k \\ \sum_{k=3}^N \cos \hat{\omega}k \sin \hat{\omega}k & \sum_{k=3}^N \sin^2 \hat{\omega}k \end{array} \right)^{-1} \begin{pmatrix} \sum_{k=3}^N \cos \hat{\omega}k \cdot \tilde{y}(k) \\ \sum_{k=3}^N \sin \hat{\omega}k \cdot \tilde{y}(k) \end{pmatrix}. \quad (7)$$

При нейросетевой реализации, вместо использования оценок (7), удобнее минимизировать критерий (6) с помощью рекуррентной экспоненциально взвешенной процедуры обучения [22, 23], обеспечивающей компромисс между фильтрующими и следящими свойствами процесса оценивания. При этом, если ранее по N наблюдениям были получены оценки $\hat{\omega}(N), \hat{a}(N), \hat{b}(N)$, то с приходом $(N+1)$ -го наблюдения $\tilde{y}(N+1)$ производится шаг уточнения с помощью модифицированного алгоритма [21]

$$\left\{ \begin{array}{l} \hat{\beta}(N+1) = \hat{\beta}(N) + r_1^{-1}(N+1) \left(\tilde{y}(N+1) - \tilde{y}(N-1) - 2\hat{\beta}(N)\tilde{y}(N) \right) 2\tilde{y}(N), \\ r_1(N+1) = \alpha r_1(N) + 4\tilde{y}^2(N), 0 \leq \alpha \leq 1, \\ \hat{\omega}(N+1) = \arccos \hat{\beta}(N+1), \\ \begin{pmatrix} \hat{a}(N+1) \\ \hat{b}(N+1) \end{pmatrix} = \begin{pmatrix} \hat{a}(N) \\ \hat{b}(N) \end{pmatrix} + r_2^{-1}(N+1) \left(\tilde{y}(N+1) - \hat{a}(N) \cos \hat{\omega}(N+1)(N+1) - \right. \\ \left. - \hat{b}(N) \sin \hat{\omega}(N+1)(N+1) \right) \begin{pmatrix} \cos \hat{\omega}(N+1)(N+1) \\ \sin \hat{\omega}(N+1)(N+1) \end{pmatrix}, \\ r_2(N+1) = \alpha r_2(N) + 1. \end{array} \right. \quad (8)$$

Рассмотрим далее ситуацию, когда в моделях (3), (4) присутствует не одна, а m колебательных составляющих, например, суточная, недельная и сезонная компоненты. Для этого перепишем (4) в виде

$$\begin{aligned} \tilde{y}(k) &= \sum_{j=0}^{m-1} \beta_{j+1} \left(\tilde{y}(k+j-m) + \tilde{y}(k-j-m) \right) - \tilde{y}(k-2m) + \tilde{\xi}(k) = \\ &= 2\beta_1 \tilde{y}(k-m) + \beta_2 \left(\tilde{y}(k+1-m) + \tilde{y}(k-1-m) \right) + \beta_3 \left(\tilde{y}(k+2-m) + \tilde{y}(k-2-m) \right) + \\ &+ \dots + \beta_m \left(\tilde{y}(k-1) + \tilde{y}(k-2m+1) \right) - \tilde{y}(k-2m) + \tilde{\xi}(k) = \\ &= \beta^T Y(k) - \tilde{y}(k-2m) + \tilde{\xi}(k), \end{aligned}$$

где $\beta = (\beta_1, \beta_2, \dots, \beta_m)^T$ – вектор неизвестных параметров, подлежащих определению, $Y(k) = (2\tilde{y}(k-m), \tilde{y}(k+1-m) + \tilde{y}(k-1-m), \tilde{y}(k+2-m) + \tilde{y}(k-2-m), \dots, \tilde{y}(k-1) + \tilde{y}(k-2m+1))^T$ – $(m+1)$ -вектор предыстории.

Вводя далее критерий идентификации-обучения [24]

$$E_3^N = \sum_{k=2m+1}^N \left(\tilde{y}(k) + \tilde{y}(k-2m) - \hat{\beta}^T Y(k) \right)^2,$$

являющийся обобщением целевой функции E_1^N , можно получить вектор оценок $\hat{\beta}$ с помощью любого из алгоритмов обучения радиально-базисных нейронных сетей [4-6]. Далее вычисляется отфильтрованный полигармонический сигнал

$$\tilde{y}(k|N) = \hat{\beta}^T Y(k) - \tilde{y}(k-2m)$$

и, наконец, одношаговый прогноз

$$\hat{\tilde{y}}(N+1) = \hat{\beta}^T Y(N+1) - \tilde{y}(N-2m+1). \quad (9)$$

Неизвестные частоты ω_j связаны с параметрами β_j соотношением

$$\beta_1 + \sum_{j=1}^{m-1} \beta_{j+1} \cos j\omega = \cos m\omega$$

и с учетом того, что

$$\cos m\omega = \cos^m \omega - C_m^2 \cos^{m-2} \omega \sin^2 \omega + C_m^4 \cos^{m-4} \omega \sin^4 \omega + \dots$$

(здесь $C_m^j = \frac{m!}{j!(m-j)!}$), могут быть найдены путем отыскания m

корней степенного полинома аргумента $\cos \omega$.

Если процессу настройки вектора параметров $\hat{\beta}$ требуется обеспечить как фильтрующие, так и следящие свойства, можно воспользоваться обобщением алгоритма (8), который в этом случае приобретает вид

$$\begin{cases} \hat{\beta}(N+1) = \hat{\beta}(N) + \\ + r_1^{-1}(N+1) (\tilde{y}(N+1) - \tilde{y}(N-2m+1) - \hat{\beta}^T(N)Y(N+1))Y(N+1), \\ r_1(N+1) = \alpha r_1(N) + \|Y(N+1)\|^2 \end{cases} \quad (10)$$

и при $\alpha = 0$ совпадает с используемым в обучении искусственных нейронных сетей алгоритмом Качмажа-Уидроу-Хоффа.

Для построения прогноза в этом случае используется выражение (9), а нахождение оценок частот $\hat{\omega}$ связано с необходимостью решения на каждом шаге настройки уравнения

$$\hat{\beta}_1(N+1) + \sum_{j=1}^{m-1} \hat{\beta}_{j+1}(N+1) \cos j\hat{\omega}(N+1) = \cos m\hat{\omega}(N+1). \quad (11)$$

2. Архитектура искусственной нейронной сети

Развиваемый подход может быть достаточно просто реализован с помощью искусственной нейронной сети с прямой передачей информации, архитектура которой приведена на рис. 1.

Первый слой сети образован p элементами чистого запаздывания z^{-1} ($z^{-1}y(k) = y(k-1)$) так, что на его выходе формируется набор задержанных значений входного сигнала $y(k-1)$, $y(k-2)$, ..., $y(k-p)$. Вторым скрытым слоем – слоем вычисления разностей предназначен для удаления из входного сигнала полиномиального

тренда p -й степени и образован элементами взятия разности с передаточной функцией

$$G_{DIF}(z) = 1 - z^{-1}.$$

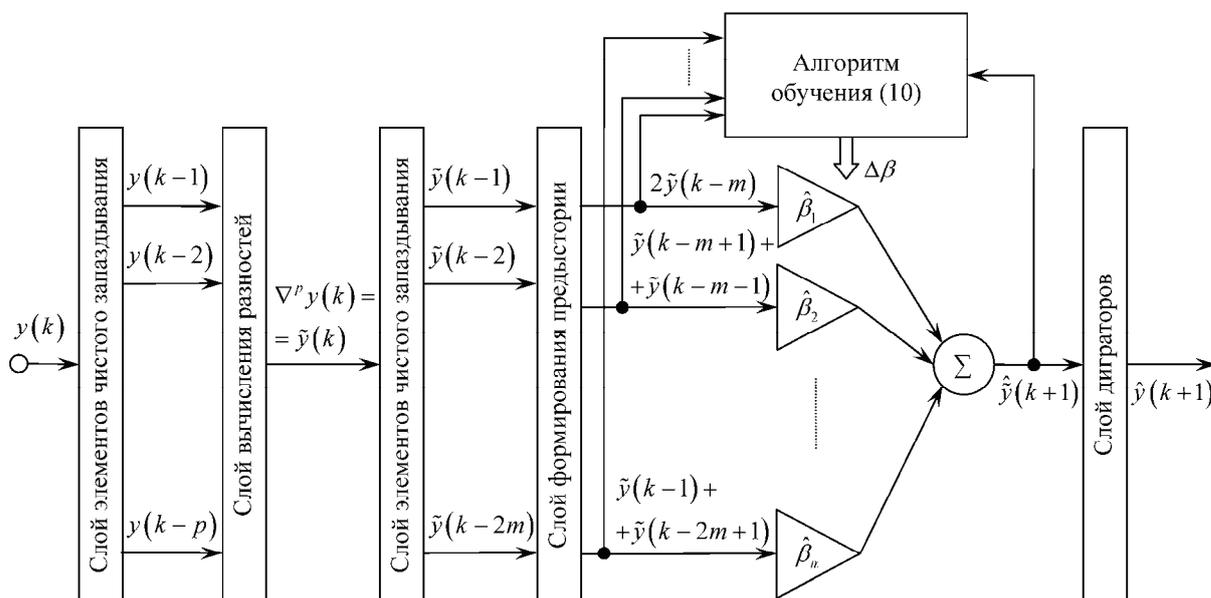


Рисунок 1 – Искусственная нейронная сеть для прогнозирования тренд-сезонных временных рядов

Схема такого элемента крайне проста и приведена на рис. 2.

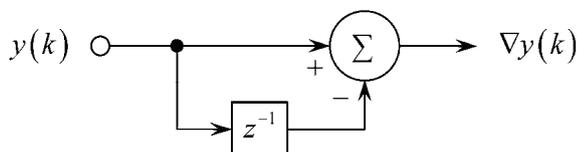


Рисунок 2 – Элемент взятия разности

Выходом этого слоя является p -я разность исходного ряда $\nabla^p y(k) = \tilde{y}(k)$, содержащая только гармонические компоненты и, возможно, случайное возмущение, присутствующее в модели (1).

Третий скрытый слой по структуре полностью аналогичен первому и содержит $2m$ элементов чистого запаздывания z^{-1} . На его выходе формируется набор задержанных значений $\tilde{y}(k-1)$, $\tilde{y}(k-2)$, ..., $\tilde{y}(k-2m)$.

Четвертый скрытый слой – слой формирования вектора предыстории $Y(k)$ – образован набором сумматоров, и на его выходе появляется набор $2\tilde{y}(k-m)$, $\tilde{y}(k-m+1) + \tilde{y}(k-m-1)$, ..., $\tilde{y}(k-1) + \tilde{y}(k-2m+1)$, который подается на пятый скрытый слой, образованный адаптивным линейным ассоциатором с настраиваемыми

синаптическими весами $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_m$, уточнение которых производится с помощью алгоритма обучения (10). На выходе этого слоя формируется одношаговый прогноз полигармонической компоненты $\hat{y}(k+1)$.

И, наконец, выходной слой диграторов образован последовательно включенными элементами с передаточной функцией

$$G_{DIG}(z) = \frac{1}{1-z^{-1}},$$

с помощью которых формируется прогноз исходного ряда $\hat{y}(k+1)$. Схема элементарного дигратора приведена на рис. 3.

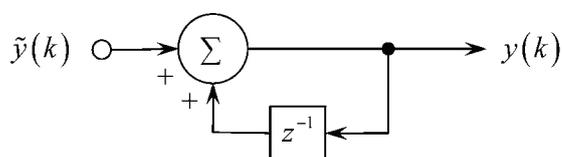


Рисунок 3 – Цифровой интегратор – дигратор

Рассматриваемая сеть предназначена для работы в последовательном режиме, обрабатывая информацию по мере ее поступления. Поэтому в ней не предусмотрен режим восстановления частот ω_j , требующий решения на каждом шаге уравнения (11).

Выводы

Рассмотрена и решена задача прогнозирования временных рядов, содержащих полиномиальный тренд и полигармоническую компоненту, возникающая в системах планирования и управления потреблением электрической энергии. Алгоритм решения предназначен для работы в последовательном режиме поступления данных, а его нейросетевая реализация позволяет повысить быстродействие за счет распараллеливания вычислений.

ЛИТЕРАТУРА

1. Шумилова Г.П., Готман Н.Э., Старцева Т.Б. Краткосрочное прогнозирование электрических нагрузок с использованием искусственных нейронных сетей // Электричество. – 1999. – N. 10. – С. 6-12.
2. Ткаченко Р.О., Павлюк О.М. Прогнозування споживання електричної енергії у Львівській області за допомогою штучних нейронних мереж // Вісник НУ «Львівська політехніка». Комп'ютерна інженерія та інформаційні технології. – 2002. – 450. – С. 76-80.
3. Бардачев Ю.Н., Гринавцев О.В., Литвиненко В.И., Фефелов А.А. Синтез и анализ работы нечетких нейронных сетей с помощью

- иммунных алгоритмов при прогнозировании электрической нагрузки // Моделивання та керування станом еколого-економічних систем регіону. – 2006. – 3. – С. 47-68.
4. Cichocki A., Unbehauen R. Neural Networks for Optimization and Signal Processing. – Stuttgart: Teubner, 1993. – 526 p.
 5. Pham D.T., Liu X. Neural Networks for Identification, Prediction and Control. – London: Springer, 1995. – 238 p.
 6. Scherer A. Neuronale Netze. Grundlagen und Anwendungen. – Braunschweig/Wiesbaden: Friedrich Vieweg & Sohn Verlagsgesellschaft mbH, 1997. – 249 S.
 7. 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. – 11. – N. 2. – P. 397-402.
 8. Tzafestas S., Tzafestas E. Computational intelligence techniques for short-term electric load forecasting // Journal of Intelligent and Robotic Systems. – 2001. – 31. – P. 7-68.
 9. 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. – 50. – N. 6. – P. 1305-1316.
 10. 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. – 5010. – P. 339-348.
 11. Бокс Д., Дженкинс Г. Анализ временных рядов. Прогноз и управление. – М.: Мир, 1974. – 406 с.
 12. Чуев Ю.В., Михайлов Ю.Б., Кузьмин В.И. Прогнозирование количественных характеристик процессов. – М.: Советское радио, 1975. – 400 с.
 13. Кобринский Н.Е. Информационные фильтры в экономике. – М.: Статистика, 1978. – 287 с.
 14. Бриллинджер Д. Временные ряды. Обработка данных и теория. – М.: Мир, 1980. – 536 с.
 15. Кашьяп Р.Л., Рао А.Р. Построение динамических стохастических моделей по экспериментальным данным. – М.: Наука, 1983. – 384 с.
 16. Льюис К.Д. Методы прогнозирования экономических показателей. – М.: Финансы и статистика, 1986. – 133 с.
 17. Montgomery D.C., Johnson L.A., Gardiner J.S. Forecasting and Time Series Analysis. – New York: McGraw-Hill, Inc., 1990. – 384 p.
 18. Ивахненко А.Г., Мюллер Й.А. Самоорганизация прогнозирующих моделей. – К.: Техніка, 1985. – 223 с.
 19. Юрачковский Ю.П., Попков Н.В. Оценивание параметров в алгоритмах МГУА моделирования полигармонических процессов и полей // Автоматика. – 1986. – N. 6. – С. 9-16.
 20. Shelekhova V.Y. Harmonic algorithm GMDH for large data volume // Systems Analysis Modelling Simulation. – 1995. – 20. – N. 1-2. – P. 117-126.

21. Бодянский Е., Воробьев С., Костюк О., Любчик Л. Фильтрация и прогнозирование тренд-сезонных временных рядов на основе искусственных нейронных сетей // Радиоэлектроника и информатика. – 1998. – № 3. – С. 76-83.
22. 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.
23. Бодянский Е.В., Плисс И.П., Соловьева Т.В. Синтез квазипрямых адаптивных регуляторов // Доклады АН УССР. – 1987. – Сер. А. – № 1. – С. 59-61.
24. Бодянский Е.В., Воробьев С.А., Плисс И.П. Адаптивная диагностика динамического объекта с периодическим выходным сигналом // Праці 3-ї Української конференції з автоматичного керування "Автоматика-96". – Севастополь, 1996. – 1. – С. 58-59.