

УДК 621.31.001.18:004.032.26

НЕЙРОНЕЧЕТКАЯ МОДЕЛЬ КРАТКОСРОЧНОГО ПРОГНОЗИРОВАНИЯ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ

Аль-Гунаид Мохаммед, аспирант, Волгоградский государственный технический университет, 400131, Российская Федерация, г. Волгоград, пр. Ленина, 28, e-mail: mohammadalgunaid@gmail.com

Исследование имеет целью разработку математической модели нечеткой нейронной сети (ННС). Представлена и обоснована структура ННС, позволяющая спрогнозировать величины потребления электроэнергии в условиях неопределенности. Рассматривается решение проблемы краткосрочного прогнозирования потребления электроэнергии с учетом нескольких сезонных паттернов в данных, календаря работ, высокой частоты сбора информации, низкой экспертной поддержки при построении моделей и необходимости интерпретируемости результатов. Приведена реализация метода, включающего последовательное применение алгоритмов формирования нечетких переменных на основе временного ряда, синтеза базы знаний, синтеза нечеткой нейронной сети на основе нечеткой базы знаний, обучения ННС. В качестве решения предлагается ННС с алгоритмом обучения. Представлены результаты вычислительных экспериментов, подтверждающие высокую эффективность предложенного решения.

Ключевые слова: краткосрочное прогнозирование, потребление электроэнергии, сезонные временные ряды, нечеткие нейронные сети, синтез базы знаний, энергосбережение, идентификация, математическая модель, ассоциативные правила, обучение ННС

NEURO-FUZZY MODEL SHORT-TERM FORECASTING OF ENERGY CONSUMPTION

Al-Gunaid Mokhammed, post-graduate student, Volgograd State Technical University, 28 Lenin av., Volgograd, 400131, Russian Federation, e-mail: mohammadalgunaid@gmail.com

This research aims to develop a mathematical model of fuzzy neural network (FNN). FNN structure presented and justified and it allows accurate prediction of electricity consumption in the face of uncertainty. This article presents the solution of the problem of short-term forecasting of energy consumption, taking into account a number of seasonal patterns in the data, the calendar works, high-frequency data collection, low expert support in the construction of models and the need for the interpretability of results. It shows the implementation of the method, including the consistent application of algorithms of fuzzy variables based on time series, knowledge synthesis the synthesis of a fuzzy neural network based on fuzzy knowledge bases, training FNN. We see the solution is in the fuzzy neural network learning algorithm. The high efficiency of the proposed solutions during experimental results was confirmed.

Keywords: short-term forecasting, energy consumption, seasonal time series, fuzzy neural network, knowledge bases synthesis, energy saving, identification, mathematical model, association rules, learning fuzzy neural network

Введение

Проблема точности прогнозирования потребления электроэнергии являлась и остается на сегодняшний день актуальной. Это обусловлено наличием достаточно большого числа не фиксируемых факторов, влияющих на потребление электроэнергии, сложностью функционирования объектов – потребителей электроэнергии. Этот тезис подтверждается достаточно регулярным выходом публикаций по данной тематике в различных журналах. Адекватное решение проблемы прогнозирования позволит с более высокой точностью опре-

делять нагрузку на сеть, снизить риски при формировании энергетического баланса и заявок в энергогенерирующие компании [2].

Общая характеристика задачи

Сформулируем ряд особенностей, отличающих данное исследование от подобных (специфические свойства задачи).

1. Потребление электроэнергии представляет собой временной ряд с несколькими сезонными паттернами. Как правило, это суточные паттерны (значительное изменение потребления в ночное и дневное время), недельные паттерны (будни, выходные), годовые. Например, потребление электроэнергии в зданиях с офисами увеличивается зимой и летом.

2. Данные об энергопотреблении в современных системах коммерческого учета могут фиксироваться с различной частотой. Например, в странах Западной Европы это обычно 96 измерений в день, т.е. каждые 15 минут. Большинство исследований проводятся с минимальной частотой – раз в один час. Увеличение частоты оказывает влияние на методы выполнения прогнозов [8]. Рассматриваемый в данной работе временной ряд имеет частоту 15 минут, т.е. используются данные с высоким временным разрешением.

3. Зачастую модели прогнозирования имеют структуру «черного ящика», поэтому они трудно интерпретируемы [1]. В то же время интерпретация выявленных закономерностей является ключевым моментом при применении ряда подходов. Модели, которые являются простыми с точки зрения интерпретируемости, зачастую не удовлетворяют заданным критериям точности и полноты.

4. Пользователь системы прогнозирования, т.е. человек, которому требуется прогноз, зачастую не является специалистом в статистическом и интеллектуальном анализе данных. Таким образом, возникает проблема формирования структуры и параметров модели прогнозирования в автоматическом режиме при сравнительно небольшой доле участия пользователя в процессе.

5. Требуется сформировать краткосрочный прогноз (на сутки вперед) с заданной дискретностью, т.е. если сбор данных осуществлялся раз в 15 минут, то требуется сформировать прогноз на 96 отсчетов вперед.

Математическая постановка задачи

Пусть имеется исследуемый объект, потребляющий электроэнергию. Значения величин потребления электроэнергии $\{x_i\}$, где $i = \overline{t_0, t_k}$. Требуется разработать механизм M , формирующий прогноз потребления $\{\hat{x}_j\}$ на h временных отсчетов вперед, т.е. для $j = \overline{t_k + h}$, при котором ошибка прогнозирования не превышала бы заданный порог ϵ . При этом внутренняя структура механизма M , отражающая взаимосвязи между зависимой и независимыми переменными, должна быть понятна для исследователя и/или интерпретируема.

Метод прогнозирования

Алгоритм формирования нечетких переменных на основе временного ряда. Как правило, формирование нечетких переменных осуществляется экспертом или специалистом, решающим задачу прогнозирования. Если задачу решает человек без специальной подготовки, то ему достаточно сложно определить совокупность нечетких множеств, связанных с переменными и задать их параметры.

Пусть имеется временной ряд $\{x_i\}$. Предположим, что текущее значение временного ряда зависит от предыдущих значений, т.е. процесс описывается авторегрессионной моделью. Будем считать, что для всех переменных, используемых для построения модели авторегрессии, можно определить нечеткие множества $\{A_j\}$, где $j = \overline{1, m_A}$, для которых определены функции принадлежности. Следовательно, необходимо получить набор нечетких мно-

жеств $\{A_j\}$ и вид гауссовской функции принадлежности $\mu_{A_j}(x; c_j, \sigma_j)$, где j – номер нечеткого множества; c_j – центра класса нечеткого множества $\{A_j\}$; σ_j – коэффициент принадлежности гауссовской функции принадлежности. Значение принадлежности нечеткому множеству рассчитывается следующим образом:

$$\mu_{A_j}(x; c_j, \sigma_j) = \frac{1}{1 + \left(\frac{x_i - b_j}{\sigma_j} \right)^2}, \quad (1)$$

где x_j – элемент временного ряда. Центры классов нечетких множеств находятся по формуле:

$$c_j = x_{\min} + 2j\Delta c, \quad (2)$$

где $x_{\min}$ – минимальное значение временного ряда $\{x_i\}$, Δc – шаг, получаемый в соответствии с формулой:

$$\Delta c = \frac{x_{\max} - x_{\min}}{m_A}, \quad (3)$$

где $x_{\max}$ – максимальное значение временного ряда $\{x_i\}$.

Ниже дано описание алгоритма формирования нечетких переменных на основе временного ряда, предложенное ранее [6].

Задать значение m_A .

Определить $x_{\min}, x_{\max}$.

Рассчитать Δc по формуле (3).

Для каждого j -ого нечеткого множества определить c_j согласно (2), положить $\sigma_j = \sigma$ и $\sigma = const$.

Алгоритм синтеза базы знаний. Под базой знаний понимается совокупность нечетких продукционных правил. Главной идеей предлагаемого ниже подхода является исключение экспертов из процедуры формирования нечетких правил в результате анализа временных рядов. Это достигается с помощью следующего алгоритма [4, 7].

1. Задать число n для авторегрессионной переменной и значение лага τ .

2. Положить текущее значение времени $t = \tau + 1$.

3. Выбрать из временного ряда значения $\tilde{X}(t) = \{x_t - i\tau\}$, где $i = \overline{1, n}$.

4. Сформировать левую часть нечеткого правила:

а) для каждого значения из $\{x_t - i\tau\}$ выбрать нечеткие множества $\{A_k^{(i)}\}$, $k = \overline{1, n}$, где

$$A_k^{(i)} = \arg \left(\max_{k=1, m_A} (\mu_{A_k}(x_i)) \right), \quad (4)$$

т.е. нечеткие множества, для которых определены максимальные значения принадлежности x_i ;

б) составить n термов вида $x_t - i\tau = A_k^{(i)}$, где $i = \overline{1, n}$;

с) составить левую часть правила конъюнкцией полученных термов.

5. Сформировать правую часть правила для x_t аналогичным п. 4 образом.

6. Составить правило r_i из полученных левой и правой частей.

7. Проверить, имеется ли правило r_i . Если нет, то добавить в базу знаний.

8. Если выполняется условие $t = t_k$, то закончить процедуру, в противном случае положить $t = t + 1$ и перейти на шаг 3.

Алгоритм синтеза нечеткой нейронной сети на основе нечеткой базы знаний. Результатом выполнения предыдущего алгоритма является база знаний, состоящая из правил $\{r_i\}$, где $i = \overline{1, n_r}$, n_r – число правил. Каждое i -ое правило состоит из n_{li} термов в левой части и n_{ri} – в правой. На основе данной системы правил реализуем алгоритм формирования структуры нечеткой нейронной сети, состоящей из пяти слоев. Обозначим через $x_{(j)}^{(i)}$ j -ую компоненту i -го входного вектора, $j = \overline{1, s}$, где s – число элементов обучающей (или тестовой) выборки. Выходные сигналы обозначим как $y_j^{(l),(i)}$, где l – номер слоя нейронной сети; j – номер нейрона в слое. Для простоты обозначений опустим индекс (i) [5]. Далее нами используется следующий алгоритм.

1. Сформировать входной слой. Число нейронов в первом слое соответствует числу авторегрессионных переменных или числу термов в левой части нечетких правил. Выходные значения нейрона $y_j^{(1),(i)}$ вычисляются согласно формуле:

$$y_j^{(1)} = x_i. \quad (5)$$

2. Сформировать слой фаззификации. Число элементов в этом слое (нейронов-фаззификаторов) равно произведению авторегрессионных переменных на число нечетких множеств, определенных для этих переменных. Так, например, если мы учитываем потребление в два предыдущих момента времени и определили 3 нечетких множества – «низкое», «среднее» и «высокое» потребление, то число нейронов во входном слое равно 6. Нейрон-фаззификатор соединен с соответствующим нейроном входного слоя в соответствии с системой нечетких правил и реализует преобразование:

$$y_{j,k}^{(2)} = \mu_{A_k} \left(y_j^{(1)}; c_k, \sigma_k \right), \quad (6)$$

где k – номер нечеткого множества.

3. Сформировать слой минимизации. Данный слой состоит из n_r нейронов, характеризующих нечеткие правила. Каждый нейрон слоя минимизации соединен с нейронами предыдущего слоя в соответствии со структурой термов соответствующего правила. Нейрон минимизатор реализует операцию произведения входов, т.е. операцию минимизации по Мамдами [3].

$$y_j^{(3)} = \prod_{i=1}^{q_i} \left(y_j^{(2)} \right), \quad (7)$$

где q_i – число термов в левой части j -го правила.

4. Сформировать слой максимизации. Данный слой состоит из $2n$ нейронов, где n – число выходов. Каждый нейрон соединен с нейронами предыдущего слоя в соответствии со структурой правил. Для первого нейрона из пары $y_{j,(1)}^{(4)}$ значения весов ω , соединяющих нейроны предыдущего слоя, соответствуют значениям центров классов нечетких множеств для термов в правых частях нечетких правил. Для второго нейрона из пары $(y_{j,(2)}^{(4)})$ значения веса равны единице.

$$y_{j,(1)}^{(4)} = \sum_{i=1}^{n_r} \left(\omega_i y_j^{(3)} \right), \quad (8)$$

5. Сформировать выходной слой. Выходной слой (или слой дефаззификации) состоит из n нейронов, где n – число выходов. Выходной нейрон соединен с соответствующими выходу нейронами предыдущего слоя и реализует механизм дефаззификации относительно среднего центра [3]. Выход рассчитывается следующим образом:

Ниже представлен пример формирования нечеткой нейронной сети для случая двух нечетких правил, показанных на рисунке.

Слой 1

Слой 2

Слой 3

Слой 4

Слой 5

y_{t-1}

y_{t-2}

Сред

Выс

Малое

Малое

Сред

Выс

R_1

R_2

R_3

Сред

Выс

Малое

$y_{j,(1)}^{(4)}$

$y_{j,(2)}^{(4)}$

$y_j^{(5)}$

Входной слой

Слой входных значений функции принадлежности

Слой нечетких правил

Слой выходных значений функции принадлежности

Выходной слой

51

Алгоритм обучения нечеткой нейронной сети. Процесс обучения нечеткой нейронной сети определяет способ модификации весов и параметров в предлагаемой модели на основе алгоритма обратного распространения ошибки [6].

Вычислительный эксперимент

Информационная база для вычислительного эксперимента потребления электроэнергии с учетом факторов поведения – это информация об использовании здания: часы открытия/закрытия, календарь работы (рабочие и праздничные дни) за год включает 6 временных рядов (по рабочим дням недели). Они имеют разные количества значений в год (табл. 1).

Таблица 1

Измеренные значения потребления электроэнергии

День недели	Состояния использования здания	Количество членов во временном ряде
Понедельник	Открытое	1215
	Закрытое	3096
Вторник	Открытое	1645
	Закрытое	2861
Среда	Открытое	1645
	Закрытое	2812
Четверг	Открытое	2051
	Закрытое	2156
Пятница	Открытое	1610
	Закрытое	2780
Суббота	Открытое	2682
	Закрытое	1632

Ниже (табл. 2, 3) представлены результаты вычислительных экспериментов по прогнозированию потребления электроэнергии и оценки качества идентификации по критериям средней абсолютной процентной ошибки (Mean Absolute Percentage Error, MAPE) и средней квадратичной процентной ошибки (Root Mean Square Error, RMSE), с различными значениями нечетких множеств $\{A_j\}$ для каждого дня недели, где номер эксперимента означает порядковый номер дня недели в календаре.

Результаты вычислительных экспериментов получены при параметрах, идентичных для всех испытаний:

Изменение коэффициента пологости функции принадлежности от $\sigma_j = 5$ до $\sigma_j = 25$.

Число y_t авторегрессионной переменной $n = 4$.

Горизонт прогнозирования $\lambda = 96$.

Размер тестовой выборки $\alpha = 672$.

Таблица 2

**Результаты экспериментов по исследованию качества идентификации
модели краткосрочного прогнозирования потребления электроэнергии
при нахождении здания в открытом состоянии**

№ эксперимента	$\{A_j\}$	n_r	Дублирования	Противоречивость	MAPE	Лучший показатель MAPE при σ_j	RMSE	Лучший показатель RMSE при σ_j
1.1	4	885	0	0	Изменяется по возрастанию		0,004	12
1.2	8	885	0	0	Изменяется по возрастанию		Изменяется по возрастанию	
1.3	16	885	0	Различные значения	Изменяется по возрастанию		Изменяется по возрастанию	
2.1	4	1261	0	0	0,053	10	0,001	12
2.2	8	1261	2	Различные значения	Изменяется по возрастанию		Изменяется по возрастанию	
2.3	16	1261	Различные значения	Различные значения	Изменяется по возрастанию		Изменяется по возрастанию	
3.1	4	1261	0	0	Изменяется по возрастанию		Изменяется по возрастанию	
3.2	8	1261	0	0	Изменяется по возрастанию		Изменяется по возрастанию	
3.3	16	1261	0	0	Изменяется по возрастанию		Изменяется по возрастанию	
4.1	4	1778	0	0	Изменяется по возрастанию		Изменяется по убыванию	
4.2	8	1778	0	0	Изменяется по возрастанию		Изменяется по убыванию	
4.3	16	1778	0	Различные значения	Изменяется по возрастанию		0,005	10
5.1	4	1261	0	0	Уменьшается		Уменьшается	
5.2	8	1261	0	2	Увеличивается		Увеличивается	
5.3	16	1261	0	2	Увеличивается		Увеличивается	
6.1	4	1261	0	0	Увеличивается		Увеличивается	
6.2	8	1261	0	0	Увеличивается		Увеличивается	
6.3	16	1261	0	0	Увеличивается		Увеличивается	

Таблица 3

**Результаты экспериментов по исследованию качества идентификации модели
 краткосрочного прогнозирования потребления электроэнергии
 при нахождении здания в закрытом состоянии**

№ эксперимента	$\{A_j\}$	n_r	Дублирования	Противоречивость	MAPE	Лучший показатель MAPE при σ_j	RMSE	Лучший показатель RMSE при σ_j
1.1	4	2859	0	14	Изменяется по возрастанию		Изменяется по возрастанию	
1.2	8	2859	0	Различные значения	Изменяется по возрастанию		Изменяется по возрастанию	
1.3	16	2859	0	Различные значения	Изменяется по возрастанию		Изменяется по возрастанию	
2.1	4	2483	0	12	Изменяется по возрастанию		Изменяется по возрастанию	
2.2	8	2483	0	12	Изменяется по возрастанию		Изменяется по возрастанию	
2.3	16	2483	0	12	Изменяется по возрастанию		Изменяется по возрастанию	
3.1	4	2483	0	Различные значения	Изменяется по возрастанию		Изменяется по возрастанию	
3.2	8	2483	0	4	Изменяется по возрастанию		Изменяется по возрастанию	
3.3	16	2483	0	Различные значения	Изменяется по возрастанию		Изменяется по возрастанию	
4.1	4	1870	3	60	Изменяется по возрастанию		Изменяется по возрастанию	
4.2	8	1870	3	60	Изменяется по возрастанию		Изменяется по возрастанию	
4.3	16	1870	3	60	0,302	13	Увеличивается	
5.1	4	2483	0	Различные значения	Увеличивается		Увеличивается	
5.2	8	2483	0	Различные значения	Увеличивается		Увеличивается	
5.3	16	2483	Различные значения	Различные значения	Увеличивается		Увеличивается	
6.1	4	2483	0	14	0,653	17	Увеличивается	
6.2	8	2483	0	14	Увеличивается		Увеличивается	
6.3	16	2483	0	14	Увеличивается		Увеличивается	

В ходе проведения вышеописанных вычислительных экспериментов мы подтвердили результативность предложенной совокупности методов. При наблюдении за изменениями коэффициента пологости функции принадлежности в интервале от 5 до 25 были выявлены лучшие показатели по критерию MAPE – «10» при нахождении здания в открытом

состоянии и «13» – в закрытом. Критерий RMSE при нахождении здания в открытом состоянии – «12», в закрытом состоянии его значения меняются.

Заключение

В результате проведенных исследований были изучены вопросы идентификации систем в условиях нечеткой информации и проблемы слабой интерпретируемости моделей идентификации. Также разработаны модели нечеткой нейронной сети для автоматического решения задачи идентификации. Кроме того, разработаны алгоритмы предварительной обработки информации. В процессе работы алгоритмы были реализованы в виде программ и испытаны на примере задачи прогнозирования потребления электроэнергии.

Приведенные результаты позволяют сделать вывод о том, что предложенные методы могут применяться для повышения точности прогнозов в условиях неопределенности.

Список литературы

1. Камаев В. А. Применение нечетких нейросетевых моделей для идентификации состояния автомобильных дорог / В. А. Камаев, М. В. Щербаков, Д. А. Скоробогатченко // Вестник компьютерных и информационных технологий. – 2010. – № 12. – С. 36–41.
2. Макоклюев Б. И. Анализ и планирование электропотребления / Б. И. Макоклюев. Москва : Энергоатомиздат, 2008. – 296 с.
3. Тарков М. С. Нейрокомпьютерные системы / М. С. Тарков. – Режим доступа: <http://www.intuit.ru/department/expert/neuro/15/2.html> (дата обращения 10.04.2012), свободный. – Загл. с экрана. – Яз. рус.
4. Щербаков М. В. Применение нечетких нейронных сетей для краткосрочного прогнозирования потребления электроэнергии в коммерческих зданиях / М. В. Щербаков, М. А. Аль-Гунаид // Современные проблемы и пути их решения в науке, транспорте, производстве и образовании'2012 : мат-лы междунар. науч.-практ. конф. – Одесса, 2012. – Вып. 4. – С. 53–55.
5. Щербаков М. В. Проблемы проектирования систем прогнозирования эксплуатационного состояния автомобильных дорог на основе нечетких нейронных сетей / М. В. Щербаков, Д. А. Скоробогатченко, А. А. Авдеев, М. А. Аль-Гунаид // Изв. ВолгГТУ. Сер. Актуальные проблемы управления, вычислительной техники и информатики в технических системах. – 2011. – Вып. 10, № 3. – С. 82–87.
6. Щербаков М. В. Разработка и исследование гибридных нечетких моделей идентификации для прогнозирования потребления электроэнергии / М. В. Щербаков, М. А. Аль-Гунаид // Изв. ВолгГТУ. Сер. Актуальные проблемы управления, вычислительной техники и информатики в технических системах. – 2012. – Вып. 14, № 15. – С. 66–72.
7. Щербаков М. В. Специфика применения интеллектуальных моделей анализа данных для повышения энергетической эффективности / М. В. Щербаков и др. // Изв. ВолгГТУ. Сер. Актуальные проблемы управления, вычислительной техники и информатики в технических системах. – 2010. – Вып. 9, № 11. – С. 72–76.
8. Ummuhan Basaran Filik. A novel modeling approach for hourly forecasting of long-term electric energy demand / Ummuhan Basaran Filik, Omer Nezih Gerek, Mehmet Kurban // Energy Conversion and Management. – 2011. Vol. 52, № 1. – P. 199–211.

References

1. Kamaev V. A., Shcherbakov M. V., Skorobogatchenko D. A. Primenenie nechetkikh neyros-etevykh modeley dlya identifikatsii sostoyaniya avtomobilnykh dorog [Application of fuzzy neural network models for identification of autoroad state]. *Vestnik kompyuternykh i informatsionnykh tekhnologiy* [Bulletin of computer and information technologies], 2010, no. 12, pp. 36–41.
2. Makoklyuev B. I. *Analiz i planirovanie elektropotrebleniya* [Analysis and planning of power consumption]. Moscow, 2008. 296 p.
3. Tarkov M. S. *Neyrokompyuternye sistemy* [Neurocomputer systems]. Available at <http://www.intuit.ru/department/expert/neuro/15/2.html> (accessed 10 April 2012).
4. Shcherbakov M. V., Al-Gunaid M. A. Primenenie nechetkikh neyronnykh setey dlya kratkos-rochnogo prognozirovaniya potrebleniya elektroenergii v kommercheskikh zdaniyakh [Application of fuzzy neuron networks for short-term forecasting of power consumption in commercial buildings]. *Sovremennye*

problemy i puti ikh resheniya v nauke, transporte, proizvodstve i obrazovanii'2012: materialy mezhdunarodnoy nauchno-prakticheskoy konferentsii [Current problems and ways of their solution in science, transport and education'2012: Proceedings of the International Scientific-Practical Conference]. Odessa, 2012, issue 4, pp. 53–55.

5. Shcherbakov M. V., Skorobogatchenko D. A., Avdeev A. A., Al-Gunaid M. A. Problemy proektirovaniya sistem prognozirovaniya ekspluatatsionnogo sostoyaniya avtomobilnykh dorog na osnove nechetkikh neyronnykh setey [Problems of designing of forecasting of exploitation state of roads based on fuzzy neuron networks]. *Izvestiya Volgogradskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya. Aktualnye problemy upravleniya, vychislitel'noy tekhniki i informatiki v tekhnicheskikh sistemakh* [News of Volgograd State Technical University. Series. Actual problems of management, computer engineering and informatics in technical systems], 2011, issue 10, no. 3, pp. 82–87.

6. Shcherbakov M. V., Al-Gunaid M. A. Razrabotka i issledovanie gibridnykh nechetkikh modeley identifikatsii dlya prognozirovaniya potrebleniya elektroenergii [Development and research of hybrid fuzzy identification models for forecasting power consumption]. *Izvestiya Volgogradskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya. Aktualnye problemy upravleniya, vychislitel'noy tekhniki i informatiki v tekhnicheskikh sistemakh* [News of Volgograd State Technical University. Series. Actual problems of management, computer engineering and informatics in technical systems], 2012, issue 14, no. 15, pp. 66–72.

7. Shcherbakov M. V. et al. Spetsifika primeneniya intellektualnykh modeley analiza dannykh dlya povysheniya energeticheskoy effektivnosti [Specificity of application of intellectual models of data analysis for increasing energetic efficiency]. *Izvestiya Volgogradskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya. Aktualnye problemy upravleniya, vychislitel'noy tekhniki i informatiki v tekhnicheskikh sistemakh* [News of Volgograd State Technical University. Series. Actual problems of management, computer engineering and informatics in technical systems], 2010, issue 9, no. 11, pp. 72–76.

8. Ummuhan Basaran Filik, Omer Nezhil Gerek, Mehmet Kurban. A novel modeling approach for hourly forecasting of long-term electric energy demand. *Energy Conversion and Management*, 2011, vol. 52, no. 1, pp. 199–211.

УДК 539.193/.194;535/33.34

СТРУКТУРНО-ДИНАМИЧЕСКИЕ МОДЕЛИ ДИМЕРОВ МОНОГИДРОКСИУРАЦИЛА СО СЛАБОЙ ВОДОРОДНОЙ СВЯЗЬЮ

Элькин Михаил Давыдович, доктор физико-математических наук, профессор, Астраханский государственный университет, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а, e-mail: elkinmd@mail.ru

Смирнов Владимир Вячеславович, кандидат физико-математических наук, доцент, Астраханский государственный университет, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а, e-mail: kofl@aspu.ru

Джалмухамбетова Елена Азатуллаевна, кандидат физико-математических наук, доцент, Астраханский государственный университет, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а, e-mail: kofl@aspu.ru

Гречухина Оксана Николаевна, кандидат физико-математических наук, доцент, Астраханский государственный университет, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а, e-mail: kofl@aspu.ru

Алыкова Ольга Михайловна, кандидат педагогических наук, доцент, Астраханский государственный университет, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а, e-mail: kofl@aspu.ru

Гайсина Альфия Рафаиловна, ассистент, Астраханский государственный университет, 414056, Российская Федерация, г. Астрахань, ул. Татищева, 20а, e-mail: kofl@aspu.ru