

# ПОЧАСОВОЕ ПРОГНОЗИРОВАНИЕ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ КОЛЛЕКТИВОМ НЕЙРОННЫХ СЕТЕЙ

## HOURLY PREDICTION OF ELECTRICITY CONSUMPTION BY THE COLLECTIVE OF NEURAL NETWORKS

**И. В. Абрамов, Г. Л. Тимонович**  
**I. Abramov, G. Timonovich**

Белорусский государственный университет, МГЭИ им. А. Д. Сахарова БГУ,  
г. Минск, Республика Беларусь  
abramov937@gmail.com  
Belarusian State University, ISEI BSU, Minsk, Republic of Belarus

Прогнозирование потребления электроэнергии является важным фактором в сфере планирования и управления энергетическими ресурсами каждой страны. Построение точных прогнозов позволяет экономить и эффективно распределять энергетические ресурсы. Проблематика построения прогнозов потребления электроэнергии заключается в сложности построения аналитической модели электропотребления. Для эффективного решения такого типа задач используются технологии искусственного интеллекта. В данном исследовании рассматривались искусственные нейронные сети (ИНС) типа многослойных перцептронов (МЛП) [1].

Forecasting of electricity consumption is an important factor in the planning and management of energy resources of each country. Building accurate forecasts allows us to save and efficiently allocate energy resources. The problem of building energy consumption forecasts lies in the complexity of building an analytical model of electricity consumption. To effectively solve this type of problem, artificial intelligence technologies are used. In this study, artificial neural networks types of multilayer perceptrons were considered.

*Ключевые слова:* электропотребление, искусственные нейронные сети.

*Keywords:* power consumption, artificial neural networks.

Цель проведенного исследования заключалась в построении прогноза электропотребления на час вперед коллективом искусственных нейронных сетей типа многослойных перцептронов.

Исходные данные – почасовое электропотребление Минской областной энергосистемы.

Перечень проведенных задач для построения прогноза потребления электроэнергии нейронной сетью:

- предварительная обработка данных;
- формирование обучающей выборки;
- выбор топологии нейронной сети;
- обучение нейронной сети.

Предварительная обработка данных включала в себя обнаружение выбросов и восстановление их значений.

Потребление электроэнергии имеет свои шаблоны, которые выражаются в схожем поведении потребления электроэнергии в будние, рабочие и праздничные дни. Выделяя эти шаблоны можно сделать предположение, что те значения электропотребления, которые имеют явные отклонения от основного распределения данных в шаблонах, являются выбросами. Соответственно, при выделении шаблонов электропотребления и построении доверительных интервалов к этим шаблонам можно идентифицировать предполагаемые выбросы.

При обучении нейронной сети обучающую выборку необходимо масштабировать в некотором интервале, в данном исследовании использовался  $[-0.5, 0.5]$  [2]. Наличие выбросов приведет к сдвинутому распределению данных в заданном интервале, что непосредственно влияет на обучение нейронной сети.

Известно, что потребление электроэнергии зависит от температуры погодных условий, поскольку часть вырабатываемой электроэнергии идет на отопительные процессы для поддержания нормальной температуры в помещениях. Следовательно, температура является важным фактором при прогнозировании, однако рассмотрим следующий ряд электропотребления.

Пусть  $E$  – исходный временной ряд электропотребления. Тогда временной ряд с лагом (лаг – смещенное значение временного ряда по времени), равным единице  $E_{11}$ :

$$E_{11} = E_i - E_{i-1}, \quad (1)$$

где  $i$  – индекс значения электропотребления.

Каждое значение ряда (1) определяется предыдущим, поэтому при часовом прогнозировании потребления электроэнергии на ряде (1) прогнозируется колебание электроэнергии относительно предыдущего часа. Прогнозирование колебания электроэнергии относительно предыдущего часа не является строго зависимым от темпера-

турных условий, поскольку уровень электропотребления за предыдущий час уже хранит в себе эту информацию. На рис. 1 приведены гистограммы для исходного ряда электропотребления и ряда (1).

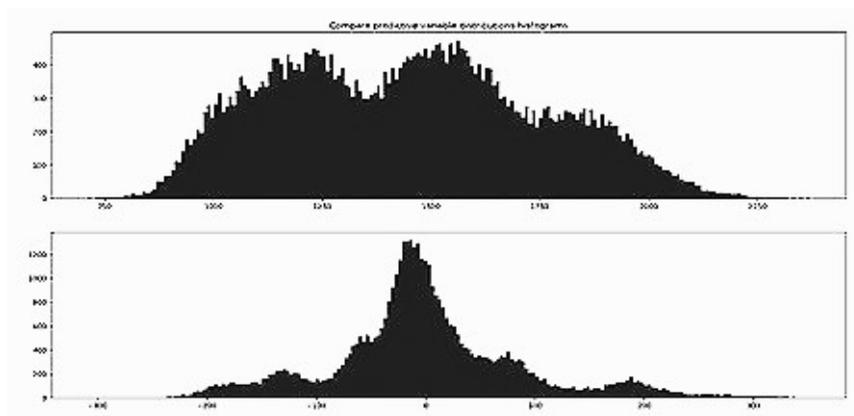


Рисунок 1 – Верхний график – гистограмма исходного ряда электропотребления, нижний – гистограмма для ряда колебания электропотребления относительно предыдущего часа

Из рис. 1 следует, что распределение электропотребления для ряда (1) близко к нормальному, поэтому является более предпочтительным при прогнозировании. С этой целью в данном исследовании прогнозирование проводилось на временном ряду (1).

В эконометрике при прогнозировании временных рядов принято приводить временной ряд к стационарному виду, в котором среднее значение и дисперсия постоянны, полученные путем удаления трендов исходного временного ряда. Удаление трендов может производиться путем взятия разности временного ряда относительно некоторого лага, при котором наблюдается некоторый тренд. Основные тренды ряда электропотребления: часовая, суточная и недельная тренды. Также присутствует годовой тренд, выражающийся в цикличности температурных погодных условий. Ряд (1) является разностным с лагом, равным единице, то есть показатели корреляции от 1 до 23 лагов будут ниже чем у исходного.

При формировании обучающей выборки использовалась автокорреляционная функция [2] для выделения наиболее значимых лагов временного ряда (1) электропотребления. Так как наиболее значимые лаги электропотребления являются высоко коррелированными, использовался метод главных компонент [2] для снижения размерности обучающего множества и устранения корреляций между лагами электропотребления. Наличие сильно коррелирующих признаков в обучающем множестве понижает информативность обучающего множества и является показателем наличия линейной зависимости между признаками, что может привести к проблеме переобучения нейронной сети [3].

На рис. 2 приведена классическая топология многослойного персептрона с одним скрытым слоем.

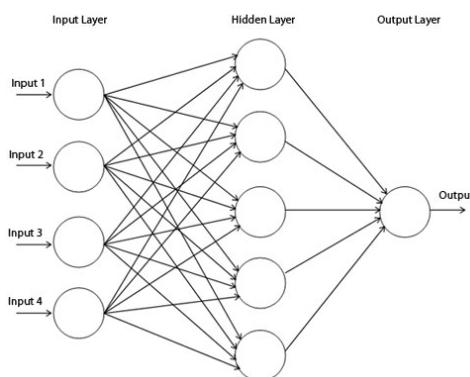


Рисунок 2 – Многослойный персептрон с одним скрытым слоем

Рассмотрим классическую постановку задачи обучения искусственной нейронной сети с учителем методом обратного распространения ошибки [1]. Дано: множество обучающих признаков  $Is$  (2), найти такую модель  $M$  (3), которая давала бы наиболее точный прогноз.

$$Is = \{x_i^k, x_{i+1}^k, \dots, x_{i+n}^k \mid y^k\}, \quad (2)$$

$$M(x, w, \varphi), \quad (3)$$

где  $i = 1, \dots, n$  – индекс признака,  $k = 1 \dots N$  – количество обучающих элементов в обучающем множестве,  $x_i^k$  – обучающий признак,  $y^k$  – значение электропотребления, прогнозируемой переменной,  $w, \varphi$  – веса и пороговая функция активации нейронной сети соответственно.

Критерий минимизации обучения нейронной сети  $Q(w)$ :

$$Q(w) = \sum_{i=1}^n \gamma_i(w) \rightarrow \min_w, \quad (4)$$

$$\gamma_i(w) = \gamma(M(x_i, w, \varphi), y_i), \quad (5)$$

$$M(x_i, w, \varphi) = y', \quad (6)$$

$$\gamma(M(x_i, w, \varphi)) = (y - y')^2, \quad (7)$$

где  $\gamma$  – функция потерь,  $y'$  – предсказание модели  $M$ ,  $y$  – реальное значение электропотребления.  
Обновление весов нейронной сети:

$$w_{jh}^{k+1} = w_{jh}^k - \eta \frac{\partial \gamma_i(w^k)}{\partial w_{jh}}, \quad (8)$$

где  $\eta$  – шаг градиента,  $k$  – номер итерации,  $w_{jh}^k$  –  $j$ -ый вес нейрона в скрытом слое  $h$ ,  $w_{jh}^{k+1}$  – обновленный вес. Следовательно, в процессе обучения нейронной сети, обучаемым параметром являются веса ИНС. Изначально веса инициализируются случайным образом, соответственно нейронная сеть приобретает уникальную матрицу весов и ИНС с различными параметрами (таких как кол-во скрытых слоев, пороговая ф-я активации) будут показывать отличающиеся прогнозы в случае недостижения глобального минимума при обучении.

При прогнозировании нейронной сетью нужно определить комплекс параметров описывающих структуры сети и её метода обучения (например, использования параметров регуляризации), при этом изначально нельзя с достоверностью указать на качество будущих прогнозов при использовании различных комбинаций параметров.

Учитывая проблематику выбора параметров нейронной сети, в данном исследовании создавалось некоторое множество МЛП с различными параметрами. С помощью методики случайного поиска (путем выбора случайным образом различных параметров нейронной сети из некоторого интервала) выбирались те модели МЛП, которые показывали наилучшую способность к обобщению на этапе валидации (промежуточного тестирования). Три лидирующие модели нейронных сетей, имевшие лучшие показатели на этапе валидации, вошли в итоговый коллектив для прогнозирования.

В итоге был реализован следующий алгоритм (рис. 3):

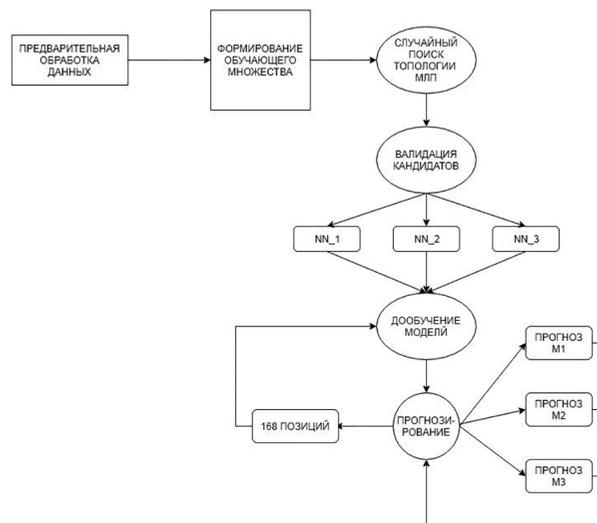


Рисунок 3 – Реализованный алгоритм прогнозирования потребления электроэнергии на час вперед

Обучение проводилось по данным 2013–2014 г., валидация – по 2015 г., тестирование – по 2016 г. В итоге три нейронные сети показали следующие результаты почасового прогнозирования в метрике ошибок MAPE (9) на 2016 г.:

- 0,9455 %;
- 0,8873 %;
- 0,8719 %.

$$Mape = \frac{100 * \sum_{i=1}^n |y_i - y'_i| / y_i}{n} \quad (9)$$

где  $n$  – количество часов в 2016 г.,  $y$  – фактическое значение электропотребления,  $y'$  – прогнозное.

Средний коллективный прогноз (усредненный прогноз входящих в коллектив моделей МЛП) составил 0,8290 %. В итоге исследования были получены достаточно точные прогнозы электропотребления на час вперед, показано, что прогнозирование коллективом ИНС является более точным, нежели ИНС, участвующими в прогнозе по отдельности.

#### ЛИТЕРАТУРА

1. Хайкин, С. Нейронные сети: полный курс 2-е издание / С. Хайкин. – М.: ООО «И.Д. Вильямс», 2016. – 1104 с.
2. Дубров, А. М. Многомерные статистические методы / А. Дубров, В. Мхитарян, Л. Трошин. – М.: Финансы и статистика, 2011. – 352 с.
3. Yoshua, Bengio Practical Recommendations for Gradient-Based Training of Deep Architectures / Y. Bengio // Neural Networks: Tricks of the Trade / Second Edition. Sept. 16<sup>th</sup>, 2012.

## РАЗРАБОТКА КОМПЛЕКСА ВЕБ-РЕСУРСОВ ВИЗУАЛИЗАЦИИ И МОНИТОРИНГА ДЛЯ АВТОМАТИЗИРОВАННОГО УПРАВЛЕНИЯ ЗАМКНУТОЙ ВОДНОЙ СРЕДОЙ В ГИДРО- И АКВАПОННЫХ СИСТЕМАХ

## DEVELOPMENT OF A WEB RESOURCE OF VISUALIZATION AND MONITORING FOR AUTOMATED CONTROL OF A CLOSED WATER ENVIRONMENT IN BOTH HYDRO- AND AQUAPONIC SYSTEMS

***М. А. Аевсецина, А. И. Каркоцкая, Т. В. Бучукова  
M. Ausetyna, A. Karkotskaya, T. Buchukova***

*Белорусский государственный университет, МГЭИ им. А. Д. Сахарова БГУ,  
г. Минск, Республика Беларусь  
anzhelika201777@gmail.com/ milana6666666@gmail.com  
Belarusian State University, ISEI BSU, Minsk, Republic of Belarus*

Рассматривается проблема разработки комплекса web-ресурсов для осуществления визуализации и мониторинга для автоматизированного управления замкнутой водной средой в гидро- и аквапонных системах.

This report examines the problem of developing complex of web-resources for implementation of visualization and monitoring for automated control of a closed water environment in hydro and aquaponic systems on the basis of system of monitoring.

*Ключевые слова:* SVG, web-ресурс, 3D, Zabbix, PHP, гидропонные системы, аквапонные системы.

*Keywords:* SVG, web-sait, 3D, Zabbix, PHP, aquaponix, hydroponics.

Студенческая научно-исследовательская лаборатория кафедры экологический информационных систем в настоящий момент занимается исследованием и разработкой автономной автоматизированной аквапонной системы с использованием современных технологий в контексте интернета вещей.

Концепция Интернета вещей предполагает взаимодействие между собой трех базовых принципов:

- а) глобальная коммуникационная инфраструктура;
- б) глобальная уникальная идентификация объекта внутри коммуникационной инфраструктуры;
- в) способность каждого объекта к приему-передаче данных внутри коммуникационной инфраструктуры посредством сети Интернет.

Частью концепции Интернета вещей является идея Веба вещей (WEB of Things, WoT) – инфраструктуры, обеспечивающей взаимодействие интеллектуальных объектов («smart-вещей») посредством механизмов сети Интернет (URI, HTTP, REST и др.). Фактически Веб вещей реализует принципы Интернета вещей на прикладном уровне. Интерфейс взаимодействия smart-вещей реализуется через WWW-страницы [1].

Комплекс web-ресурсов мониторинга и визуализации статусов компонентов и подсистем, разработанных в рамках концепции Веба вещей, позволяют в режиме реального времени производить мониторинг функционирования и организовывать удаленное управление как отдельными блоками и подсистемами, так и системой автоматизированного управления замкнутой водной средой целиком.

Веб-ресурс aquaponica.iseu.by разрабатывался для информирования пользователей о работе научной исследовательской лаборатории по проекту автоматизированной систем управления замкнутой водной средой.

На сайте aquaponica.iseu.by, структура которого показана на рис. 1, реализованы следующие функции:

- новостной слайдер с медиафайлами работы участников, а также отдельная страница с большим количеством фотоснимков и видеозаписей;
- интерактивная карта для детального просмотра установки на основе SVG-изображения;