УДК 621.31

А.А.ЧЕРНЫШ, *студент, ассистент профессора*, *cher041@gmail.com*
О.Б.ШОНИН, *д-р техн. наук, профессор, nisosh_eltec@mail.ru*
Санкт-Петербургский государственный горный институт (*технический университет*)

A.A.CHERNYSH, *student, professor's assistant*, *cher041@gmail.com*
O.B.SHONIN, *Dr. in eng. sc., professor*, *nisosh_eltec@mail.ru*
Saint Petersburg State Mining Institute (*Technical University*)

ПРОГНОЗИРОВАНИЕ ЭНЕРГОПОТРЕБЛЕНИЯ ГОРНЫХ ПРЕДПРИЯТИЙ НА ОСНОВЕ СТОХАСТИЧЕСКИХ МОДЕЛЕЙ ВРЕМЕННЫХ РЯДОВ

Рассматривается построение моделей временных рядов применительно к задаче прогнозирования графиков нагрузки горного предприятия. Приведены результаты прогноза на основе различных моделей линейного фильтра и искусственной нейронной сети. Показана возможность повышения точности прогнозирования при использовании разложения исходного временного ряда с помощью вейвлет-преобразования.

Ключевые слова: график нагрузки, временной ряд, модель временного ряда, прогнозирование.

FORECASTING THE POWER CONSUMPTION OF MINES ON THE BASIS OF STOCHASTIC TIME-SERIES MODELS

The paper is devoted to building up time series models to forecast the power consumption of a mine. The results discussed are obtained using various linear filter models and artificial neural network. The wavelet transform of the raw time series is shown to be an efficient technique to increase the forecasting accuracy.

Key words: power consumption, time series, time series model, forecasting.

Одним из возможных путей снижения затрат на электроэнергию для горного предприятия является выход на оптовый рынок электроэнергии и мощности, который предполагает предоставление продавцу графиков потребления электроэнергии на сутки вперед. В случае совпадения заявленной и потребленной электроэнергии затраты на электроэнергию минимальны. В связи с этим возникает задача прогнозирования энергопотребления и возрастают требования к точности прогнозирования графиков нагрузки.

Для решения поставленной задачи использованы данные по энергопотреблению подстанции «Заполярная» ОАО «Воркутауголь» (рис.1).

График активной, реактивной или полной мощности горного предприятия можно рассматривать как временной ряд и как реализацию случайного процесса. Для инженерных расчетов применяют числовые характеристики графика нагрузки: коэффициент заполнения, коэффициент максимума, коэффициент формы. Для описания временных рядов используют стохастические модели, одной из которых является модель ли-

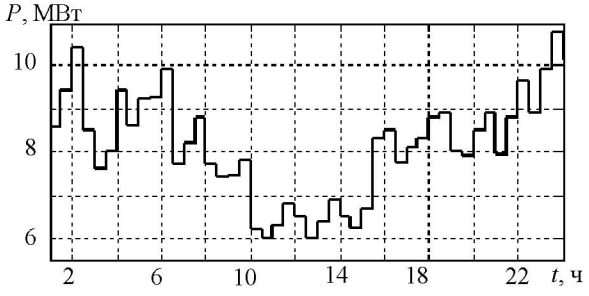


Рис.1. Суточный график активной мощности подстанции «Заполярная» ОАО «Воркутауголь»

нейного фильтра [1]. Эта модель генерирует на выходе фильтра временной ряд как реакцию на входной сигнал в виде «белого шума». В дискретной области фильтр описывается уравнением

$$z_k = \mu + a_k + \psi_1 a_{k-1} + \\ + \psi_2 a_{k-2} + \ldots + \psi_m a_{k-m}, \qquad (1)$$

где z_k – реакция фильтра на входной сигнал; μ – среднее значение временного ряда; a_k – выборки входного сигнала в моменты $t_k = kT_d$; $\psi_1, \psi_2, \ldots, \psi_n$ – параметры модели; m – порядок модели; T_d – интервал дискретизации.

Частным видом модели линейного фильтра являются модели авторегрессии, скользящего среднего и авторегрессии скользящего среднего. В модели авторегрессии (АР) текущее значение временного ряда $\tilde{z}_k$ выражается как конечная взвешенная сумма предыдущих значений $\tilde{z}_{k-p}$ и сигнала в виде белого шума a_k:

$$\tilde{z}_k = \varphi_1 \tilde{z}_{k-1} + \varphi_2 \tilde{z}_{k-2} + \ldots + \varphi_p \tilde{z}_{k-p} + a_k, \qquad (2)$$

где $\tilde{z}_k = z_k - \mu$ – отклонение от среднего значения; $\varphi_1, \varphi_2, \ldots, \varphi_n$ – параметры модели; p – порядок модели.

В модели скользящего среднего (СС) текущее значение временного ряда $\tilde{z}_k$ линейно зависит от конечного числа q предыдущих значений выборки белого шума a_k:

$$\tilde{z}_k = a_k - \theta_1 a_{k-1} - \theta_2 a_{k-2} - \ldots - \theta_q a_{k-q}, \qquad (3)$$

где $\theta_1, \theta_2, \ldots, \theta_n$ – параметры модели; q – порядок модели.

Для получения более точной и адекватной модели временного ряда целесообразно объединить модель авторегрессии (2) и модель скользящего среднего (3). Это приводит к комбинированной модели авторегрессии скользящего среднего (АРСС) порядка p, q

$$\tilde{z}_k = \varphi_1 \tilde{z}_{k-1} + \ldots + \varphi_p \tilde{z}_{k-p} + a_k - \\ - \theta_1 a_{k-1} - \ldots - \theta_p a_{k-q}. \qquad (4)$$

Параметры моделей μ; $\varphi_1, \varphi_2, \ldots, \varphi_p$; $\theta_1, \theta_2, \ldots, \theta_p$ оцениваются по наблюдениям с использованием метода наименьших квадратов.

Другим методом моделирования временного ряда является использование искусственных нейронных сетей (ИНС), которые представляют собой широкий класс разнообразных вычислительных структур [2]. Составной частью ИНС является искусственный нейрон, состоящий из умножителей (синапсов), сумматора и нелинейного преобразователя. Математическая модель нейрона

$$s = \sum_{i=1}^{n} w_i x_i + b; \quad y = f(s), \qquad (5)$$

где s – результат суммирования; n – число входов нейрона; w_i – вес синапса; x_i – компонент входного вектора (входной сигнал); b – значение смещения; y – выходной сигнал нейрона; f – нелинейное преобразование (функция активации).

Нейроны объединяются в слои. Обучив ИНС путем настройки параметров в выражении (5) по определенному алгоритму для каждого нейрона, можно получить сеть, моделирующую временной ряд и прогнозирующую будущие значения временного ряда при подаче на ее вход предыдущих значений.

В большинстве публикаций, рассматривающих ИНС для прогнозирования нагрузки, используется архитектура ИНС прямого распространения (персептрон) с обучением по методу обратного распространения ошибки [4]. Использование такой архитектуры ИНС для решения задачи прогнозирования обуславливается ее быстродействием, способностью к восстановлению нелинейных функциональных зависимостей и обнаружению скрытых закономерностей.

В работе выполнен прогноз активной нагрузки подстанции с использованием моделей линейного фильтра и модели на основе ИНС. В качестве исходных данных для построения моделей использован месячный временной ряд активной мощности подстанции (см. рис.1), который был разбит на две выборки: обучающую – для построения моделей и контрольную – для проверки моделей и получения прогноза. Построение моделей производилось с помощью вычислительной среды *MATLAB*.

Наилучшая точность прогноза для моделей линейного фильтра получена с помощью

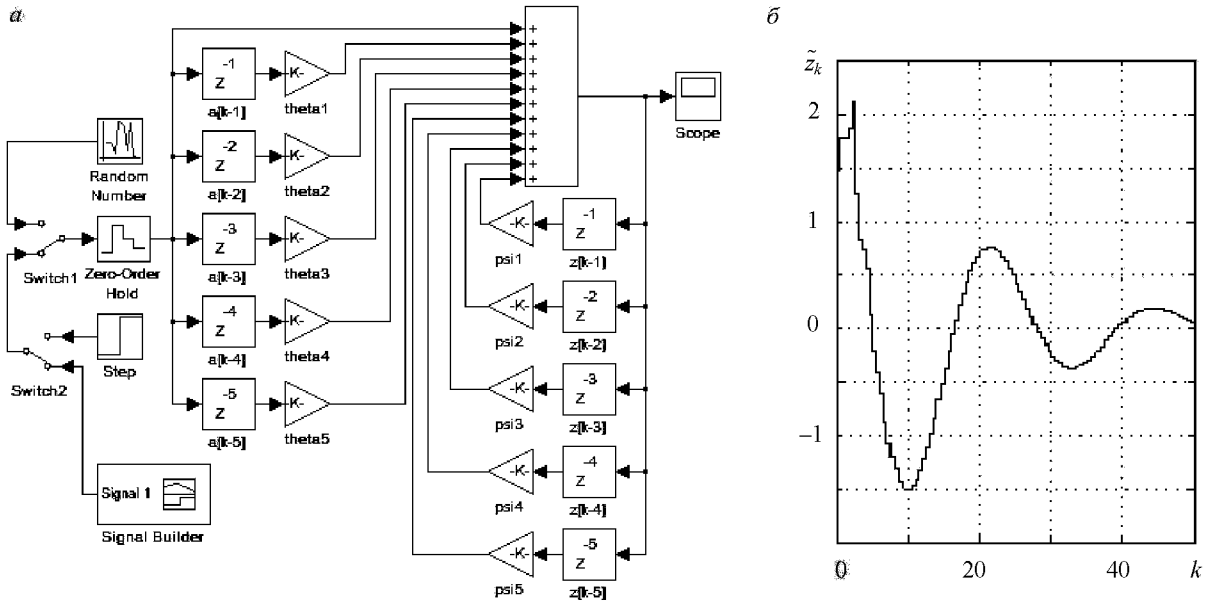


Рис.2. Структурная схема решения разностного уравнения модели АРСС(5,5) (*а*) и импульсная характеристика фильтра (*б*)

модели АРСС порядка (5,5). Параметры модели определены с использованием пакета *MATLAB Control Systems Toolbox*. Разностное уравнение этой модели имеет вид

$$\tilde{z}_k = 1{,}386\tilde{z}_{k-1} - 0{,}462\tilde{z}_{k-2} + 0{,}248\tilde{z}_{k-3} + \\ + 0{,}07034\tilde{z}_{k-4} - 0{,}288\tilde{z}_{k-5} + a_k + 0{,}011a_{k-1} + \\ + 0{,}0159a_{k-2} + 0{,}0163a_{k-3} + \\ + 0{,}0147a_{k-4} - 0{,}973a_{k-5}, \qquad (6)$$

где $\tilde{z}_k$ – текущее значение временного ряда; k – шаг вычисления.

Блок-схема решения уравнения (6) представлена на рис.2, *а*.

Реакция на сигнал в виде белого шума близка к графику нагрузки на рис.1. Импульсная характеристика построенного фильтра получена как реакция на единичный сигнал (рис.2, *б*).

Модель временного ряда на основе ИНС построена с помощью пакета *MATLAB Neural Networks Toolbox*. В модели использована двухслойная ИНС прямого распространения, в первом слое которой 10 нейронов, во втором – один, а на входе – линия задержки для хранения предыдущих значений. Обучение сети выполнялось по методу обратного распространения ошибки с критерием минимума среднеквадратичной ошибки.

Средняя относительная погрешность прогноза по модулю для модели АРСС составила 4,9 %, для модели на основе ИНС – 5,5 %.

Для повышения точности прогноза использовано разложение исходного ряда на несколько составляющих с использованием вейвлет-преобразования [3]. Вейвлет-преобразование сигнала $f(x)$ заключается в нахождении коэффициентов аппроксимации и детализации, которые имеют вид

$$a_{j-N,k} = \int_R f(x)\varphi_{j-N,k}(x)dx; \\ d_{j-N,k} = \int_R f(x)\psi_{j-N,k}(x)dx, \qquad (7)$$

где $a_{j-N,\,k}$ и $d_{j-N,\,k}$ – коэффициенты соответственно аппроксимации и детализации глубины разложения N; $\varphi_{j-N,\,k}(x)$ – масштабирующая функция; $\psi_{j-N,\,k}(x)$ – базисный вейвлет.

Зная коэффициенты вейвлет-преобразования, исходный сигнал можно представить как сумму нескольких составляющих с различной динамикой изменения процесса:

$$f(x) = \sum_k a_{j-N,k}\varphi_{j-N,k}(x) + \\ + \sum_k d_{j-N,k}\varphi_{j-N,k}(x) + \ldots + \\ + \sum_k d_{j-1,k}\varphi_{j-1,k}(x). \qquad (8)$$

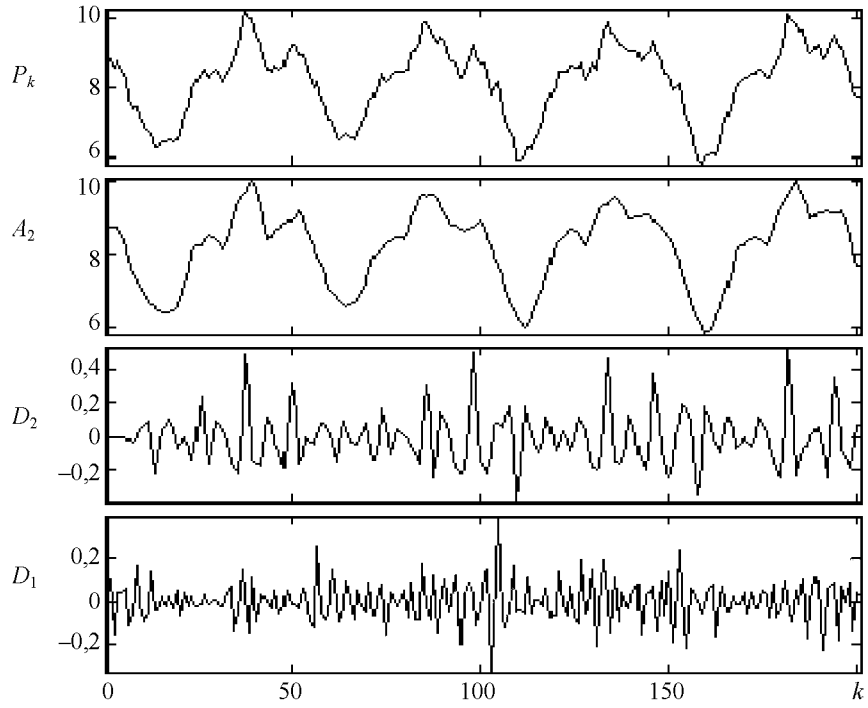


Рис.3. Разложение исходного временного ряда $P_k = A_2 + D_2 + D_1$

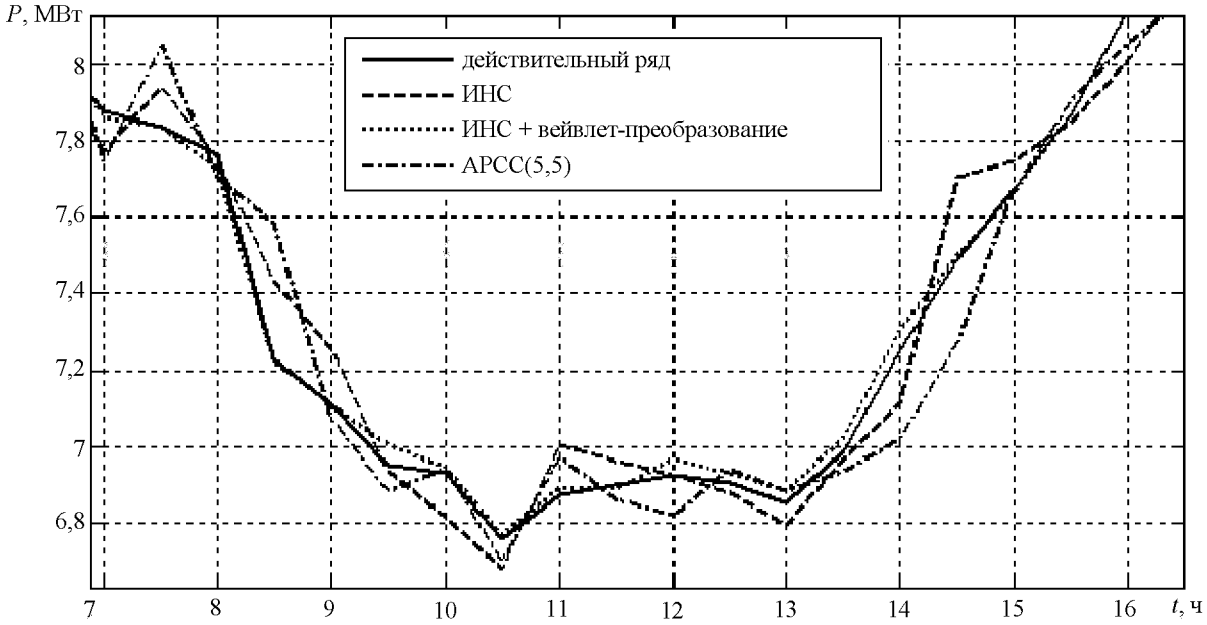


Рис.4. Прогноз графика активной мощности с помощью различных моделей

Исходный временной ряд активной мощности разложен по формуле (8) на три составляющие, как показано на рис.3. Для каждой составляющей построена модель на основе ИНС и выполнен прогноз. Искомый прогноз найден как сумма прогнозов для каждой составляющей.

Рассмотрим фрагмент графика нагрузки на интервале $\Delta t = 10$ ч и значения мощности, предсказанные различными моделями (рис.4).

Установлено, что использование вейвлет-преобразования позволило значительно повысить точность прогноза (до 1,6 %). Погрешности прогнозирования с использованием модели авторегрессии скользящего среднего (4,9 %) и искусственной нейронной сети (5,5 %) отличаются незначительно. Однако, в отличие от модели АРСС, нейронная сеть позволяет учесть ряд других факторов, влияющих на энергопотребление горного предприятия, например таких, как погодные условия (температура, влажность), день недели и т.п.

Следует отметить важность предварительного преобразования исходного временного ряда путем его разложения на несколько составляющих с использованием вейвлет-преобразования. Помимо повышения точности прогнозирования такое преобразование позволяет выявить особенности протекания технологического процесса по динамике изменения графика нагрузки.

Программная реализация рассмотренных моделей микропроцессорными средствами контроля энергопотребления позволяет автоматизировать процесс идентификации контролируемых временных рядов и осуществлять прогнозирование нагрузки с требуемым временем упреждения.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Бокс Д.* Анализ временных рядов. Прогноз и управление / Д.Бокс, Г.Дженкинс. М.: Мир, 1974. Вып.1. 406 с.; Вып.2. 197 с.

2. *Галушкин А.И.* Теория нейронный сетей.: Учеб. пособие для вузов / ИПРЖР. М., 2000. Кн.1. 416 с.

3. *Новиков Л.В.* Основы вейвлет-анализа сигналов: Учебное пособие. СПб.: Изд-во ИАнП РАН, 1999. 152 с.

4. *Шумилова Г.П.* Прогнозирование нагрузки ЭЭС на базе новых информационных технологий / Г.П.Шумилова, Н.Э.Готман, Т.Б.Старцева. Екатеринбург: Изд-во УрО РАН, 2002. 25 с.

REFERENCE

1. *Box G., Jenkins G.* Time series analysis: Forecasting and control. Moscow: Mir, 1974. Vol.1. 406 p.; Vol.2., 197 p.

2. *Galushkin A.I.* Neural Networks Theory. Vol.1: Tutorial / IPRZR. Moscow, 2000. 416 p.

3. *Novikov L.V.* Introductory wavelet signal analysis: Tutorial. Saint Petersburg: IAnP RAN, 1999. 152 p.

4. *Shumilova G.P., Gotman N.E., Startzeva T.B.* Forecasting the power consumption of power grid on the basis of novel information technologies. Yekaterinburg: UrO RAN, 2002. 25 p.

Научный руководитель д-р техн. наук, профессор *О.Б.Шонин*