

УДК 681.326

Определение наиболее перспективных нейронных сетей и способов их обучения для прогнозирования электропотребления

Б.А. Староверов, Б.А. Гнатюк
ФГБОУВПО «Костромской государственной технологической академии»,
г. Кострома, Российская Федерация
E-mail: sba44@mail.ru

Авторское резюме

Состояние вопроса: Для оптимизации режимов загрузки электрических сетей, повышения эффективности процедур закупок на оптовом рынке электроэнергии сбытовыми компаниями первостепенное значение имеет максимально точное прогнозирование электропотребления. Для этого разработано большое количество различных способов и технологий прогнозирования потребления электроэнергии. В связи с этим актуальной является проблема создания универсальной методики прогнозирования.

Материалы и методы: Наиболее перспективным для разработки универсальных средств прогнозирования почасового электропотребления является использование искусственных нейронных сетей.

Результаты: Определен минимальный набор значимых факторов и размерность входного обучающего вектора, который обеспечивает универсальность нейросетевого метода прогнозирования. Определен необходимый размер массива данных для почасового прогнозирования электропотребления «на сутки вперед». Экспериментальным методом выявлены типы искусственных нейронных сетей, их архитектура и состав, которые обеспечивают максимальную точность прогнозирования при минимальном наборе значимых факторов.

Выводы: Различные типы нейронных сетей дают минимальную погрешность прогнозирования в разные часы суточного графика потребления электроэнергии, и невозможно найти такую универсальную искусственную нейронную сеть, которая бы давала минимально достижимую погрешность в течение всего периода прогнозирования. Дальнейшее повышение качества прогнозирования электропотребления можно обеспечить объединением наиболее эффективных нейронных сетей в многоуровневую систему.

Ключевые слова: электропотребление, почасовое прогнозирование, искусственные нейронные сети, архитектура нейронной сети, набор факторов, многоуровневая система.

Determining of the most promising artificial neural networks and ways of their training to forecast electrical energy consumption

B.A. Staroverov, B.A. Gnatyuk
Kostroma State University of Technology, Kostroma, Russian Federation
E-mail: sba44@mail.ru

Abstract

Background: One of the main ways to optimize power systems operating modes and improve the efficiency of utility companies' procurement procedures on the wholesale market is accurate forecasting of power consumption. There are a lot of different methods and techniques of energy consumption forecasting. However, the problem of creating a universal forecasting method remains unsolved.

Materials and methods: Studies show that the use of artificial neural networks is the most promising technique of developing a universal method of hourly electricity consumption forecast.

Results: The minimum set of important factors, and the dimension of the input training vector providing the flexibility of neural network forecasting method have been determined. The necessary size of the array of data to predict the hourly electricity consumption «day-ahead» has been also obtained. Experimental methods identified types, architecture and composition of artificial neural networks that ensure the maximum forecasting accuracy with the minimum set of significant factors.

Conclusions: Different types of neural networks have minimum prediction error at different times of the daily consumption schedule, and it is impossible to find a universal artificial neural network with the minimum achievable error during the whole forecast period. Improving the quality of power consumption prediction can be achieved by combining the most effective neural networks into a multi-level system.

Key words: electrical energy consumption, hourly forecasting, artificial neural networks, neural network architecture, factor set, multilayer system.

DOI: 10.17588/2072-2672.2015.6. 059-064

Для большого количества прикладных задач по обеспечению энергоэффективности и энергосбережения, по определению оптимальных режимов загрузки электрических сетей, по

оптимизации процедуры закупок на оптовом рынке электроэнергии первостепенное значение имеет максимально точное прогнозирование электропотребления [1, 2, 3]. В связи с этим

разработано и разрабатывается по сей день большое количество различных способов и технологий прогнозирования потребления электроэнергии. Тем не менее проблема создания универсальной методики прогнозирования еще далека от окончательного решения. Это связано с рядом принципиальных трудностей.

Во-первых, для планирования и управления требуются прогнозы на различную перспективу: оперативный (на час вперед), краткосрочный (на сутки вперед), среднесрочный (на неделю, на месяц) и долгосрочный (на квартал, год).

Во-вторых, для решения многих практических задач необходимы довольно высокие показатели точности прогнозирования. Наиболее часто для оценки качества прогнозов используются такие показатели, как среднее отклонение (СО):

$$\varepsilon_{\text{со}} = \frac{1}{n} \sum_{n=1}^n \frac{|P_{\text{пр}} - P_{\text{ф}}|}{P_{\text{ф}}} 100\%,$$

и среднее квадратичное отклонение (СКО):

$$\varepsilon_{\text{ско}} = \frac{1}{n} \sum_{n=1}^n \frac{(P_{\text{пр}} - P_{\text{ф}})^2}{P_{\text{ф}}^2} 100\%,$$

где $P_{\text{пр}}$, $P_{\text{ф}}$ – прогнозное и фактическое значения потребления электроэнергии соответственно; n – число отдельных прогнозов (почасовых, посуточных и т.п.).

Эти показатели должны находиться в пределах 1,5–5 %.

Наряду с такими усредненными показателями, в определенных случаях требуется высокая точность в каждом текущем значении прогнозов. Например, при покупке электроэнергии сбытовыми компаниями на Федеральном оптовом рынке энергии и мощности (ФОРЭМ) осуществляется маргинальное ценообразование, с учетом потерь и системных ограничений [8]. На балансирующем рынке, если ошибка прогнозирования превышает 2 % в более 30 % случаях отдельных почасовых прогнозов потребления, назначается существенный по своим размерам штраф. Поэтому целесообразно оценивать точность прогнозирования количеством и (или) процентом попадания получаемых прогнозов с погрешностями, находящимися в определенных интервалах:

$$\eta_i = \frac{n_i}{N} 100\%,$$

где N – множество единичных (например, почасовых) прогнозов; $n_i \in N$ – число прогнозов, погрешность которых находится в интервале, определяемом выражением

$$\varepsilon_i = \frac{|P_{\text{пр}} - P_{\text{ф}}|}{P_{\text{ф}}} 100\% \leq \Delta_i,$$

где, например, $\Delta_i = 0-3\%$; $> 3-5\%$; $> 5-10\%$; $> 10\%$.

В-третьих, вид, а следовательно, и график потребления электроэнергии зависят

от большого количества разнородных факторов и условий.

Потребители электроэнергии отличаются как по масштабу (регион, район, предприятие), так и по характеру (бытовые, промышленные, смешанные). От этого зависит набор факторов, которые необходимо учитывать для обеспечения требуемой точности прогнозирования. Например, при прогнозировании в масштабе региона существенно значимыми являются такие факторы, как время года (зима, лето), тип дня (рабочий, выходной) и т.д. В отличие от этого, для прогноза электропотребления в масштабе предприятия наибольшую значимость приобретают такие факторы, как режим работы предприятия, вид технологических циклов и т.д.

Сложность проблемы породила множество методов прогнозирования, поэтому первоочередной задачей является выбор наиболее эффективного метода прогнозирования.

Наибольшее распространение получили следующие методы [4, 5, 6]:

- аналитические и статистические методы (метод авторегрессии, метод сезонных кривых, факторный анализ и др.);
- эволюционный метод, основанный на мутации и естественном отборе особей, максимально удовлетворяющих требуемым критериям. В качестве особей популяции выступают детерминированные автоматы Мили, которые в процессе решения подвергаются случайным изменениям, а в качестве критерия оптимальности используется минимизация ошибки прогнозирования;
- методы, основанные на использовании фильтра Винера;
- методы, основанные на использовании искусственных нейронных сетей (ИНС).

Применение того или иного метода прогнозирования зависит, в свою очередь, от объема априорной информации и от условий и видов прогнозов, которые были рассмотрены выше. Наиболее сложной и актуальной задачей является почасовое прогнозирование «на сутки вперед», которое требуется: субъектам ФОРЭМ – для оптимизации своих стратегий поведения на оптовом рынке; сетевым и генерирующим компаниям – для получения сбалансированных графиков производства и потребления электроэнергии. Однако отсутствие инвариантных к различным условиям потребления электроэнергии методов и средств прогнозирования является причиной затратных по времени и средствам работ по постоянной адаптации предлагаемых инструментов прогнозирования, что в итоге приводит к широкому распространению «ручных» методов со всеми вытекающими отсюда недостатками.

Исследования показывают, что наиболее перспективным для разработки универсальных средств почасового прогнозирования «на сутки вперед» является использование искусствен-

ных нейронных сетей. Это подтверждается наличием большого количества исследований и разработок по прогнозированию с использованием ИНС [7, 8, 9]. Однако именно в создании универсальных или инвариантных средств прогнозирования даже на основе ИНС не наблюдается заметных успехов. Это обусловлено тем, что разработки систем прогнозирования на основе ИНС практически не поддаются формализации и, в основном, базируются на эвристических технологиях. Поэтому данную проблему необходимо решать с использованием системного подхода. На первом этапе целесообразно провести декомпозицию проблемы на ряд взаимосвязанных задач:

– определение входного вектора или количества факторов, которые необходимо принимать во внимание для прогнозирования на основе ИНС. При этом критериями или требованиями отбора значимых факторов являются достижение необходимой точности прогнозирования и минимизация размерности входного вектора. Очевидно, эти критерии являются противоречивыми и требуют компромиссного решения;

– определение необходимого объема обучающих, тестовых и контрольных выборок. При решении этой задачи также возникают противоречивые требования, связанные со способностью нейронных сетей к обобщению (проблема недоученности и переученности сети);

– выбор типа, структуры и состава нейронной сети. Данная задача является наиболее сложной. В настоящее время известно более сотни различных видов нейронных сетей. Среди них многослойные сети, радиально-базисные сети, сети с внутренними обратными связями, сети, использующие нечеткие множества, и др. Для обучения нейронных сетей используются статистические данные почасового потребления электроэнергии за несколько лет. Количество данных потребления или производства электроэнергии за один год составляет почти 9 тысяч. В связи с этим имеется возможность использования нейронных сетей сложной структуры с большим количеством нейронов и синаптических связей (весов), чтобы обеспечить требуемую универсальность или инвариантность прогнозирования в отношении графиков производства и потребления электроэнергии.

Задача по определению размерности входного вектора и состава значимых факторов для прогнозирования решалась с позиции максимальной универсальности (унификации). Для этого исключена операция масштабирования переменных, среди входных переменных отсутствуют показатели погоды и характеристики графиков нагрузки (пики, полу-пики, провалы). Отказ от таких переменных придает универсальность прогнозированию в отноше-

нии зависимости от погодных условий, часовых и климатических поясов. Данные факторы, конечно, влияют на потребление электроэнергии [10], но эти влияния должны учитываться опосредованно.

Исходя из принципа минимальности размерности входного вектора были выбраны следующие обучающие переменные:

- статические переменные – день недели (понедельник, вторник, ... воскресенье), месяц (январь, февраль, ... декабрь), час (1, 2, ..., 24);

- динамические переменные – почасовое потребление электроэнергии, отражающее изменение потребления электроэнергии в предшествующие дни. Для прогнозирования почасового потребления электроэнергии «на сутки вперед» проведена проверка ретроспективного сдвига от одних до восьми суток. В качестве тестируемой нейронной сети была выбрана нейросеть с прямым распределением и задержкой по времени. Результаты тестирования представлены в табл. 1.

Таблица 1

Величина сдвига (сутки)	Погрешность прогнозирования	
	СО	СКО
1	3,479	4,417
3	3,484	4,371
5	3,337	4,258
7	3,247	4,164
8	3,111	3,960

Анализ данных табл. 1 показывает, что с добавлением ретроспективных данных повышается точность прогнозирования, но при этом увеличивается размерность входного вектора. Экспериментально установлена компромиссная закономерность, которая определяет, что допустимым ретроспективным сдвигом, при котором точность прогнозирования снижается незначительно, является пять суток. При меньшем сдвиге существенно снижается точность, а при увеличении ретроспективы входной вектор становится слишком большим, что создает проблемы в обучении нейронных сетей из-за значительного массива данных.

Таким образом, формируется компактный входной вектор (Impute), состоящий из 8 переменных:

$$\text{Imp} = \{X_{N-1} X_{N-2} X_{N-3} X_{N-4} X_{N-5} T D M\},$$

где X_{N-i} , $i = 1, 2, \dots, 5$ – ретроспективные данные потребления электроэнергии на момент со сдвигом на пять дней, соответствующий прогнозируемому (X_N – прогнозируемое потребление); $T \subset \{1 2 3 4 \dots 24\}$ – значение часа, на момент которого осуществляется прогнозирование; $D \subset \{1 2 3 4 5 6 7\}$; – обозначение дня недели, на момент которой осуществляется прогнозирование (1 – поне-

дельник, 2 – вторник, ... 7 – воскресенье); $M \subset \{1\ 2\ 3\ 4\ 5\ 6\ 7\ 8\ 9\ 10\ 11\ 12\}$ – обозначение месяца, на момент которого осуществляется прогнозирование (1 – январь, 2 – февраль, ..., 12 – декабрь).

Переменные X_{N-i} являются количественными, а переменные T, D, M – порядковыми.

В целях исключения переобученности сетей размерность входного вектора была расширена до 12 без увеличения количества учитываемых факторов. Для этого в составе вектора фактор T был продублирован пять раз, что соответствует количеству ретроспективных данных потребления электроэнергии. Результаты проверки данной гипотезы представлены в табл. 2.

Таблица 2

Количество входов	Количество и % попадания в интервалы ошибок			
	0–3 %	3–5 %	5–10 %	> 10 %
8	74 44,04	49 29,16	40 23,8	5 3
12	87 51,78	47 27,98	34 20,24	0 0

Эксперимент проводился на нейросети с прямым распределением и задержкой по времени. Он доказывает, что расширение размерности входного вектора без увеличения значимых факторов приводит к ощутимому улучшению точности прогнозирования.

Дальнейшая модификация входного вектора связана с необходимостью повышения точности прогнозирования в предпраздничные и праздничные дни, так как в эти дни график потребления электроэнергии существенно отличается от будничных и даже выходных дней. Для идентификации предпраздничных и праздничных дней вводится дополнительная переменная определения аномалий, которая при обучении нейросетей часы предпраздничных дней идентифицирует цифрой 2, часы праздничных дней – цифрой 1, а часы будничных дней – цифрой 0. В процессе непосредственного прогнозирования значения дополнительной переменной изменяются: часы будничных и предпраздничных дней идентифицируются цифрой 0, часы праздничных дней – цифрой 1. Это делается в целях исключения переобученности сети.

Представленные в табл. 3 экспериментальные данные подтверждают целесообразность такой модификации (расширения) входного вектора, так как она обеспечивает универсальность почасового прогнозирования «на сутки вперед».

Вторая задача (определение необходимого объема обучающих выборок) также решается экспериментальным методом. Эксперименты показали, что наилучший результат

при ограничениях на трудоемкость обучения ИНС достигается на данных трех предыдущих лет, включая текущий год.

Таблица 3

Название нейронной сети	Входной вектор	Погрешность прогнозирования	
		СО	СКО
Нейросеть с прямым распределением и задержкой по времени	Без модификации	2,520	3,472
Нейросеть с прямым распределением и задержкой по времени	С вектором определения аномалий	1,893	2,362

Для решения третьей задачи (выбор типа, структуры и состава нейронной сети) были протестированы сети различных видов – это линейная сеть, нейросеть с прямым распределением; нейросеть с прямым распределением и задержкой по времени; нейросеть Элмана; нейросеть с каскадным распределением; рекуррентная многослойная нейросеть и др. [11].

Фрагмент наиболее удачных результатов экспериментальных исследований различных типов нейронных сетей при использовании входного вектора размерностью 12 представлен в табл. 4.

Таблица 4

Название нейронной сети	Количество нейронов	Количество и % попадания в интервалы ошибок			
		0–3 %	3–5 %	5–10 %	> 10 %
Линейная нейросеть	1	63 37,5	44 26	52 31	9 5,5
Нейросеть с прямым распределением и задержкой по времени	75	87 51,8	47 27,97	34 20,23	0 0
Нейросеть Элмана	75	100 59,52	31 18,48	37 22	0 0
Нейросеть с прямым распределением	75	77 45,93	35 20,83	51 30,35	5 2,97
Нейросеть с каскадным распределением	75	80 47,61	39 23,21	44 26,19	5 2,97
Рекуррентная многослойная нейросеть	75	72 42,58	39 23,21	47 27,97	10 5,95
Двухслойная нейросеть Элмана	30–35	88 52,38	41 24,4	37 22,02	2 1,19

Анализ данных табл. 4 показывает, что наиболее перспективным для прогнозирования электропотребления является использование однослойных и двухслойных нейронных сетей

следующих типов: нейронной сети Элмана; нейросети с прямым распределением; нейросети с прямым распределением и задержкой по времени; нейросети с каскадным распределением.

Сопряженной с проблемой выбора типа нейронных сетей является проблема определения структуры сети, т.е. необходимого количества нейронов и слоев. Для решения данной задачи были получены зависимости точности прогнозирования от количества нейронов для различных типов ИНС. Один из примеров таких зависимостей для нейросети с прямым распределением, представлен в табл. 5.

Таблица 5

Количество нейронов	Количество и % попадания в интервалы ошибок			
	0–3 %	3–5 %	5–10 %	> 10 %
10	385 53,47	175 24,3	145 20,13	15 2,08
15	375 52,08	189 26,25	146 20,27	10 1,38
20	378 52,5	183 25,41	150 20,83	9 1,25
25	394 54,72	191 26,52	126 17,5	9 1,25
30	384 53,33	179 24,86	144 20	13 1,8
35	392 54,44	185 25,69	134 18,61	9 1,25
40	380 52,77	187 25,97	145 20,13	8 1,11
45	406 56,38	181 25,13	124 17,22	9 1,25
50	403 55,97	177 24,58	132 18,33	8 1,11
55	399 55,41	173 24,02	144 20	4 0,55
60	371 54,52	185 25,69	155 21,52	9 1,25
65	399 55,41	167 23,19	142 19,72	12 1,66
70	372 51,66	203 28,19	137 19,02	8 1,11
75	398 55,27	180 25	137 19,02	5 0,69
80	411 57,08	174 24,16	125 17,36	10 1,38
85	368 51,11	176 24,44	166 23,05	10 1,38

Анализ данных табл. 5 показывает, что нейросеть с прямым распределением имеет четыре пика точности: при 25, 35, 45, 55 и 75 нейронах.

Эксперименты с другими типами ИНС показывают, что практически все нейросети имеют несколько пиков точности на интервале от 10 до 55 нейронов («нижняя граница») и на интервал от 70 до 75 нейронов («верхняя граница»). Вследствие чего можно сделать вывод, что даже при небольшом количестве нейронов нейросеть может дать хорошую точность прогнозирования. Однако «нижняя» граница количества нейронов является плавающей, в зависимости от типа нейросети. «Верхняя» граница

имеет большую стабильность, т.е. в меньшей степени зависит от типа сети. Поэтому большей универсальностью обладают нейросети с числом нейронов 70–75.

Это подтверждается и при использовании ИНС двухслойной структуры. Для различных типов нейросетей с различными функциями активации выделяется общий пик точности при 40 нейронах в первом скрытом слое и при 35 нейронах во втором скрытом слое, что дает в сумме 75 нейронов.

Таким образом, при выборе структуры однослойной нейронной сети для обеспечения универсальности прогнозирования рекомендуется использовать 70–75 нейронов в первом скрытом слое, при использовании двухслойной структуры нейронной сети целесообразно иметь 35–40 нейронов в первом скрытом слое и 30–35 нейронов во втором скрытом слое. В качестве функции активации в первом слое рекомендуется использовать сигмоид, чтобы избежать проблемы шумового насыщения, во втором слое можно использовать как линейную, так и тангенциальную функции.

Кроме того, анализ результатов экспериментальных исследований точности прогнозов почасового потребления показывает, что различные типы ИНС дают минимальную погрешность прогнозирования в разные часы суточного графика потребления электроэнергии и невозможно найти такую универсальную ИНС, которая бы давала минимально достижимую погрешность в течение всего периода прогнозирования. Поэтому дальнейшее повышение качества и универсальности методов и средств прогнозирования можно обеспечить лишь путем объединения наиболее эффективных нейронных сетей, в многоуровневую нейросетевую систему [3, 8].

Заключение

В результате проведенных исследований определен минимальный набор значимых факторов и размерность входного обучающего вектора, который обеспечивает универсальность прогнозирования на основе использования ИНС. При этом в состав обучающего или входного вектора должны быть включены данные почасового потребления электроэнергии с ретроспективой относительно момента прогнозирования на пять дней.

Для исключения переученности нейросетей необходимо расширить размерность обучающего вектора без увеличения значащих факторов путем кратного глубине ретроспективы дублирования переменной, соответствующей значению часа, на момент которого осуществляется прогнозирование.

Необходимый размер массива данных для почасового прогнозирования электропо-

требления «на сутки вперед» должен включать данные потребления трех предшествующих лет.

Экспериментальным методом выявлены типы искусственных нейронных сетей, их архитектура и состав, которые обеспечивают максимальную точность прогнозирования при минимальном наборе значимых факторов.

Различные типы ИНС дают минимальную погрешность прогнозирования в разные часы суточного графика потребления электроэнергии, и невозможно найти такую универсальную ИНС, которая бы давала минимальную погрешность в течение всего периода прогнозирования. Поэтому дальнейшее повышение качества и универсальности методов и средств прогнозирования электропотребления может дать лишь объединение нейронных сетей в многоуровневую систему.

Список литературы

1. **Беляев Л.С., Шурупов В.В.** Сравнительный анализ моделей оптового рынка электроэнергии // Энергоэксперт. – 2008. – № 3(8). – С. 58–63.
2. **Гельфанд А.М., Фридман Л.И., Мисриханов М.Ш.** Основные принципы создания автоматизированных систем технологического управления предприятиями межсистемных электрических сетей ФСК ЕЭС // Вестник ИГЭУ. – 2004. – Вып. 2. – С. 78–82.
3. **Староверов Б.А., Гнатюк Б.А.** Повышение эффективности системы автоматизированного контроля и учета электроэнергии за счет введения функций прогнозирования // Вестник ИГЭУ. – 2013. – Вып. 5. – С. 43–46.
4. **Бэнн Д.В., Фармер Е.Д.** Сравнительные модели прогнозирования электрической нагрузки: пер. с англ. – М.: Энергоатомиздат, 1987.
5. **Шумилова Г.П., Готман Н.Э., Старцева Т.Б.** Прогнозирование электрических нагрузок при оперативном управлении электроэнергетическими системами на основе нейросетевых структур. – Сыктывкар: КНЦ УрО РАН, 2008. 76 с.
6. **Поляхов Н.Д., Приходько И.А., Ван Ефэн.** Прогнозирование электропотребления на основе метода опорных векторов с использованием эволюционных алгоритмов оптимизации // Современные проблемы науки и образования. – 2013. – № 2. – URL: <http://www.science-education.ru/108-8962>
7. **Бажинов А.Н.** Методика формирования прогнозных значений электропотребления в металлургии с помощью аппарата нейро-нечетких сетей // Наука и техника XXI века: материалы междунар. заоч. науч.-практ. конф. – Новосибирск, 2011. – С. 110–115.
8. **Староверов Б.А., Мормылев М.А.** Прогнозирование и управление энергопотреблением с помощью ансамбля нейронных сетей // Проблемы автоматизации и управления в технических системах: тр. Междунар. науч.-техн. конф. – Пенза: Изд-во ПГУ, 2009. – С. 239–242.
9. **Бирюков Е.В., Корнев М.С.** Практическая реализация нечеткой нейронной сети при краткосрочном прогнозировании электрической нагрузки [Электронный ресурс]. – Режим доступа: <http://library.mephi.ru/data/scientific-sessions/2005/nero/ch2/3-2-1.doc>
10. **Макоклюев Б.И., Еч В.Ф.** Учет влияния метеорологических факторов при прогнозировании электропотребления энергообъединений [Электронный ресурс]. – Режим доступа: http://www.masters.donntu.edu.ua/2006/kita/chuykov/library/library/article_7.htm
11. **Осовский С.** Нейронные сети для обработки информации / пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с.

References

1. Belyaev, L.S., Shurupov, V.V. *Sravnitel'nyy analiz modeley optovogo rynka elektroenergii* [Comparative analysis of wholesale electric power market models]. *Energoekspert*, 2008, no. 3(8), pp. 58–63.
2. Gelfand, A.M., Fridman, L.I., Misrikhanov, M.Sh. *Osnovnye printsipy sozdaniya avtomatizirovannykh sistem tekhnologicheskogo upravleniya predpriyatiyami mezhssystemnykh elektricheskikh setey FSK EES* [Basic principles of developing automated process control systems of intersystem power networks of the Federal Grid Company]. *Vestnik IGEU*, 2004, issue 2, pp. 78–82.
3. Staroverov, B.A., Gnatyuk, B.A. *Povyshenie effektivnosti sistemy avtomatizirovannogo kontrolya i ucheta elektroenergii za schet vvedeniya funktsiy prognozirovaniya* [Improving the efficiency of power automated control and metering system by introducing forecasting functions]. *Vestnik IGEU*, 2013, issue 5, pp. 43–46.
4. Benn, D.V., Farmer, E.D. *Sravnitel'nye modeli prognozirovaniya elektricheskoy nagruzki* [Comparative models of power load forecasting]. Moscow, Energoatomizdat, 1987.
5. Shumilova, G.P., Gotman, N.E., Startseva, T.B. *Prognozirovaniye elektricheskikh nagruzok pri operativnom upravlenii elektroenergeticheskimi sistemami na osnove neyrosetevykh struktur* [Forecasting of electric loads in operational control of electric power systems based on neural networks]. Sykttyvkar: KNTs UrO RAN, 2008. 76 p.
6. Polyakhov, N.D., Prikhod'ko, I.A., Van, Efen. *Prognozirovaniye elektropotrebleniya na osnove metoda opornykh vektorov s ispol'zovaniem evolyutsionnykh algoritmov optimizatsii* [Forecasting power consumption by the support vector method employing evolutionary optimization algorithms]. *Sovremennyye problemy nauki i obrazovaniya*, 2013, no. 2. Available at: <http://www.science-education.ru/108-8962>
7. Bazhinov, A.N. *Metodika formirovaniya prognoznnykh znacheniy elektropotrebleniya v metallurgii s pomoshch'yu apparata neyro-nchetkikh setey* [Power consumption forecast generation by the neuro-fuzzy networks method in metallurgy]. *Materialy mezhdunarodnoy zaochnoy nauchno-prakticheskoy konferentsii «Nauka i tekhnika XXI veka»* [Proceedings of the International Distance Scientific and Practical Conference «Science and Engineering in the XXI century»]. Novosibirsk, 2011, pp. 110–115.
8. Staroverov, B.A., Mormylev, M.A. *Prognozirovaniye i upravleniye energopotreblieniye s pomoshch'yu ansamblya neyronnykh setey* [Forecast and control of power consumption by a set of neural networks]. *Trudy Mezhdunarodnoy nauchno-tekhnicheskoy konferentsii «Problemy avtomatizatsii i upravleniya v tekhnicheskikh sistemakh»* [Automation and control problems in technical media: collected works of the International scientific and technical conference]. Penza: Izdatel'stvo PGU, 2009, pp. 239–242.
9. Biryukov, E.V., Kornev, M.S. *Prakticheskaya realizatsiya nechetkoy neyronnoy seti pri kratkosrochnom prognozirovanii elektricheskoy nagruzki* [Practical implementation of fuzzy neural networks in short-term forecasting of electric load]. Available at: <http://library.mephi.ru/data/scientific-sessions/2005/nero/ch2/3-2-1.doc>
10. Makoklyuev, B.I., Ech, V.F. *Uchet vliyaniya meteorologicheskikh faktorov pri prognozirovanii elektropotrebleniya energoob'edineniy* [Accounting for the influence of meteorological factors on interconnected utility companies' power consumption forecast]. Available at: http://www.masters.donntu.edu.ua/2006/kita/chuykov/library/library/article_7.htm
11. Osovskiy, S. *Neyronnye seti dlya obrabotki informatsii* [Neural networks for data processing]. Moscow, Finansy i statistika, 2002. 344 p.

Староверов Борис Александрович,
ФГБОУВПО «Костромской государственный технологический университет»,
доктор технических наук, профессор, зав. кафедрой автоматики и микропроцессорной техники,
телефон (4942) 31-75-60,
e-mail: sba44@mail.ru

Гнатюк Борислав Алексеевич,
ФГБОУВПО «Костромской государственный технологический университет»,
аспирант кафедры автоматики и микропроцессорной техники,
телефон (4942) 31-75-60,
e-mail: gnatyukb@gmail.com