

## МЕТОДЫ РЕШЕНИЯ ЗАДАЧ ОЦЕНКИ И ПРОГНОЗИРОВАНИЯ ЭНЕРГЕТИЧЕСКОЙ ЭФФЕКТИВНОСТИ

А.А. Капанский

Гомельский государственный технический университет  
им. П.О. Сухого (Беларусь), г. Гомель, Республика Беларусь  
kapanski@mail.ru

**Резюме:** Статья посвящена исследованию методов математического моделирования энергетической эффективности, которые на протяжении последних десятилетий использовались как инструмент прогнозирования общих и удельных расходов электроэнергии при решении системных исследований в энергетике. В работе уделяется внимание методам экспоненциального сглаживания временных рядов и моделям на основе детерминированного хаоса. Показано, что использование этих методов не всегда обеспечивает приемлемое качество прогноза. При сравнении результатов моделирования с реальными режимами электропотребления установлено, что теоретические данные практически совпадают с фактическими при однонаправленной тенденции электропотребления. Однако, при изменении направления тренда, что характерно для предприятий при вводе нового энергоёмкого оборудования или внедрении энергосберегающих мероприятий погрешность моделирования существенно возрастает.

В работе также приводятся используемые методы прогнозирования развития энергетики различных стран (Китая, Австралии, Италии и др.) на основе вероятностных и детерминированных моделей.

В статье показано, что множественный регрессионный анализ позволяет не только получить аналитическое уравнение изменения электропотребления, но и оценить степень влияния отдельно взятых факторов. Более совершенные формы моделирования, направленные на корректировку коэффициентов регрессии в зависимости от направленности технических мероприятий, обеспечивают высокое качество прогноза при решении вопросов системных исследований

**Ключевые слова:** энергетическая эффективность, прогнозирование электропотребления, энергосбережение, энергоуправления, математические модели электропотребления.

## METHODS FOR SOLVING THE PROBLEMS OF EVALUATION AND FORECASTING ENERGY EFFICIENCY

A.A. Kapansky

Gomel State Technical University named after P.O. Sukhoi,  
Gomel, Republic of Belarus  
kapanski@mail.ru

**Abstract:** The article is devoted to the study of methods of mathematical modeling of energy efficiency, which have been used over the past decades as a tool for predicting total and specific energy consumption when solving systemic research in the energy sector. The paper pays attention to methods of exponential smoothing of time series and models based on deterministic chaos. It is shown that the use of these methods does not always provide an acceptable forecast quality. When

*comparing the simulation results with real power consumption modes, it was found that the theoretical data practically coincides with the actual ones with a unidirectional trend of power consumption. However, if the trend direction changes, which is typical for enterprises when introducing new energy-intensive equipment or introducing energy-saving measures, the modeling error increases significantly.*

*The paper also describes the methods used to predict the energy development of various countries (China, Australia, Italy, etc.) based on probabilistic and deterministic models.*

*The article shows that multiple regression analysis allows not only to obtain an analytical equation for changes in power consumption, but also to assess the degree of influence of individual factors. More sophisticated forms of modeling, aimed at adjusting the regression coefficients depending on the direction of technical measures, provide a high quality forecast when solving issues of system research.*

**Keywords:** *energy efficiency, power consumption forecasting, energy saving, energy management, mathematical power consumption models.*

### **Введение**

Развитие отраслей экономики сопровождается ежегодным изменением объемов потребления топливно-энергетических ресурсов (ТЭР), в связи с чем, прогнозирование спроса на электроэнергию (ЭЭ) является неотъемлемым элементом в электроэнергетике, служащим для формирования энергетических балансов и планирования электрических нагрузок. В топливно-энергетическом комплексе (ТЭК) любого государства планирование энергетической эффективности (ЭЭФ) является важным инструментом на стадии принятия управленческих решений, включая закупку и производство ЭЭ, развитие инфраструктуры ТЭК и планирование величины предельных нагрузок [1, 2].

Качественные прогнозы ЭЭФ важны на всех стадиях процесса производства, передачи, распределения и потребления ЭЭ. Для промышленных и коммунально-бытовых потребителей ТЭР достоверное определение пика электрической нагрузки позволяет снизить величину оплаты за заявленную мощность, а качественное планирование общих и удельных расходов ЭЭ позволяет с наименьшей погрешностью учесть энергетическую составляющую в структуре себестоимости производимой продукции и избежать штрафных санкций за перерасход ЭЭ. На этапе разработки проекта развития электрических сетей во многих случаях возникает необходимость учитывать долгосрочный прогноз спроса на электроэнергию для возможности оперативного планирования режимов работы энергосистемы [3, 4], в связи с чем, актуальной задачей является исследование современных методов прогнозирования энергетической эффективности, определение области применения, достоинств и недостатков.

### **Методы прогнозирования на основе временных рядов**

В ряде случаев выбор того или иного метода прогнозирования ЭЭФ определяется заданной длительностью планирования. Как правило, горизонт планирования ЭЭ, в зависимости от конкретной ситуации может варьироваться: до 1 года – краткосрочное планирование; от 2 до 5 лет – среднесрочное планирование; от 5 до 10 лет, а в некоторых случаях и до 20 лет – долгосрочное планирование. Стремление к получению более достоверных прогнозов потребления ЭЭ влечет за собой развитие новых методов прогнозирования ЭЭФ. В среднесрочном и долгосрочном планировании автор работы [5] выделяет три основные группы методов: методы конечного потребления; методы тренда; эконометрические методы.

Сущность моделей конечного использования заключается в определении влияния различных типов технических, социальных, экономических и политических факторов в

отношении спроса на энергию. Такие модели предназначены для определения потребности в энергии на глобальном уровне (государственном, региональном или местном), посредством чего их можно использовать для выполнения многолетних прогнозов. Модель конечного использования позволяет учесть влияние структурных изменений в местной или мировой экономике на спрос энергии в анализируемой области.

К наиболее интересным методам тренда, описывающих эволюционный процесс изменения, следует отнести модель Брауна и Хольта [6, 7]. Модель Брауна по своей сути является моделью экспоненциального сглаживания и относится к основным методам выравнивания временных рядов. По типу исследуемого процесса модель относится к необратимым, учитывающим ход эволюционных изменений и является наиболее популярным методом краткосрочного прогнозирования. Сущность метода заключается в определении прогнозного значения в будущем периоде на основе скорректированной величины разности между фактом и прогнозом ЭЭ текущего периода [7]:

$$\widehat{W}_{t+1} = \widehat{W}_t + \alpha \cdot (W_t - \widehat{W}_t), \quad (1)$$

где  $\widehat{W}_t$ ,  $\widehat{W}_{t+1}$  – прогнозные значения электропотребления в текущем и будущем периоде соответственно;  $\alpha$  – коэффициент сглаживания ряда;  $W_t$  – фактическое значение электропотребления в рассматриваемом периоде  $t$ .

Недостатками модели Брауна является низкий горизонт прогнозирования. Кроме того, в рассмотренной модели наблюдается эффект «запаздывания» прогнозных значений (рис. 1). Снижение такого эффекта возможно при построении аддитивной модели сезонных колебаний, предложенной в работах Тейла и Вейджа [8], или адаптивной модели с мультипликативной сезонностью рассмотренной в работах Уинтерса [9] и усовершенствованной в работе Тейлора [10].

Логичным продолжением развития экспоненциальной сглаживающей является модель Хольта. Данный вид модели представляет собой систему уравнения с двумя постоянными сглаживания [11]:

$$\begin{cases} \widehat{W}_{t+1} = W_t \cdot (1 + x_{t+1}) \\ x_{t+1} = \alpha \cdot x_t \cdot (1 - x_t), \\ x_t = \frac{W_t - W_{t-1}}{W_{t-1}} \end{cases} \quad (2)$$

где  $\tau$  – период прогнозирования;  $a_t$ ,  $b_t$  – прогноз, очищенный от тренда, и параметр линейного тренда соответственно;  $a_1$ ,  $a_2$  – постоянные сглаживания.

В практике моделирования ЭЭФ метод Хольта является наиболее популярным среди приведенных моделей. Даже на сегодняшний день, работы по оптимизации выбора параметров не прекращаются. К примеру, автор работы [11] исследует тему поиска функциональных связей между параметрами модели и погрешностью прогнозирования, которые учитывают не только ошибку в прошлом периоде, но и накопление ошибки в перспективе.

В научной работе [12] П. Петровский провел пассивный эксперимент и установил, что повышение качества прогноза можно добиться, используя модифицированную форму уравнения Хольта:

$$F_t = a \cdot W_{t-1} + (1 - a) \cdot (F_{t-1} + S_{t-1}), \quad (3)$$

$$S_t = b \cdot (F_t + F_{t-1}) + (1-b) \cdot S_{t-1}, \text{ для } t \leq n, \quad (4)$$

$$\widehat{W}_t = F_t + (1-n) \cdot S_n, \text{ для } t > n, \quad (5)$$

где  $F_t$  – вспомогательная переменная;  $S_t$  – вспомогательная переменная, определяющая степень сглаживания;  $a, b$  – параметры модели;  $n$  – время (при  $t = n$  – настоящее время; при  $t > n$  – будущее время);  $t$  – период времени;  $W_{t-1}$  – значение электропотребления в период времени  $t-1$ ;  $\widehat{W}_t$  – прогноз электропотребления в периоде времени  $t$ .

В последние годы широкий спектр работ в области прогнозирования ЭЭФ основывается на моделях детерминированного хаоса к которым относятся логистическое уравнение И. Пригожина и модель Г. Шустера [13].

В своей работе И. Пригожин и И. Стенгерс [14] рассматривают процесс эволюции через коэффициенты рождаемости и смертности с учетом «несущей способности» окружающей среды. Автор работы [13] использует уравнение И. Пригожина с целью прогнозирования ЭЭ:

$$\widehat{W}_{t+1} = W_t \cdot \left( 1 + r \cdot \left( 1 - \frac{W_t}{K} \right) \right), \quad (6)$$

где  $r$  – коэффициент роста;  $K$  – потолок развития (ожидаемый рост в будущем).

Коэффициенты  $r, K$  логистического уравнения определяются итеративно, исходя из наименьшей погрешности прогнозов.

Прогностическая модель электропотребления на основе прогноза Шустера [15], полученная из анализа хаотического поведения динамической системы, приведена в работе [13] в виде системы алгебраических уравнений:

$$\begin{cases} \widehat{W}_{t+1} = W_t \cdot (1 + x_{t+1}) \\ x_{t+1} = \alpha \cdot x_t \cdot (1 - x_t), \\ x_t = \frac{W_t - W_{t-1}}{W_{t-1}} \end{cases} \quad (7)$$

где  $x_{t+1}, x_t$  – относительное увеличение спроса на электроэнергию;  $\alpha$  – параметр системы, определяющийся из обучающей последовательности;  $W_t, W_{t-1}$  – фактическое значение электропотребления в рассматриваемом и предшествующем периоде.

Naive-метод (наивный метод) является одним из наиболее простых методов прогнозирования, отмеченных в иностранной литературе. Использование рассмотренного метода основано на том, что наиболее качественным прогнозом на  $h$  шагов вперед, является результат последнего наблюдения [16]:

$$\widehat{W}_{t+h} = W_t. \quad (8)$$

Очевидно, что результаты прогнозирования при использовании Naive-метода на шаге  $h$  и  $h+1$  будут идентичны и основываться на последнем наблюдении. Применение этого метода приводит к вероятности получения недостоверных прогнозов, сформированных под

влиянием случайной ошибки. В научной работе [17] делается вывод о том, что *Naive*-метод плохо прогнозирует конкретный набор анализируемых временных рядов независимо от используемой меры измерения погрешности.

Неизвестные параметры рассмотренных моделей (коэффициенты сглаживания, роста, вспомогательные переменные и др.) определяются в результате поиска локального экстремума по критерию минимума погрешности прогнозирования. Какой показатель выбрать в качестве меры сравнения ошибок временных рядов подробно рассмотрено в работе [18]. Авторы проанализировали более сотни различных временных рядов. В качестве оценок использовались следующие показатели: среднеквадратическая ошибка (*RMSE*); наивысший процент (*Percent Better*); средняя ошибка абсолютной погрешности (*MAPE*); средняя абсолютная рабочая ошибка (*MdAPE*); среднегеометрическая ошибка (*GMRAE*); медиана абсолютной ошибки (*MdRAE*). Для выбора наиболее точных прогнозов авторы рекомендуют использовать показатель *MAPE* и *MdRAE*.

Для тестирования качества рассмотренных моделей использовалась годовая статистика электропотребления городской системы водоснабжения, сформированная на протяжении 13-и лет. В качестве тестовой выборки использовался период с 2013 по 2017 года. Результаты теста отражены на рис. 1.

При сравнении полученных моделей с реальными режимами электропотребления видно, что теоретические данные практически совпадают с фактическими, что свидетельствует о достаточно хорошем качестве рассмотренных моделей. Средняя погрешность годового прогнозирования (*MAPE*) в тестовом периоде составила для модели Брауна – 11,4 %; модели Хольта – 2,4 %; модели Пригожина – 1,2 %; модели Шустера – 5,6 %.




Рис. 1. Результаты тестирования моделей прогнозирования

Рассмотренные модели, несмотря на свою простоту и во многих случаях хорошее качество прогнозов, имеют недостатки. Поскольку прогнозы электропотребления основываются на предыстории статистических данных и не учитывают формирующие электропотребление факторы, то и результат прогнозирования отражает лишь общую тенденцию расхода ЭЭ. Это означает, что в случае изменения направления тренда электропотребления в тестовом (прогнозируемом) периоде, погрешность моделирования существенно возрастает, что наблюдается на рис. 1 в виде расхождения условно-возможных значений с прогнозируемыми.

### Методы системных исследований в энергетике

В последние годы все большее количество работ посвящено прогнозам развития энергетики различных стран на основе вероятностных и детерминированных моделей. К примеру, для прогнозирования электропотребления в Китае в период на 2000-2010 гг. авторы работы [19] предложили метод, который учитывает как изменение валового внутреннего продукта страны, так и общее повышение ЭЭФ. Используя модификацию функции Кобба-Дугласа, широко известную в эконометрике, авторы предложили следующий вид модели [19]:

$$\widehat{W}_t = \left( \frac{\text{ВВП}_t}{\text{ВВП}_{t-k}} \right)^\alpha \cdot \left( \frac{P_t}{P_{t-k}} \right)^\beta \cdot (1-\gamma) \cdot W_{t-k}, \quad (9)$$

где  $\widehat{W}_t$  – годовой прогноз электроэнергии;  $\text{ВВП}_t$  – валовый внутренний продукт в прогнозируемом периоде;  $P_t$  – цена электроэнергии в прогнозируемом периоде;  $\alpha$  – индикатор эластичности дохода (принимается в районе 0,7);  $\beta$  – индикатор эластичности цен (принимается в районе 0,2);  $\gamma$  – показатель повышения ЭЭФ;  $k$  – задержка.

Для регионального планирования энергопотребления в работах [20, 21] приведены две логарифмические модели, связывающие в первом случае количество годового внутреннего потребления ЭЭ с ВВП на душу населения и ценой на ЭЭ, а во втором случае к тому же временной тренд, учитывающий движение технического процесса.

Модель 1 принимает вид [20, 21]:

$$\log Y_{dom,t} = a_0 + a_1 \log x_{3,t} + a_2 \log PR_t + a_3 \log PR_{t-3} + a_4 \log Y_{dom,t-3}, \quad (10)$$

где  $Y_{dom,t}$  – потребление электроэнергии внутри страны;  $x_{3,t}$  – ВВП на душу населения;  $PR_t$  – цена на электроэнергию для внутренних потребителей страны;  $a_0, a_1, a_2, a_3, a_4$  – коэффициент регрессии;  $t$  – временной индекс.

Модель 2 принимает вид [20, 21]:

$$\log Y_{dom,t} = \beta_0 + \beta_1 \log x_{3,t} + \beta_2 \log PRND_t + \beta_3 \log IND_{t-3} + \beta_4 \log Y_{dom,t-3}, \quad (11)$$

где  $PRND_t$  – цена на электроэнергию для потребителей, не являющихся внутренними;  $IND$  – временной тренд;  $\beta_0, \beta_1, \beta_2, \beta_3, \beta_4$  – коэффициент регрессии.

В зарубежной литературе вопросам прогнозирования посвящено множество научных статей, затрагивающих вопросы не только отдельно взятых потребителей, но и энергетического комплекса в целом, что приводит к появлению новых математических методов или модификации существующих. Подбор ключевых факторов и выбор эффективного математического аппарата является центральной проблемой большинства работ. Стоит отметить, что для прогнозирования ЭЭФ на глобальном республиканском или отраслевом уровне во всех работах прослеживается общность определяющих факторов. Со статистической точки зрения эти факторы определяются ростом популяции и экономическим развитием [22].

В работе [23] исследована взаимосвязь между электропотреблением, занятостью населения и реальными доходами в Австралии. В результате исследования установлено, что потребление ЭЭ тесно коррелирует с включенными в модель факторами и в долгосрочной перспективе работа и реальные доходы населения приводят к увеличению потребления электроэнергии.

Влияние экономических и демографических переменных на годовое потребление электроэнергии в Италии исследовалось в работе [24]. В качестве математического аппарата использовалась линейная регрессия с периодом статистической выборки с 1970 по 2007 год. В качестве значимых факторов выступали общий ВВП, удельный ВВП на душу населения и численность населения. В работе доказано, что регрессионные модели соответствуют официальным прогнозам, с отклонениями в 1% для лучшего случая и 11% для худшего.

Схожие исследования проводились в работе [25], где авторами исследованы различные методологии одномерного моделирования для прогнозирования ежемесячного потребления электроэнергии в Ливане. В работе использовались одномерные временные модели: авторегрессионная и интегрированная модель авторегрессии (*ARIMA*), подробно описанная в работе [26]. В исследовании [27] для прогнозирования энергопотребления Индии использовались три различные модели временных рядов: модель Грей-Маркова, метод сингулярного спектра (*Singular spectrum analysis* или *SSA*) и Грей-метод (модель *GM*) прогнозирования поведения нелинейных временных рядов.

Для краткосрочного прогнозирования нагрузки Тайваньской энергетической системы в научной работе [28] рассматривается два метода: интегрированная модель авторегрессии (метод Бокса-Дженкинса или *ARIMA*) и предлагаемый экспертный метод, который учитывает характерные режимы работы, присущие рассматриваемой системе: типовые и специфические электрические нагрузки, включающие чрезвычайно низкий уровень загрузки энергосистемы в течение недели китайского Нового года, частичное закрытие некоторых заводов в выходные дни и др. Приводятся результаты средней погрешности моделирования с помощью экспертного системного подхода в 2,52% и ошибка статистического метода 3,86%.

В последние годы наблюдается значительный интерес в использовании в качестве инструментария нейронных сетей, которые вошли в практику везде, где решаются задачи прогнозирования, классификации и управления [29, 30]. В работе [31] рассмотрены вопросы прогнозирования энергопотребления Греции на основе искусственных нейронных сетей. Использована многослойная модель персептрона (*MLP*) путем тестирования нескольких возможных архитектур для выбора наиболее качественного вида модели. Полученные результаты сопоставлялись с методами линейной регрессии и с реальными показателями потребления энергии и показали свою значимость.

В работе [32] с использованием искусственной нейронной сети и регрессионного анализа исследуется значимость причинно-следственных связей между социально-экономическими и демографическими показателями Турции. В качестве факторов, формирующих ЭЭФ, приняты следующие показатели: ВВП, численность и занятость населения, объемы импорта и экспорта.

В статье [33] авторы представили результаты прогнозирования цен на ЭЭ на основе модели временных рядов нейронной сети. Особенностью являлось использование грид-вычислительного подхода с взаимосвязью множества компьютеров над решением единой сложной задачи. Как показано в статье, сетевые вычисления, предназначенные для единой компьютерной обработки, с использованием существующих прикладных программ, улучшают вычислительную скорость и точность прогнозирования.

Многие авторы используют прямую нейронную сеть для моделирования и прогнозирования временных рядов. В действительности, выбор архитектуры нейросети является сложной задачей. Авторы работы [34] для анализа значимости весовых коэффициентов моделей сети использовали метод пошаговой регрессии. Используя асимптотические свойства оценок, авторы предлагают определять степень значимости весов с целью упрощения топологии нейронной сети.

В научной работе [35] приводится сравнение использования нелинейной нейросетевой модели с линейной авторегрессионной моделью *ARMA* по статистическим данным электропотребления Чехии. Модель *ARMA* используется для прогнозирования

стационарных процессов и по своей сути обобщает две более простые модели: модель авторегрессии (AR) и модель скользящего среднего (MA). Результаты исследования показали, что краткосрочное прогнозирование электропотребления в Чехии, в первую очередь, является линейной проблемой, в связи с чем, условия использования нейронных сетей должно быть математически обоснованным.

Большая работа по оценке эффективности использования нейронных сетей для прогнозирования представлена в статье [36]. В качестве критериев эффективности использованы: оценка сходимости (конвергенции) обучающей выборки; оценка обобщения, т.е. способности делать точные прогнозы на данных, не относящихся к обучающей выборке; оценка согласования результатов на этапе валидации с различными образцами данных. Полученные результаты свидетельствовали, что только двадцать два исследования (46%) дали положительные результаты применимости нейронных сетей к проблемам прогнозирования. В связи с чем, применимость нейронных сетей должна быть технически обоснована.

С одной стороны, использование нейронных сетей, значительно расширяет возможности моделирования и позволяет воспроизводить с достаточной точностью очень сложные нелинейные зависимости, причем, с минимальными временными затратами на цензурирование данных. На сегодняшний день, разработано множество новых методов, определяющих использование той или иной нейросетевой топологии и выбор оптимального количества входных переменных, в связи с чем, основные задачи проектировщика нейронных сетей заключаются в определении требуемой архитектуры, достоверном отборе информации, необходимом для успешного обучения выборки, и интерпретации полученных результатов. Последняя задача, по своей сути, является целевой, требующей от инженера большого уровня знаний и пониманий сущности процессов, что усложняет использование нейронных сетей в практических условиях производства.

Множественная регрессия представляет особый интерес для разработчиков моделей, поскольку позволяет не только получить аналитическое уравнение изменения ЭЭ, но и оценить степень влияния отдельно взятых факторов. В научных изданиях с использованием вышесказанного метода рассматривается множество моделей для краткосрочного и среднесрочного прогнозирования. К примеру, в научной статье [37, 38] для американского предприятия *Puget Sound Power and Light* приводятся результаты исследования часовых нагрузок с динамической структурой ошибок и их адаптивными корректировками. Результаты показывают, что модель множественной регрессии хорошо отражает реальное изменение фронта электрических нагрузок по сравнению с широким спектром альтернативных моделей.

В работах [39, 40] использован новый метод адаптации уравнения множественной регрессии в зависимости от направленности технических мероприятий, проводимых на предприятии. Для определения прогнозной величины удельного расхода электроэнергии предложена корректировка коэффициентов регрессии по формуле [41]:

$$w'_{уд} = \left( w_{уд,тех} \pm k_1 \cdot \frac{\Delta W_{тех}}{\Pi} \right) + \frac{\sum b_k x_k + (W_{усл,п} \pm k_2 \cdot \Delta W_{тех})}{\Pi} = w'_{уд,тех} + \frac{\sum b_k x_k + W'_{усл,п}}{\Pi}, \quad (12)$$

где  $w_{уд,тех}$  – коэффициент регрессии при факторе объема производства;  $\Delta W_{тех}$  – величина абсолютного прироста или снижения электропотребления в зависимости от направленности мероприятий;  $\Pi$  – объем производства;  $b$  – коэффициенты регрессии прочих факторов;  $x$  – факторы модели;  $W_{усл,п}$  – свободный член регрессии, отражающий условно-постоянный расход электропотребления;  $k_1, k_2$  – адаптационные параметры модели, которые определяются путем минимизации погрешности прогнозирования



тестовой выборки на основе ретроспективных изменений удельного расхода ЭЭ и сопутствующих при этом изменений электропотребления.




Рис. 2. Сравнение реальных значений электропотребления с результатами моделирования

Результаты апробации метода прогнозирования удельного расхода ЭЭ на примере предприятия водопроводно-канализационного хозяйства приведены на рисунке 2. Слева области построения отражены результаты с нескорректированными параметрами модели, справа – при учете реализованных энергосберегающих мероприятий, внедрении трубопроводных сетей и насосных станций. В тестовом периоде с 2013 г. по 2017 г. погрешность прогнозирования не выходила за пределы 2,0 %, а в среднем за пять лет, составила 0,9 %.

### Заключение

Рассмотренные математические модели и подходы к системному анализу вопросов управления энергетической эффективностью нашли широкое распространение в отечественной и зарубежной практике прогнозирования общих и удельных расходов электроэнергии. Однако, использование методов экспоненциального сглаживания и моделей на основе детерминированного хаоса не всегда обеспечивает приемлемое качество прогноза. При сравнении моделей Брауна, Хольта, Пригожина и Шустера с реальными значениями электропотребления, установлено, что теоретические данные практически совпадают с фактическими при однонаправленной тенденции электропотребления, однако в случае изменения направления тренда, что характерно для предприятий при вводе нового энергоёмкого оборудования или внедрении энергосберегающих мероприятий, погрешность моделирования существенно возрастает.

Использование нейронных сетей позволяет воспроизводить с достаточной точностью очень сложные нелинейные зависимости причем с минимальными временными затратами на цензурирование данных. Однако, невозможность интерпретации промежуточных результатов моделирования усложняет использование нейронных сетей в практических условиях производства.

Множественный регрессионный анализ позволяет не только получить аналитическое уравнение изменения электропотребления, но и оценить степень влияния отдельно взятых факторов. Более совершенные формы моделирования, направленные на корректировку коэффициентов регрессии в зависимости от направленности технических мероприятий, обеспечивают высокое качество прогноза при решении вопросов системных исследований.

### Литература

1. Русан В. И., Мордань И. Л. Зарубежный опыт в сфере энергосбережения и основные направления повышения энергоэффективности в Беларуси // Энергетическая стратегия. 2016. №6. С. 48-50.
2. Романюк В. Н., Муслина Д. Б. Прогнозирование объемов производства предприятий легкой промышленности для определения их потребности в энергоресурсах (Часть 1) // Наука и техника. 2015. № 4. С. 66 – 76.
3. Willis H. L. Spatial electric load forecasting. Marcel Dekker Inc. New York: Basel; 2002. 739 p.
4. Грачева Е. И., Наумов О.В., Садыков Р.Р., и др. Моделирование параметров функциональных характеристик цеховых сетей // Технические науки – от теории к практике. 2015. №. 53. С. 105-114.
5. Willis H. L. Distribution load forecasting. IEEE Tutorial Course on Power Distribution Planning. ЕНО 361-6-PWR; 1992. 1217 p.
6. Koehler A. B., Snyder R. D., Ord J. K. Forecasting models and prediction intervals for the multiplicative Holt–Winters method // International Journal of Forecasting. 2001. Vol. 17. №. 2. pp. 269-286.
7. Brown G. R. Smoothing, Forecasting and Prediction of Discrete Time Series. N.Y.: Dover Phoenix Editions; 2004. 480 p.
8. Theil H., Wage S. Some observations on adaptive forecasting // Management Science. 1964. Vol. 10. № 2. pp. 198-206.
9. Winters P.R. Forecasting sales by exponentially weighted moving averages // Management Science. 1960. Vol. 6. № 3. pp. 324-342.
10. Taylor J.W. Short-term electricity demand forecasting using double seasonal exponential smoothing // The Journal of the Operational Research Society. 2003. Vol. 54. N 8. pp. 799-805.
11. Beliczynski B., Osowska M. Stability of the holt-type forecasting models // Theoretical Quarterly of Economics and Informatics. 2004. pp. 49-55.
12. Piotrowski P. Z 144: Prognozowanie w elektroenergetyce w różnych horyzontach czasowych. Warszawa: Oficyna wydaw. Politech. warszawskiej, 2013. 198 p.
13. Trojanowska M. Wykorzystanie teorii chaosu zdeterminowanego w prognozowaniu krokowym rocznego zużycia energii elektrycznej przez odbiorców wiejskich // Polska akademia nauk. 2005. № 2. pp. 121-128.
14. Prigogine I., Stengers I. Order out of Chaos: Man's new dialogue with nature. Bantam Books; 1984. 349 p.
15. Schuster H. G. Deterministic Chaos. An Introduction. Weinheim. Physik-Verlag; 1984. 220 p.
16. Faloutsos C., Ranganathan M., Manolopoulos Y. Fast subsequence matching in time-series databases // ACM. 1994. T. 23. №. 2. pp. 419-429.
17. Fildes R. The evaluation of extrapolative forecasting methods // International Journal of Forecasting. 1992. T. 8. №. 1. pp. 81-98.
18. Armstrong J. S., Collopy F. Error measures for generalizing about forecasting methods: Empirical comparisons // International Journal of Forecasting. Vol. 8, Iss.1, June 1992. pp.69–80.
19. von Hirschhausen C., Andres M. Long-Term Electricity Demand in China –From Quantitative to Qualitative Growth // Energy Policy. United Kingdom, 2000. Vol. 28. pp. 231-241.
20. Erdogdu E. Electricity demand analysis using cointegration and ARIMA modelling: A case study of Turkey // Energy policy. 2007. Vol. 35. №. 2. pp. 1129-1146.
21. Haas R., Schipper L. Residential energy demand in OECD-countries and the role of irreversible efficiency improvements // Energy economics. 1998. Vol. 20. №. 4. pp. 421-442.
22. Kadoshin S., Nishiyama T., Ito T. The trend in current and near future energy consumption from a statistical perspective // Applied Energy. 2000. Vol. 67. №. 4. pp. 407-417.
23. Narayan P. K., Smyth R. Electricity consumption, employment and real income in Australia evidence from multivariate Granger causality tests // Energy policy. 2005. Vol. 33. №. 9. pp. 1109-1116.
24. Bianco V., Manca O., Nardini S. Electricity consumption forecasting in Italy using linear regression models // Energy. 2009. Vol. 34. №. 9. pp. 1413-1421.

25. Saab S., Badr E., Nasr G. Univariate modeling and forecasting of energy consumption: the case of electricity in Lebanon // *Energy*. 2001. Vol. 26. №. 1. pp. 1-14.
26. Conejo A. J., et al. Day-ahead electricity price forecasting using the wavelet transform and ARIMA models // *IEEE transactions on power systems*. 2005. Vol. 20. №. 2. pp. 1035-1042.
27. Kumar U., Jain V. K. Time series models (Grey-Markov, Grey Model with rolling mechanism and singular spectrum analysis) to forecast energy consumption in India // *Energy*. 2010. Vol. 35. №. 4. pp.1709-1716.
28. Harvey A., Koopman S. J. Forecasting hourly electricity demand using time-varying splines // *Journal of the American Statistical Association*. 1993. Vol. 88. №. 424. pp. 1228-1236.
29. Lago J., et al. Forecasting day-ahead electricity prices in Europe: the importance of considering market integration // *Applied energy*. 2018. Vol. 211. pp. 890-903.
30. Wang F., et al. Daily pattern prediction based classification modeling approach for day-ahead electricity price forecasting // *International Journal of Electrical Power & Energy Systems*. 2019. Vol. 105. pp. 529-540.
31. Ekonomou L. Greek long-term energy consumption prediction using artificial neural networks // *Energy*. 2010. Vol. 35. №. 2. pp. 512-517.
32. Kankal M., et al. Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables // *Applied Energy*. 2011. Vol. 88. №. 5. pp. 1927-1939.
33. Sakamoto N., Ozawa K., Niimura T. Grid computing solutions for artificial neural network-based electricity market forecasts. *Neural Networks; 2006. IJCNN'06. International Joint Conference on. IEEE; 2006. pp. 4382-4386.*
34. Cottrell M., et al. Neural modeling for time series: a statistical stepwise method for weight elimination // *IEEE transactions on neural networks*. 1995. Vol. 6. №. 6. pp. 1355-1364.
35. Darbellay G. A., Slama M. Forecasting the short-term demand for electricity: Do neural networks stand a better chance? // *International Journal of Forecasting*. 2000. Vol. 16. №. 1. pp. 71-83.
36. Adya M., Collopy F. How effective are neural networks at forecasting and prediction? A review and evaluation // *J. Forecasting*. 1998. Vol. 17. pp. 481-495.
37. Ramanatha R., et al. Short-run forecasts of electricity loads and peaks // *International journal of forecasting*. 1997. Vol. 13. №. 2. pp. 161-174.
38. Amiri S. S., Mottahedi M., Asadi S. Using multiple regression analysis to develop energy consumption indicators for commercial buildings in the US // *Energy and Buildings*. 2015. Vol. 109. pp. 209-216.
39. Грунтович Н. В., Капанский А. А., Федоров О. В. Исследование влияния факторов на формирование удельных и общих расходов электрической энергии в технологической системе водоснабжения // *Электротехнические системы и комплексы*. 2016. № 3 (32). С. 54-59.
40. Капанский А. А. Управление энергоэффективностью трубопроводных систем водоотведения на основе многофакторного моделирования режимов электропотребления // *Агротехника и энергообеспечение*. 2016. № 1(10). С. 51-63.
41. Грунтович Н. В., Грунтович Н. В., Капанский А. А. Прогнозирование энергоэффективности технологических систем водоснабжения и водоотведения при внедрении мероприятий по энергосбережению // *Энергоэффективность*. 2016. № 1. С. 44-48.

#### **Авторы публикации**

**Капанский Алексей Александрович** – старший преподаватель кафедры «Электроснабжение», Гомельский государственный технический университет им. П.О. Сухого, г.Гомель, Белоруссия. Email: kapanski@mail.ru.

### References

1. Zarubezhnyj opyt v sfere energosberezheniya i osnovnye napravleniya povysheniya energoeffektivnosti v Belarusi. *Energeticheskaya strategiya*. 2016; 6:48-50. (In Belarus).
2. Romanyuk VN, Muslina DB. Prediction of production volumes of light industry enterprises to determine their need for energy resources (Part 1). *Science & Technique*. 2015; 4:66-76. (In Belarus).
3. Willis HL. *Spatial electric load forecasting*. Marcel Dekker Inc. New York: Basel; 2002. 739 p.
4. Gracheva EI, Naumov OV, Sadykov RR, et al. Modeling the parameters of functional characteristics of workshop networks. *Technical Sciences – from theory to practice*. 2015; 53:105-114. (In Russ).
5. Willis HL. *Distribution load forecasting*. IEEE Tutorial Course on Power Distribution Planning. EHO 361-6-PWR; 1992. 1217 p.
6. Koehler AB, Snyder RD, Ord JK. Forecasting models and prediction intervals for the multiplicative Holt–Winters method. *International Journal of Forecasting*. 2001; 17(2):269-286.
7. Brown GR. *Smoothing, Forecasting and Prediction of Discrete Time Series*. N.Y.: Dover Phoenix Editions; 2004. 480 p.
8. Theil H, Wage S. Some observations on adaptive forecasting. *Management Science*. 1964; 10(2):198-206.
9. Winters PR. Forecasting sales by exponentially weighted moving averages. *Management Science*. 1960; 6(3): 324-342.
10. Taylor JW. Short-term electricity demand forecasting using double seasonal exponential smoothing. *The Journal of the Operational Research Society*. 2003; 54(8):799-805.
11. Beliczynski B, Osowska M. Stability of the holt-type forecasting models. *Theoretical Quarterly of Economics and Informatics*. 2004. pp. 49-55.
12. Piotrowski P. *Z 144: Prognozowanie w elektroenergetyce w różnych horyzontach czasowych*. Warszawa: Oficyna wydaw. Politech. warszawskiej, 2013. 198 p. (In Poland).
13. Trojanowska M. Wykorzystanie teorii chaosu zdeterminowanego w prognozowaniu krokowym rocznego zużycia energii elektrycznej przez odbiorców wiejskich. *Polska akademia nauk*. 2005; 2:121-128. (In Poland).
14. Prigogine I, Stengers I. *Order out of Chaos: Man's new dialogue with nature*. Bantam Books; 1984. 349 p.
15. Schuster HG. *Deterministic Chaos. An Introduction*. Weinheim. Physik-Verlag; 1984. 220 p.
16. Faloutsos C, Ranganathan M, Manolopoulos Y. Fast subsequence matching in time-series databases. *ACM*. 1994; 23(2):419-429.
17. Fildes R. The evaluation of extrapolative forecasting methods. *International Journal of Forecasting*. 1992; 8(1):81-98.
18. Armstrong JS, Collopy F. Error measures for generalizing about forecasting methods: Empirical comparisons. *International Journal of Forecasting*. 1992; 8(1):69-80.
19. von Hirschhausen C, Andres M. Long-Term Electricity Demand in China –From Quantitative to Qualitative Growth. *Energy Policy*. United Kingdom, 2000; 28:231-241.
20. Erdogdu E. Electricity demand analysis using cointegration and ARIMA modelling: A case study of Turkey. *Energy policy*. 2007; 35(2):1129-1146.
21. Haas R, Schipper L. Residential energy demand in OECD-countries and the role of irreversible efficiency improvements. *Energy economics*. 1998; 20(4):421-442.
22. Kadoshin S, Nishiyama T, Ito T. The trend in current and near future energy consumption from a statistical perspective. *Applied Energy*. 2000; 67(4):407-417.
23. Narayan PK, Smyth R. Electricity consumption, employment and real income in Australia evidence from multivariate Granger causality tests. *Energy policy*. 2005; 33(9):1109-1116.
24. Bianco V, Manca O, Nardini S. Electricity consumption forecasting in Italy using linear regression models. *Energy*. 2009; 34(9):1413-1421.

25. Saab S, Badr E, Nasr G. Univariate modeling and forecasting of energy consumption: the case of electricity in Lebanon. *Energy*. 2001; 26(1):1-14.
26. Conejo AJ., et al. Day-ahead electricity price forecasting using the wavelet transform and ARIMA models. *IEEE transactions on power systems*. 2005; 20(2):1035-1042.
27. Kumar U, Jain VK. Time series models (Grey-Markov, Grey Model with rolling mechanism and singular spectrum analysis) to forecast energy consumption in India. *Energy*. 2010; 35(4):1709–1716.
28. Harvey A, Koopman SJ. Forecasting hourly electricity demand using time-varying splines. *Journal of the American Statistical Association*. 1993; 88(424):1228-1236.
29. Lago J, et al. Forecasting day-ahead electricity prices in Europe: the importance of considering market integration. *Applied energy*. 2018; 211:890-903.
30. Wang F, et al. Daily pattern prediction based classification modeling approach for day-ahead electricity price forecasting. *International Journal of Electrical Power & Energy Systems*. 2019; 105:529-540.
31. Ekonomou L. Greek long-term energy consumption prediction using artificial neural networks. *Energy*. 2010; 35(2):512-517.
32. Kankal M, et al. Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables. *Applied Energy*. 2011; 88(5):1927-1939.
33. Sakamoto N, Ozawa K, Niimura T. Grid computing solutions for artificial neural network-based electricity market forecasts. *Neural Networks; 2006. IJCNN'06. International Joint Conference on. IEEE; 2006*. pp. 4382-4386.
34. Cottrell M, et al. Neural modeling for time series: a statistical stepwise method for weight elimination. *IEEE transactions on neural networks*. 1995; 6(6):1355-1364.
35. Darbellay GA, Slama M. Forecasting the short-term demand for electricity: Do neural networks stand a better chance? *International Journal of Forecasting*. 2000; 16(1):71-83.
36. Adya M, Collopy F. How effective are neural networks at forecasting and prediction? A review and evaluation. *J. Forecasting*. 1998; 17:481-495.
37. Ramanatha R, et al. Short-run forecasts of electricity loads and peaks. *International journal of forecasting*. 1997; 13(2):161-174.
38. Amiri SS, Mottahedi M, Asadi S. Using multiple regression analysis to develop energy consumption indicators for commercial buildings in the US. *Energy and Buildings*. 2015; 109:209-216.
39. Gruntovich NV, Kapansky AA, Fedorov OV. Study of Influence of Factors on Formation of Specific and General Consumption of Electrical Energy in Technology Water System. *Electrotechnical systems and complexes*. 2016; 3(32):54-59. (In Russ).
40. Kapansky AA. Upravlenie energoeffektivnost'yu truboprovodnyh sistem vodootvedeniya na osnove mnogofaktornogo modelirovaniya rezhimov elektropotrebleniya. *Agrotehnika i energoobespechenie*. 2016; 1(10):51-63. (In Russ).
41. Gruntovich NV, Gruntovich NV, Kapansky AA. Prognozirovaniye energoeffektivnosti tekhnologicheskikh sistem vodosnabzheniya i vodootvedeniya pri vnedrenii meropriyatij po energosberezheniyu. *Energoeffektivnost'*. 2016; 1:44-48. (In Belarus).

#### **Authors of the publication**

*Aleksej Al. Kapanskij* – Gomel State Technical University named after P.O. Sukhoi, Gomel, Republic of Belarus. Email: kapanski@mail.ru.

*Поступила в редакцию*

*19 июня 2019 г.*