

## ФИЛЬТРАЦИЯ И ПРОГНОЗИРОВАНИЕ ТРЕНД- СЕЗОННЫХ ВРЕМЕННЫХ РЯДОВ НА ОСНОВЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

БОДЯНСКИЙ Е.В., ВОРОБЬЕВ С.А.,  
КОСТЮК О.В., ЛЮБЧИК Л. М.

Рассматриваются задачи фильтрации и прогнозирования тренд-сезонных временных рядов. Приводится многоэтапная адаптивная схема решения этих задач, построенная с учетом их особенностей. Основной проблемой при этом является нестационарность таких последовательностей. Показывается, что проблемы, возникающие при анализе спектрального состава, фильтрации и прогнозировании таких последовательностей, имеют весьма простое решение с помощью методов теории адаптивных систем и искусственных нейронных сетей.

Задача обработки нестационарных стохастических последовательностей с тренд-сезонной компонентой достаточно часто встречается на практике и, прежде всего, в экономическом прогнозировании и технической диагностике [1-9]. При этом предполагается, что анализируемый ряд может быть представлен в виде модели

$$\tilde{y}_k = \sum_{i=0}^p \tilde{a}_i k^i + \sum_{j=1}^m (\tilde{a}_j \cos \omega_j k + \tilde{b}_j \sin \omega_j k) + \tilde{\xi}_k, \quad (1)$$

или через оператор сдвига назад  $z^{-1}$ :

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

Здесь  $p$  и  $m$  — порядок полиномиальной компоненты и количество гармоник в последовательности  $\tilde{y}_k$  соответственно;  $\tilde{a}_i, \tilde{a}_j, \tilde{b}_j$  — коэффициенты модели, в общем случае неизвестные;  $0 < \omega_j = 2\pi f_j T_0 < \pi$  — неизвестные частоты гармонических компонент, при этом  $\omega_i \neq \omega_j, i \neq j$ ;  $T_0$  — период квантования;  $k = 1, 2, \dots, N$  — дискретное время;  $\tilde{\xi}_k$  — стохастическая компонента типа белого шума с нулевым математическим ожиданием и ограниченным вторым моментом. В общем случае модель должна иметь несмещенную структуру (значение  $m$  известно заранее), что, однако, не является обременительным ограничением.

Для оценивания неизвестных параметров модели (1) в [1-9] предлагается использовать метод наимень-

ших квадратов, при этом частоты  $\omega_j$  полагаются известными, поскольку входят в описание ряда нелинейно и их оценивание сопряжено со значительными трудностями. Однако в ряде случаев именно частоты представляют особый интерес, в связи с чем необходимо предусмотреть возможность их оценивания параллельно с коэффициентами  $\tilde{a}_i, \tilde{a}_j, \tilde{b}_j$ .

В [10-12] предложена многоэтапная схема оценивания параметров полигармонических сигналов, которая для нашего случая может быть представлена в следующем виде:

1. Исключение полиномиальной компоненты путем взятия  $(p+1)$ -й разности последовательности

$$\tilde{y}_k \text{ или вычитание из } \tilde{y}_k \text{ компоненты } \sum_{i=0}^p \tilde{a}_i k^i, \text{ где}$$

$\tilde{a}_i$  — оценки, получаемые с помощью метода наименьших квадратов.

2. Оценка параметров модели

$$\prod_{j=1}^m (1 - 2 \cos \omega_j z^{-1} + z^{-2}) y_k = \xi_k$$

с помощью метода наименьших квадратов.

3. Восстановление оценки частот  $\hat{\omega}_j$  путем нахождения корней полинома  $m$ -й степени.

4. Нахождение оценок  $\hat{a}_j, \hat{b}_j$  с помощью метода наименьших квадратов и пересчет их в оценки  $\hat{\tilde{a}}_j, \hat{\tilde{b}}_j$ .

5. Дигрирование центрированного сигнала  $y_k$  и получение отфильтрованной оценки ряда  $\tilde{y}_k$ .

В качестве иллюстрации данного подхода рассмотрим несколько простых примеров.

Пусть в (1)  $p = 0$ , т. е. анализируемая последовательность  $\tilde{y}_k$  колеблется относительно среднего уровня  $d_0$ . Исключить его можно путем взятия первой разности, т. е. переходя к последовательности  $y_k$  такой, что

$$y_k = \sum_{j=1}^m (a_j \cos \omega_j k + b_j \sin \omega_j k) + \xi_k, \quad (3)$$

или

$$\prod_{j=1}^m (1 - 2 \cos \omega_j z^{-1} + z^{-2}) y_k = \xi_k, \quad (4)$$

где  $y_k = \tilde{y}_k - \tilde{y}_{k-1}$ ,  $\xi_k = \tilde{\xi}_k - \tilde{\xi}_{k-1}$ . При этом несложно видеть, что существует однозначная связь между коэффициентами

$$\begin{cases} a_j = \tilde{a}_j (1 - \cos \omega_j) + \tilde{b}_j \sin \omega_j, \\ b_j = \tilde{b}_j (1 - \cos \omega_j) - \tilde{a}_j \sin \omega_j. \end{cases} \quad (5)$$

Оценивание параметров модели (3), (4) с помощью метода наименьших квадратов осложняется тем, что шум  $\xi_k$  уже не является белым, что может привести к смещённым (ридж-) оценкам [11], хотя в [12] и утверждается, что такое смещение не возникает. Так или иначе, в ряде случаев удобнее из  $\tilde{y}_k$  вычесть среднее

$$\hat{d}_0 = \bar{y} = \frac{1}{N} \sum_{k=1}^N \tilde{y}_k \quad (6)$$

и перейти к центрированному сигналу  $y_k$  с белым шумом  $\tilde{\xi}_k$ . Этот процесс можно организовать в реальном времени, вычисляя на каждом такте среднее

$$\hat{d}_{0,k} = \bar{y}_k = \frac{1}{k} \tilde{y}_k + \frac{k-1}{k} \bar{y}_{k-1} \quad (7)$$

и центрированное значение  $y_k = \tilde{y}_k - \bar{y}_k$ . Если средний уровень  $d_0$  варьирует во времени, то вместо (7) можно использовать экспоненциальное среднее

$$\hat{d}_{0,k} = \bar{y}_k = \alpha \tilde{y}_k + (1-\alpha) \bar{y}_{k-1}, \quad (8)$$

где  $0 < \alpha < 1$  — параметр сглаживания [2, 7]. Далее переходим к пункту 2 многоэтапной схемы оценивания.

Пусть тестовый временной ряд генерируется с помощью следующей модели:

$$\tilde{y}_k = d_0 + \sum_{j=1}^2 \sin 2\pi f_j T_0 k + \xi_k.$$

Здесь  $d_0 = 2,4$ ;  $f_1 = 50$ ;  $f_2 = 120$ ;  $T_0 = 1$  — квант машинного времени;  $\xi_k$  — последовательность случайных величин с нулевым средним и среднеквадратическим отклонением  $\sigma_{\xi} = 2$ , т. е. генерируемый гармонический ряд сильно искажен действием помехи и смещен относительно центра на величину 2,4.

Ряд  $\tilde{y}_k$  показан на рис. 1. На рис. 2 приведена первая разность ряда  $\tilde{y}_k$ . Очевидно, что первая разность колеблется относительно нуля. Таким образом, последовательность  $y_k = \tilde{y}_k - \bar{y}_{k-1}$  является центрированной. На рис. 3 также представлены среднее ряда  $\tilde{y}_k$ , вычисленное по формуле (7), и центрированный ряд  $y_k = \tilde{y}_k - \hat{d}_{0,k}$ . Из-за действия интенсивной помехи среднее ряда  $\tilde{y}_k$  варьирует во времени.

Пусть теперь в (3)  $m = 1$ , т. е. в сигнале присутствует лишь одна гармоника с частотой  $\omega$ . Тогда (4) можно переписать в виде

$$(1 - 2 \cos \alpha z^{-1} + z^{-2}) y_k = \xi_k, \quad (9)$$

$$(1 - \beta 2z^{-1} + z^{-2}) y_k = \xi_k, \quad (10)$$




Рис. 1. Временной ряд  $\tilde{y}_k$




Рис. 2. Ряд первой разности

$$y_k = \tilde{y}_k - \tilde{y}_{k-1}$$




Рис. 3. Среднее  $\hat{d}_{0,k}$  и центрированный ряд

$$y_k = \tilde{y}_k - \hat{d}_{0,k}$$

$$y_k = \beta 2y_{k-1} - y_{k-2} + \xi_k \quad (11)$$

и ввести критерий идентификации

$$J_1 = \sum_{k=3}^N ((y_k + y_{k-2}) - \hat{\beta} 2y_{k-1})^2, \quad (12)$$

минимизация которого ведёт к оценке

$$\hat{\beta} = \frac{\sum_{k=3}^N (y_k + y_{k-2}) y_{k-1}}{2 \sum_{k=3}^N y_{k-1}^2}. \quad (13)$$

Заметим, что если  $y_k$  есть  $p$ -я разность процесса  $\tilde{y}_k$ , то нижний индекс суммирования в (12) начинается с  $k = p + 3$ .

Далее несложно найти оценку частоты

$$\hat{\omega} = \arccos \hat{\beta}, \quad (14)$$

отфильтрованный сигнал

$$y_{k,N} = 2\hat{\beta} y_{k-1} - y_{k-2} \quad (15)$$

и прогноз на один шаг

$$\hat{y}_{N+1} = 2\hat{\beta}y_N - y_{N-1}. \quad (16)$$

В принципе задачу фильтрации и прогнозирования можно на этом считать решённой, однако, если необходимо, можно перейти к пункту 4 многоэтапной схемы; ввести критерий идентификации

$$J_2 = \sum_{k=3}^N (y_k - \hat{a} \cos \hat{\omega}k - \hat{b} \sin \hat{\omega}k)^2 = \sum_{k=3}^N (y_k - (\hat{a}, \hat{b}) \begin{pmatrix} \cos \hat{\omega}k \\ \sin \hat{\omega}k \end{pmatrix})^2 \quad (17)$$

и получить оценки коэффициентов в виде

$$\begin{pmatrix} \hat{a} \\ \hat{b} \end{pmatrix} = \begin{pmatrix} \sum \cos^2 \hat{\omega}k & \sum \cos \hat{\omega}k \sin \hat{\omega}k \\ \sum \cos \hat{\omega}k \sin \hat{\omega}k & \sum \sin^2 \hat{\omega}k \end{pmatrix}^{-1} \times \begin{pmatrix} \sum \cos \hat{\omega}ky_k \\ \sum \sin \hat{\omega}ky_k \end{pmatrix} \quad (18)$$

Задача оценивания параметров  $\omega$ ,  $a$  и  $b$  может быть решена в реальном времени, для чего целесообразно воспользоваться экспоненциально взвешенной процедурой стохастической аппроксимации [13-15], обеспечивающей компромисс между фильтрующими и следящими свойствами процесса идентификации. В этом случае, если по  $N$  наблюдениям были получены оценки  $\hat{\omega}_N$ ,  $\hat{a}_N$ ,  $\hat{b}_N$ , то с приходом  $N+1$ -го наблюдения производится уточнение согласно рекуррентной схеме

$$\begin{cases} \hat{\beta}_{N+1} = \hat{\beta}_N + r_{N+1}^{-1} (y_{N+1} + y_{N-1} - \\ - \hat{\beta}_N 2y_N) 2y_N, \\ r_{N+1} = \gamma r_N + 4y_N^2, \quad 0 \leq \gamma \leq 1, \\ \hat{\omega}_{N+1} = \arccos \hat{\beta}_{N+1}, \end{cases} \quad (19)$$

$$\begin{cases} \begin{pmatrix} \hat{a}_{N+1} \\ \hat{b}_{N+1} \end{pmatrix} = \begin{pmatrix} \hat{a}_N \\ \hat{b}_N \end{pmatrix} + R_{N+1}^{-1} (y_{N+1} - \hat{a}_N \times \\ \times \cos \hat{\omega}_{N+1}(N+1) - \hat{b}_N \sin \hat{\omega}_{N+1}(N+1)) \times \\ \times \begin{pmatrix} \cos \hat{\omega}_{N+1}(N+1) \\ \sin \hat{\omega}_{N+1}(N+1) \end{pmatrix}; \\ R_{N+1} = \gamma R_N + 1, \quad 0 \leq \gamma \leq 1. \end{cases} \quad (20)$$

Несложно видеть, что при  $\gamma = 0$  (20) превращается в градиентную процедуру с единичным шагом, а при  $\gamma = 1$  – в алгоритм Кифера-Вольфовица.

Заметим, что в многоэтапной схеме результаты каждого этапа влияют на точность последующего, поэтому неточность в определении оценки  $\hat{\beta}$  влечёт за собой накопление погрешностей в оценках  $\hat{\omega}$ ,  $\hat{a}$ ,

$\hat{b}$ . Поэтому если для решения задачи фильтрации и прогнозирования достаточно лишь  $\hat{\beta}$  (см. (15), (16)), то этим и следует ограничиться.

Рассмотрим ещё один численный пример. В этот раз временной ряд генерируется моделью вида

$$\tilde{y}_k = 0,93 \sin 2\pi T_0 k + \xi_k.$$

Здесь  $f = 50$ ,  $\xi_k$  – последовательность случайных величин с нулевым средним и дисперсией, равной 0,4.

Ряд  $\tilde{y}_k$  и его прогноз  $\hat{y}_k$  приведены на рис. 4. На рис. 5 показан средний квадрат ошибки прогнозирования.




Рис.4. Ряд  $\tilde{y}_k$  и прогноз  $\hat{y}_k$




Рис.5. Средний квадрат ошибки прогнозирования

$$\bar{e}_k^2 = \frac{1}{k} \sum_{i=1}^k (\tilde{y}_i - \hat{y}_i)^2$$

На рис. 6 и 7 соответственно представлены оценки параметра модели (11)  $\hat{\beta}_k$  и частоты сезонной составляющей ряда  $\hat{\omega}_k$ , полученные на основании алгоритма (19). Очевидно, что значение параметра  $\beta$ , описывающего сезонную составляющую ряда  $\tilde{y}_k$ , должно быть равно  $\beta \approx 0,6427$ . Однако оцениваемое значение  $\beta$  незначительно варьирует. Это




Рис.6. Оценка параметра  $\hat{\beta}_k$

рации и  
5), (16)),  
р. В Этом  
ида  
чайных  
ной 0,4.  
рис. 4.  
прогно-




Рис. 7. Оценка частоты  $\hat{\omega}_k$

связано с действующим шумом. Заметим, что в алгоритме (19) параметр  $\gamma$  был выбран равным 0,9 для усиления фильтрующих свойств алгоритма.

Далее рассмотрим процедуру идентификации параметров модели (3), (4), содержащей  $m$  гармоник неизвестных частот. Путём несложных преобразований можно привести (4) к виду

$$y_k = \sum_{j=0}^{m-1} \beta_{j+1} (y_{k+j-m} + y_{k-j-m}) - y_{k-2m} + \xi_k = \beta_1 2y_{k-m} + \beta_2 (y_{k+1-m} + y_{k-1-m}) + \beta_3 (y_{k+2-m} + y_{k-2-m}) + \dots + \beta_m (y_{k-1} + y_{k-2m+1}) - y_{k-2m} + \xi_k = \beta^T y(k, m) - y_{k-2m} + \xi_k, \quad (21)$$

где  $\beta = (\beta_1, \beta_2, \dots, \beta_m)^T$ ,  $y(k, m) = (2y_{k-m}, y_{k-m+1} + y_{k-m-1}, y_{k-m+2} + y_{k-m-2}, \dots, y_{k-1} + y_{k-2m+1})^T$  —  $(m \times 1)$  векторы параметров и предыстории последовательности соответственно.

Вводя далее критерий идентификации

$$J_I = \sum_{k=2m+1}^N ((y_k + y_{k-2m}) - \hat{\beta}^T y(k, m))^2 \quad (22)$$

и используя стандартную процедуру наименьших квадратов, получаем вектор оценок  $\hat{\beta}$ . Далее можно построить отфильтрованный сигнал (гармонический тренд)

$$y_{k,N} = \hat{\beta}^T y(k, m) - y_{k-2m} \quad (23)$$

и прогноз

$$\hat{y}_{N+1} = \hat{\beta}^T y(N+1, m) - y_{N-2m+1}. \quad (24)$$

Неизвестные частоты  $\omega_j$  связаны с параметрами  $\beta_j$  соотношением

$$\beta_1 + \sum_{j=1}^{m-1} \beta_{j+1} \cos j\omega = \cos m\omega \quad (25)$$

и с учётом того, что

$$\cos m\omega = \cos^m \omega - C_m^2 \cos^{m-2} \omega \sin^2 \omega + C_m^4 \cos^{m-4} \omega \sin^4 \omega + \dots \quad (26)$$

(здесь  $C_m^j = \frac{m!}{j!(m-j)!}$ ), могут быть найдены при отыскании  $m$  корней степенного полинома от аргумента  $\cos \omega$ .

Переходя к работе в реальном времени, запишем экспоненциально взвешенную процедуру стохастической аппроксимации, которая в данном случае имеет вид

$$\begin{cases} \hat{\beta}_{N+1} = \hat{\beta}_N + r_{N+1}^{-1} (y_{N+1} + y_{N-2m+1} - \hat{\beta}_N^T y(N+1, m)) y(N+1, m), \\ r_{N+1} = r_N + \|y(N+1, m)\|^2, \quad 0 \leq r \leq 1. \end{cases} \quad (20)$$

При  $\gamma = 1$  она принимает форму алгоритма Гудвина-Рэмеджа-Кэйнеса, широко распространённого в адаптивных системах управления, а при  $\gamma = 0$  — алгоритма Уидроу-Хоффа, применяемого для обучения искусственных нейронных сетей.

При этом прогноз может быть записан в виде

$$\hat{y}_{N+1} = \hat{\beta}_N^T y(N+1, m) - y_{N-2m+1}, \quad (21)$$

а отфильтрованный сигнал —

$$y_{N+1,N+1} = \hat{\beta}_{N+1}^T y(N+1, m) - y_{k-2m+1}. \quad (25)$$

Определение оценок частот связано с необходимостью решения на каждом такте уравнения

$$\hat{\beta}_{1,N+1} + \sum_{j=1}^{m-1} \beta_{j+1,N+1} \cos j\hat{\omega}_{N+1} = \cos m\hat{\omega}_{N+1}, \quad (30)$$

однако поскольку получение положительных действительных корней (30) в общем случае не гарантируется, этого этапа следует по возможности избегать.

Приведем пример, демонстрирующий работу полученного алгоритма. Ряд генерируется с помощью модели вида

$$\tilde{y}_k = 0,93 \sin 2\pi 50k + 1,34 \sin 2\pi 120k + \xi_k.$$

Характеристики  $\xi_k$  следующие: математическое

ожидание равно 0 и  $\sigma_\xi = 1,1$ . Ряд  $\tilde{y}_k$  и прогноз  $\hat{y}_k$ , а также средний квадрат ошибки прогнозирования приведены соответственно на рис. 8 и 9.




Рис. 8. Ряд  $\tilde{y}_k$  и его прогноз  $\hat{y}_k$

енки  
ной  
нии  
етра  
ряда  
ни-  
Это




Рис. 9. Средний квадрат ошибки прогнозирования  $\bar{e}_k^2$

На рис. 10 изображены оценки коэффициентов  $\hat{\beta}_{1,k}$  и  $\hat{\beta}_{2,k}$ , настраиваемые в соответствии с алгоритмом (27). Как и в предыдущем примере, в (27)  $\gamma$  равно 0,9.




Рис. 10. Оценки коэффициентов  $\hat{\beta}_{1,k}$  и  $\hat{\beta}_{2,k}$

Заметим, что из-за действия шума в спектре ряда на частоте  $f_3 = 270$  присутствует небольшой всплеск, что указывает на наличие ложной гармоники небольшой амплитуды.

В пользу адаптивного подхода к рассматриваемой задаче, кроме численной простоты, свидетельствует также следующее:

1. Возможность работы в условиях нестационарности, т. е. девиации частот. При этом следящие свойства алгоритма определяются варьированием параметра  $\gamma$  в (27).
  2. Возможность работы в условиях "цветных" шумов  $\xi_k$ . При этом вектор  $y(k, m)$  расширяется путём введения обновлений.
  3. Защита от проблем, связанных с вырождением процедуры при больших  $N$  [12]. При этом объём обрабатываемой информации ограничивается в результате использования  $\gamma < 1$ .
  4. Возможность организации в реальном времени процедуры контроля над изменениями свойств обрабатываемой последовательности, т. е. раннего обнаружения разладок [8, 9, 16, 17].
  5. Возможность распараллеливания вычислений и использования для обработки информации технологии искусственных нейронных сетей [18-20].
- На рис. 11, 12 приведена схема искусственной нейронной сети, реализующей процесс прогнозирования и фильтрации тренд-сезонного временного ряда. Данная сеть состоит из двух независимых частей, первая

из которых (рис. 11) обрабатывает полиномиальную компоненту ряда, а вторая (рис. 12) — сезонную. Входной слой сети на рис. 11 образован элементом чистой задержки  $z^{-1}$ , вследствие чего на первый скрытый слой, образованный сумматорами  $\Sigma$ , параллельно подаются сигналы  $\tilde{y}_k, \tilde{y}_{k-1}, \dots, \tilde{y}_{k-p}$ . На выходе первого скрытого слоя формируются сигналы разностей  $\nabla \tilde{y}_k, \nabla \tilde{y}_{k-1}, \dots, \nabla \tilde{y}_{k-p+1}$ , которые подаются на сумматоры второго скрытого слоя, вычисляющего вторые разности  $\nabla^2 \tilde{y}_k, \nabla^2 \tilde{y}_{k-1}, \dots, \nabla^2 \tilde{y}_{k-p+2}$ . На выходе  $p$ -го скрытого слоя, образованного одним сумматором, вычисляется сигнал  $p$ -й разности  $\nabla^p \tilde{y}_k$ . Сигналы разностей подаются на усредняющие элементы  $\alpha$ , реализующие рекуррентный алгоритм (8) и вычисляющие средние значения  $\overline{\tilde{y}_k}, \overline{\nabla \tilde{y}_k}, \overline{\nabla^2 \tilde{y}_k}, \dots, \overline{\nabla^p \tilde{y}_k}$ . Сигналы среднего подаются на релейные элементы, имеющие два состояния: 0, если соответствующее среднее равно нулю, и 1 в противном случае. Выходы реле подаются на входы логических элементов  $\Lambda$ , реализующих операцию типа  $\overline{w} = (\overline{x \wedge y}) \wedge x$  и фактически фиксирующих наименьший порядок разности, не имеющей полиномиального тренда. Схема, приведенная на рис. 11, соответствует ряду с линейным трендом, у которого  $\overline{\nabla^2 \tilde{y}_k} = 0$ , что обнаружено логическим элементом, на входы которого поданы сигналы  $x = 1, y = 0$ . Контроль над выходами логических элементов позволяет обнаруживать в реальном времени изменения порядка полиномиального тренда. Кроме того, логические элементы управляют ключами  $K$ , которые открываются только при подаче на них сигнала, соответствующего единице. Таким образом, на входы выходного сумматора  $\bar{\Sigma}$  подаётся сигнал лишь той разности, которой соответствует единичный выход логического элемента  $\Lambda$ . В данном случае отпирается только ключ, соответствующий второй разности, в результате чего на выходе данной части сети появляется центрированный сигнал  $y_k = \nabla^2 \tilde{y}_k$ .

Вторая половина сети (рис. 12) обрабатывает сигнал  $y_k$  с исключенной полиномиальной компонентой и содержит во входном слое  $2m$  элементов чистой задержки. Сумматорами первого скрытого слоя формируется вектор предыстории  $y(k, m)$ . Он подаётся на  $m$ -входовую адалину, обучение которой осуществляется с помощью алгоритма (27). На выходе адалины появляется отфильтрованная оценка  $\hat{y}_k$ , которая, будучи обработана цепочкой, состоящей из  $p$  диграторов, даёт прогноз исходного ряда  $\hat{y}_k$ . Дигрирование удобно также производить в соответствии с выражением

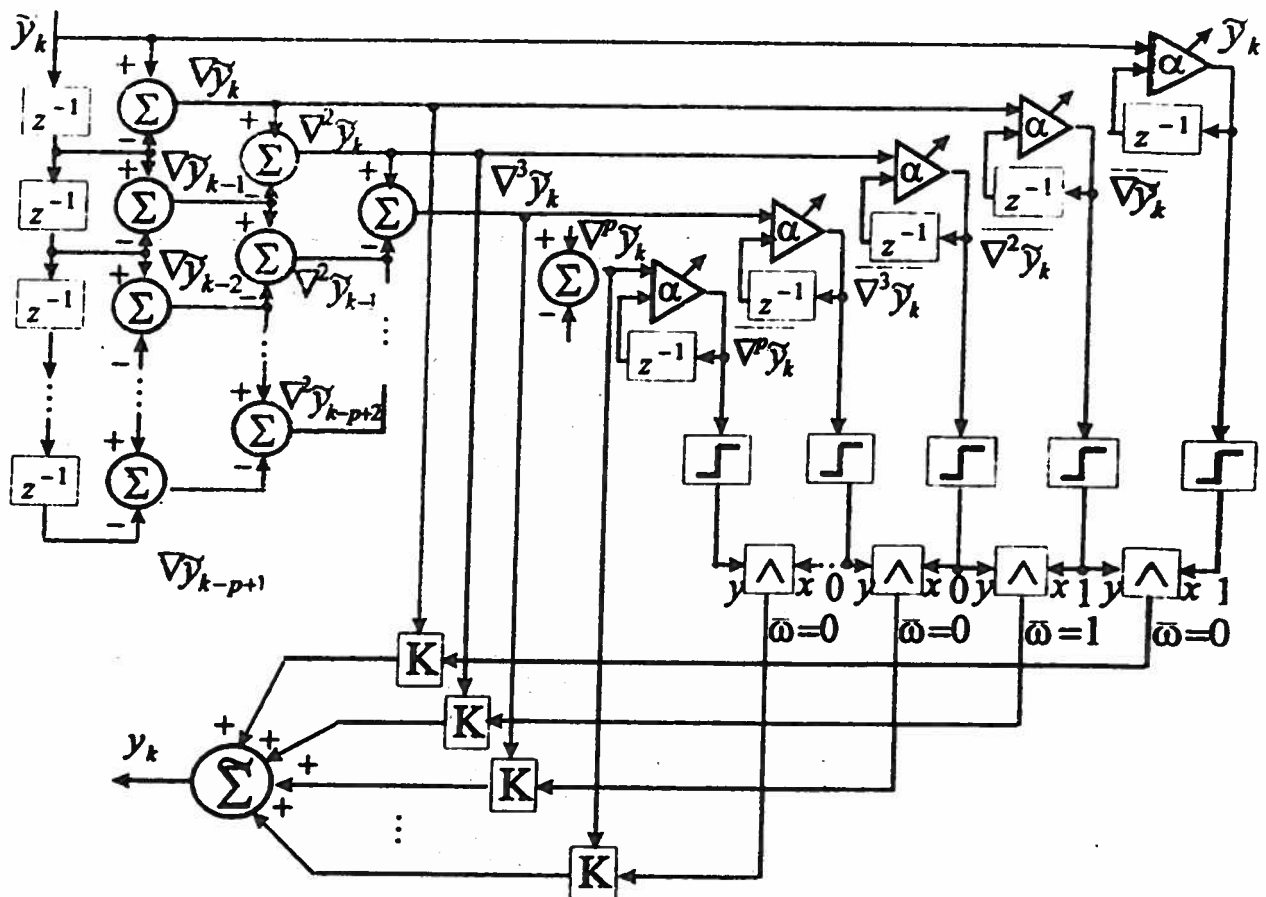


Рис. 11. Искусственная нейронная сеть для анализа полиномиального тренда

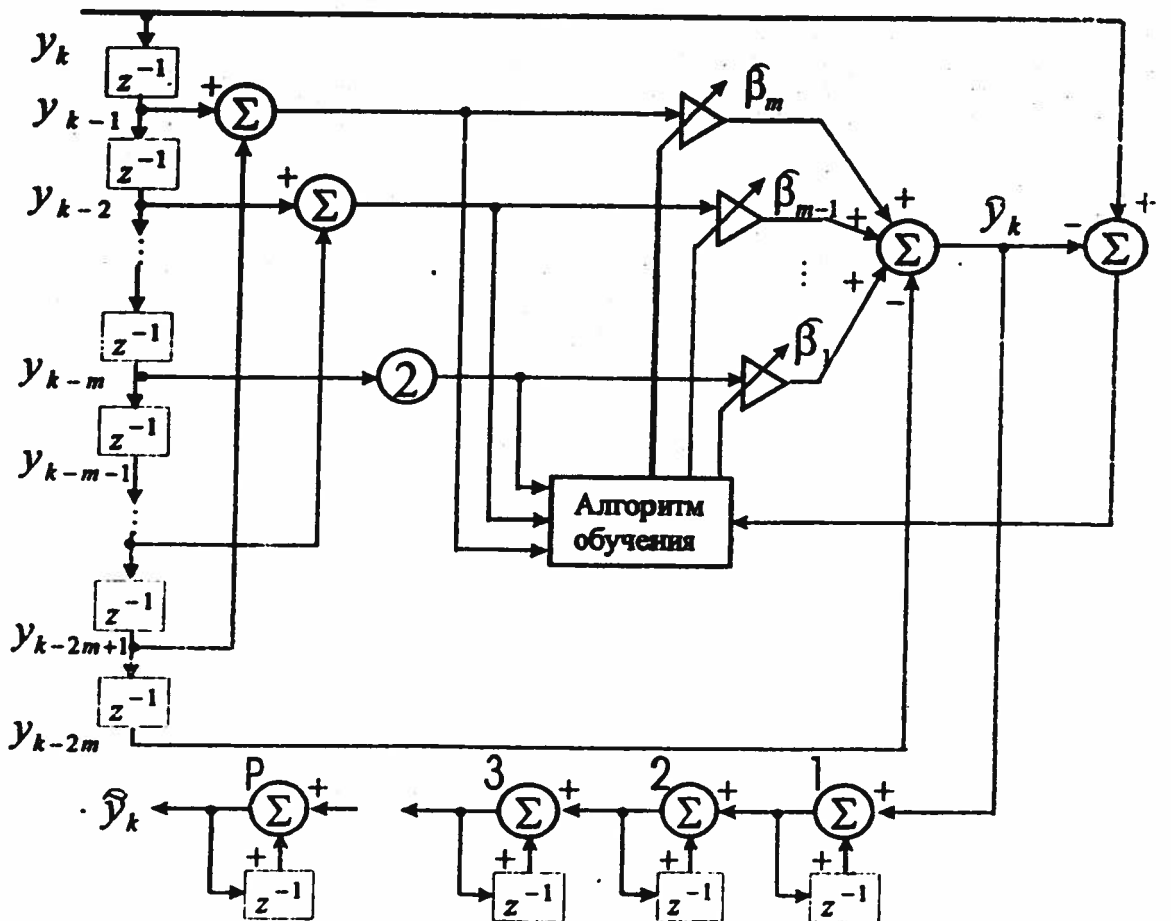


Рис. 12. Искусственная нейронная сеть для фильтрации тренд-сезонного временного ряда

$$\hat{y}_k = \sum_{i=1}^p (-1)^i C_i^p \hat{y}_{k-i} - \nabla^p \hat{y}_k. \quad (31)$$

Контроль над возможными изменениями ряда  $y_k$  осуществляется путём анализа поведения синаптических весов адалины  $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_m$  и является достаточно элементарной процедурой [9].

Таким образом, на основе использования методов теории адаптивных систем и искусственных нейронных сетей удаётся получить весьма простое решение задачи фильтрации, прогнозирования и обнаружения разладок в тренд-сезонных стохастических последовательностях.

**Литература:** 1. Бокс Дж., Дженкинс Г. Анализ временных рядов. Прогноз и управление. М.: Мир, 1974. 406 с. 2. Чув Ю.В., Михайлов Ю.Б., Кузьмин В.И. Прогнозирование количественных характеристик процессов. М.: Сов. радио, 1975. 400 с. 3. Кобринский Н.Е. Информационные фильтры в экономике. М.: Статистика, 1978. 287 с. 4. Бриллинджер Д. Временные ряды. Обработка данных и теория. М.: Мир, 1980. 536 с. 5. Кашьяп Р.Л., Рао А.Р. Построение динамических стохастических моделей по экспериментальным данным. М.: Наука, 1983. 384 с. 6. Льюис К.Д. Методы прогнозирования экономических показателей. М.: Финансы и статистика, 1986. 133 с. 7. Montgomery D.C., Johnson L.A., Gardiner J.S. Forecasting and Time Series Analysis. N.Y.: McGraw-Hill, Inc., 1990. 384 p. 8. Isermann R. Fault diagnosis of machines via parameter estimation and knowledge processing. Tutorial paper // Automatica. 1993. 29. № 4. P.815-835. 9. Paulozos A.D., Stavrakakis G.S. Real Time Fault Monitoring of Industrial Processes. Dordrecht: Kluwer Academic Publisher, 1994. 542 p. 10. Иващенко А.Г., Маллер Я.А. Самоорганизация прогнозирующих моделей. К.: Техніка, 1985; Берлин: ФЭБ Ферлаг Техник, 1984. 223 с. 11. Юрчиковский Ю.П., Полков Н.В. Оценивание параметров в алгоритмах МГУА моделирования полигармонических процессов и полей // Автоматика. 1986. №6. С.9-16. 12. Shelekhova V.Yu. Harmonic algorithm GMDH for large data volume // SAMS. 1995. 20. P.117-126. 13. Бодянский Е.В., Паусс И.П., Соловьева Т.В. Многошаговые оптимальные предикторы многомерных нестационарных стохастических процессов // Докл. АН УССР. 1986. Сер. А. №12. С.47-49. 14. Бодянский Е.В., Паусс И.П., Соловьева Т.В. Синтез квазипрямых адаптив-

ных регуляторов // Докл. АН УССР. 1987. Сер. А. №1. С.59-61. 15. Бодянский Е.В., Руденко О.Г. Адаптивные модели в системах управления техническими объектами. К.: УМК ВО, 1988. 212 с. 16. Бодянский Е.В., Воробьёв С.А., Паусс И.П. Адаптивная диагностика динамического объекта с периодическим выходным сигналом // Праці 3-ї Української конференції з автоматичного керування "Автоматика-96". Т.1. Севастополь: СевГТУ, 1996. С.58-59. 17. Воробьёв С.А., Паусс И.П. Адаптивная диагностика динамического объекта с периодическим выходным сигналом // Деп. в УкрИНТЭИ 18.11.96. №130. Харьков, 1996. 14 с. 18. Cichocki A., Unbehauen R. Neural Networks for Optimization and Signal Processing. Stuttgart: Teubner, 1993. 526 p. 19. Pham D.T., Liu X. Neural Networks for Identification, Prediction and Control. London: Springer-Verlag, 1995. 238p. 20. Scherer A. Neuronale Netze. Grundlagen und Anwendungen. Braunschweig/Wiesbaden: Friedr. Vieweg & Sohn Verlagsgesellschaft mbH, 1997. 249 s.

Поступила в редколлегию 23.07.98

Рецензент: д-р техн. наук Алексеев О.П.

**Бодянский Евгений Владимирович**, д-р техн. наук, профессор кафедры ТК ХТУРЭ. Научные интересы: теория адаптивных систем, искусственные нейронные сети, техническая диагностика, гармонический анализ. Хобби: фелинология, восточные учения, японская поэзия, история. Адрес: Украина, 310145, Харьков, пр. Ленина, 14. e-mail: bodya@kture.kharkov.ua

**Воробьёв Сергей Алятович**, канд. техн. наук, старший научный сотрудник ПНИЛАСУ ХТУРЭ. Научные интересы: искусственные нейронные сети, фильтрация и прогнозирование нестационарных процессов, фракталы и фрактальная размерность. Хобби: психология, иностранные языки, музыка. Адрес: Украина, 310726, Харьков, пр. Ленина, 14. e-mail: svor@kture.kharkov.ua

**Костюк Ольга Васильевна**, стажёр-исследователь кафедры САУ ХГПУ. Научные интересы: моделирование динамических систем, гармонический анализ, анализ нестационарных периодических процессов. Хобби: шитьё, горный туризм. Адрес: Украина, 310002, Харьков, ул. Фрунзе, 21.

**Любчик Леонид Михайлович**, д-р техн. наук, профессор кафедры САУ ХГПУ. Научные интересы: теория управления, адаптивные системы, анализ и прогнозирование случайных процессов, искусственные нейронные сети. Хобби: литература, искусство, живопись. Адрес: Украина, 310002, Харьков, ул. Фрунзе, 21. E-mail: Lyubchik@lotus.kpi.kharkov.ua

