

## ПРИМЕНЕНИЕ НОВЫХ ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ В РЕШЕНИИ ЭЛЕКТРОЭНЕРГЕТИЧЕСКИХ ЗАДАЧ

*Представлены методы анализа и прогнозирования режимных параметров электрических сетей в условиях ужесточения требований к точности планирования расхода электроэнергии.*

**Ключевые слова:** прогнозирование режимных параметров, сети электрические, искусственные нейронные.

Развитие вычислительной техники и прикладной математики позволяет по-новому ставить вопросы совершенствования управления в электрических сетях и даёт возможность находить эффективные решения сложных электроэнергетических задач, возникающих на современном этапе реформирования электроэнергетики. В этой связи, в настоящее время перспективным представляется использование технологий искусственного интеллекта. Внедрение «интеллектуальных» обучающихся систем, аккумулирующих опыт персонала, и возможности цифровой обработки данных позволяют находить оптимальные решения при осуществлении электроэнергетических расчётов в условиях современных жёстких требований к их точности и надёжности.

**Основные интеллектуальные подходы, используемые в электроэнергетике.** В современной электроэнергетике можно выделить ряд практических направлений новых информационных технологий [1-6]:

1. Обработка нечёткой информации для создания нечётких систем управления.

2. Нейросетевая обработка информации при создании самообучающихся нейросетевых систем управления.

3. Методы эволюционного моделирования для настройки и поиска функций принадлежности в нечётких системах управления.

4. Многоагентные системы для создания распределительных интеллектуальных управляющих систем.

Многочисленные исследования и практические работы показывают, что из всех указанных технологий наиболее популярными и эффективными для задач электроэнергетики являются искусственные нейронные сети (ИНС) [6, 7]. Различные способы объединения нейронов между собой и организации их взаимодействия привели к созданию ИНС разных типов. Каждый тип сети, в свою очередь, тесно связан с соответствующим методом подбора весов межнейронных связей (т.е. обучения). Среди множества существующих видов ИНС в качестве важнейших для электроэнергетики можно выделить те, что представлены в табл. 1.

*Таблица 1*

*Перечень электроэнергетических задач, решаемых на базе нейросетевых моделей*

Архитектура ИНС	Виды задач
Многослойный персептрон	Прогнозирование режимных параметров и различных характеристик (величины электрической нагрузки, перетоков и потерь электроэнергии, метеоданных и т.д.)
Сеть Кохонена	Задачи классификации (состояний электрической системы, аварийных ситуаций и т.д.) Диагностирование электрооборудования Достоверизация критических измерений ЭЭС Анализ потерь электрической энергии
Рекуррентные сети (сеть Хопфилда, рекуррентный персептрон, сеть Хэминга)	Оценивание состояния ЭЭС Идентификация параметров при задаче распознавания зашумлённой информации Моделирование динамических процессов электрических машин в режиме «online»
Сеть Вольтерри	Идентификации нелинейных объектов (электродвигателей, генераторов и т.д.) Прогнозирование переменных во времени нестационарных сигналов Устранение интерференционных шумов в исходной информации

**Анализ параметров режима и технологических характеристик в электрических сетях.** Актуальность получения «прозрачной картины» по обслуживаемым электрическим сетям энергосбытовых организаций и электросетевых предприятий продиктована новыми условиями, сложившимися на современном рынке электроэнергии. Каждый отдельный субъект такого рынка пред-

ставляет собой обособленный элемент общей системы покупки и реализации ЭЭ, который для своего успешного финансового функционирования должен проводить, чаще всего самостоятельно, анализ основных параметров режима и технологических характеристик. Важно отметить, что для получения эффективной оценки и проведения качественного анализа на уровне

\* - автор, с которым следует вести переписку

энергосбытовой компании необходимо учитывать большое количество технических и экономических переменных в рамках обслуживаемых ею электрических сетей и энергорайона в целом.

Сложная система взаимоотношений между участниками электроэнергетического рынка требует от электросетевых и энергосбытовых организаций применения эффективных методов оценки и анализа, а также выработки корректных решений.

Таким образом, отмеченные обстоятельства требуют применения новых математических методов, позволяющих найти эффективные решения в условиях многокритериальности входной информации, с одной стороны, и дефицита исходных данных – с другой.

Как показывают проведенные авторами многочисленные исследования [9–13], перспективным в этом отношении является применение самоорганизующихся ИНС, позволяющих на нейросетевой основе (карты SOM<sup>1</sup>) выполнять

<sup>1</sup> На карте SOM на каждом узле сетки изображается ограниченная область (к примеру, квадрат), размер которого пропор-

кластерный анализ исследуемых параметров. Методы кластерного анализа [14] на сегодняшний день достаточно широко используются в ряде важных электроэнергетических задач, и в первую очередь при идентификации состояний электрической системы, в том числе аварийных ситуаций; диагностировании электрооборудования, достоверизации критических измерений ЭЭС и т.д.

Применительно к моделированию электрических сетей структуры SOM чаще всего используются для выявления особенностей и различий в режимах поведения энергосистемы и для выделения ненормальных режимов работы. Неоднозначности в «раскраске» карты (рис. 1) могут отвечать различным режимам поведения энергообъекта или электрической сети в целом, что при последующем моделировании может служить своеобразным индикатором на нежелательные (или аварийные) соотношения параметров при текущей эксплуатации системы.

ционален числу точек данных, ближайших к данному узлу, а оттенок отражает значение соответствующего признака.

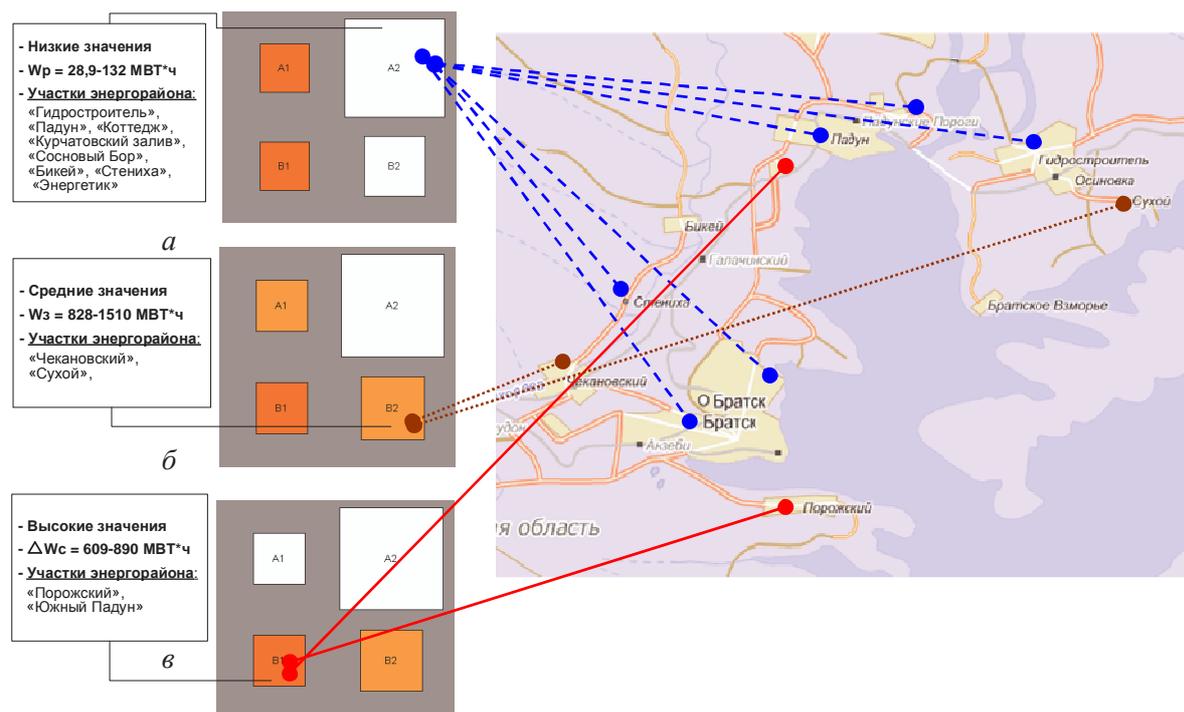


Рис. 1. Анализ потребления ЭЭ бытовым сектором в исследуемом энергорайоне г. Братска:  
а – фактическая реализация ЭЭ; б – закуп ЭЭ; в – сверхнормативные потери ЭЭ

Так, в задаче анализа потребления ЭЭ в энергорайоне имеется значительный набор различных технологических характеристик ЭЭ, а именно: закуп ЭЭ, расход ЭЭ субабонентами, плановая реализация ЭЭ, фактическая реализация ЭЭ, значения сверхнормативных потерь ЭЭ (под сверхнормативными (коммерческими) потерями ЭЭ понимаются потери, обусловленные несоответствием показаний

счётчиков ЭЭ у бытовых потребителей, хищениями ЭЭ и другими причинами в сфере организации контроля за потреблением ЭЭ) и т.д. В новых рыночных условиях актуальна задача анализа общей картины потребления ЭЭ с учётом всех ее входных технологических характеристик, а также оценка каждой подобной характеристики в отдельности для выработки мероприятий, связанных с планиро-

ванием расхода электроэнергии и снижения возникающих ее потерь.

Использование структуры SOM для решения этой задачи позволило, с учётом указанных требований, успешно выделить особенности потребления ЭЭ за исследуемый период с помощью наглядной картины визуализации (способ представления многомерного распределения данных на двумерную плоскость) в виде карт Кохона (рис. 1).

Необходимо отметить, что в ряде задач целесообразно совмещать методы новых информационных технологий с традиционными видами статистического анализа. Так, авторами разработана методика анализа данных [9; 13; 15], в основе которой лежит совместное использование кластерного анализа SOM и факторного анализа (метод главных компонент (Principal Component Analysis (PCA) – принцип главных компонент) [14; 16]. Здесь анализ PCA используется как дополнительное средство анализа и визуализации данных и позволяет определить наличие корреляционной связи между различными анализируемыми параметрами. Использование PCA поможет сокращению количества факторов в исследуемом массиве исследуемых параметров или характеристик, необходимому для эффективного представления данных, при этом оставляют лишь те линейные комбинации, дисперсии которых велики.

На основании этой методики разработан эффективный подход к анализу потерь ЭЭ.

Важно отметить: сегодня стало совершенно очевидно, что при решении этой задачи для субъектов электроэнергетического рынка особенно важно корректно выявлять «очаги» потерь ЭЭ и причину их возникновения, поскольку подобные очаги в значительной степени предопределяют финансовые убытки энергосбытовой организации.

Такой подход предполагает совместное использование нейросетевой кластеризации SOM и факторного анализа PCA для выявления основных факторов, приводящих к высоким потерям ЭЭ и кластеризации участков электрической сети энергорайона на компактные группы с близкими характеристиками свойствами

Применение факторного анализа PCA в задаче анализа потерь ЭЭ в Братском энергорайоне позволило определить основные факторы в исследуемом массиве изменения потерь ЭЭ, в том числе и наличие СПЭ [17] (рис. 2). Проведённый кластерный анализ (табл. 2) дал возможность разделить весь энергорайон на компактные группы, обособив при этом очаги потерь ЭЭ, и корректно идентифицировать факторы, выделенные PCA:

– фактор 1 – потери ЭЭ в с.у. Южный Падун-1 (кластер В1);

– фактор 2 – потери ЭЭ в с.у. Сухой (кластер В2).

Как видно из рис. 2, выделенные факторы характеризуют распределение высоких потерь («очаги» потерь) по месяцам года. Так, в сетевом участке Сухой высокие потери ЭЭ приходится

на летние месяцы, в сетевом участке Южный Падун-1 – на все месяцы, кроме летних.

**Системное прогнозирование в электроэнергетике.** Анализ последних документов и нормативных актов в области электроэнергетики дает возможность сделать вывод, что одним из основных действий, позволяющих минимизировать издержки, вызванные новыми правилами рынка, а следовательно, снизить финансовые убытки ЭСО, является эффективное прогнозирование параметров режима и различных технологических характеристик предприятия, тесно связанных с потреблением ЭЭ. Таким образом, новые реалии «требуют» от ЭСО получения максимально низких ошибок при прогнозировании её параметров в обслуживаемых электрических сетях.

Таблица 2

Кластерный анализ SOM сетевых участков энергорайона г. Братска

Кластер	Сетевые участки, входящие в кластер	Месяцы наибольших потерь ЭЭ
A1	Лесохимик, Надежда, Сосновый Бор, Южный Падун-2	–
A2	Бикей, Северный Артек, Стениха	–
B1	Южный Падун-1	Все месяцы, кроме июня и июля
B2	Сухой	Летние месяцы

Более того, при сложившейся новой рыночной ситуации в отечественной электроэнергетике становится актуально осуществлять *системное прогнозирование* [18–20]. Концепция такого прогнозирования заключается в том, что ЭСО, спрогнозировав развитие ситуации (к примеру, уровень потерь ЭЭ в обслуживаемом энергорайоне), стремится скорректировать свои действия, чтобы своевременно среагировать на изменение внешней среды, уменьшить ущерб или, напротив, увеличить возможную прибыль.

Авторами разработан «интеллектуальный» подход к прогнозированию с использованием нейросетевых технологий [13; 15; 20; 21], позволяющий эффективно решать прогнозные задачи в условиях жёстких требований точности таких расчётов и значительной «зашумлённости» изучаемых реализаций параметров, характерной для российских электрических сетей. Такой подход состоит из следующих этапов:

1. Выбор обучающих данных.

2. Использование алгоритмов нелинейной оптимизации, в первую очередь методов имитации отжига (SA) [6] и нейро-генетического отбора (NGIS) [2], позволяющих исследовать массив исходных данных и на основании этого организовать «соревновательную» процедуру выбора наилучшей прогнозной модели для каждой отдельной выборки.

3. Прогнозирование параметров режима и технологических характеристик ЭСО на заданный интервал упреждения на базе полученной нейросетевой модели.

4. Возможная адаптация ИНС при изменении схемно-режимных параметров электрической сети.

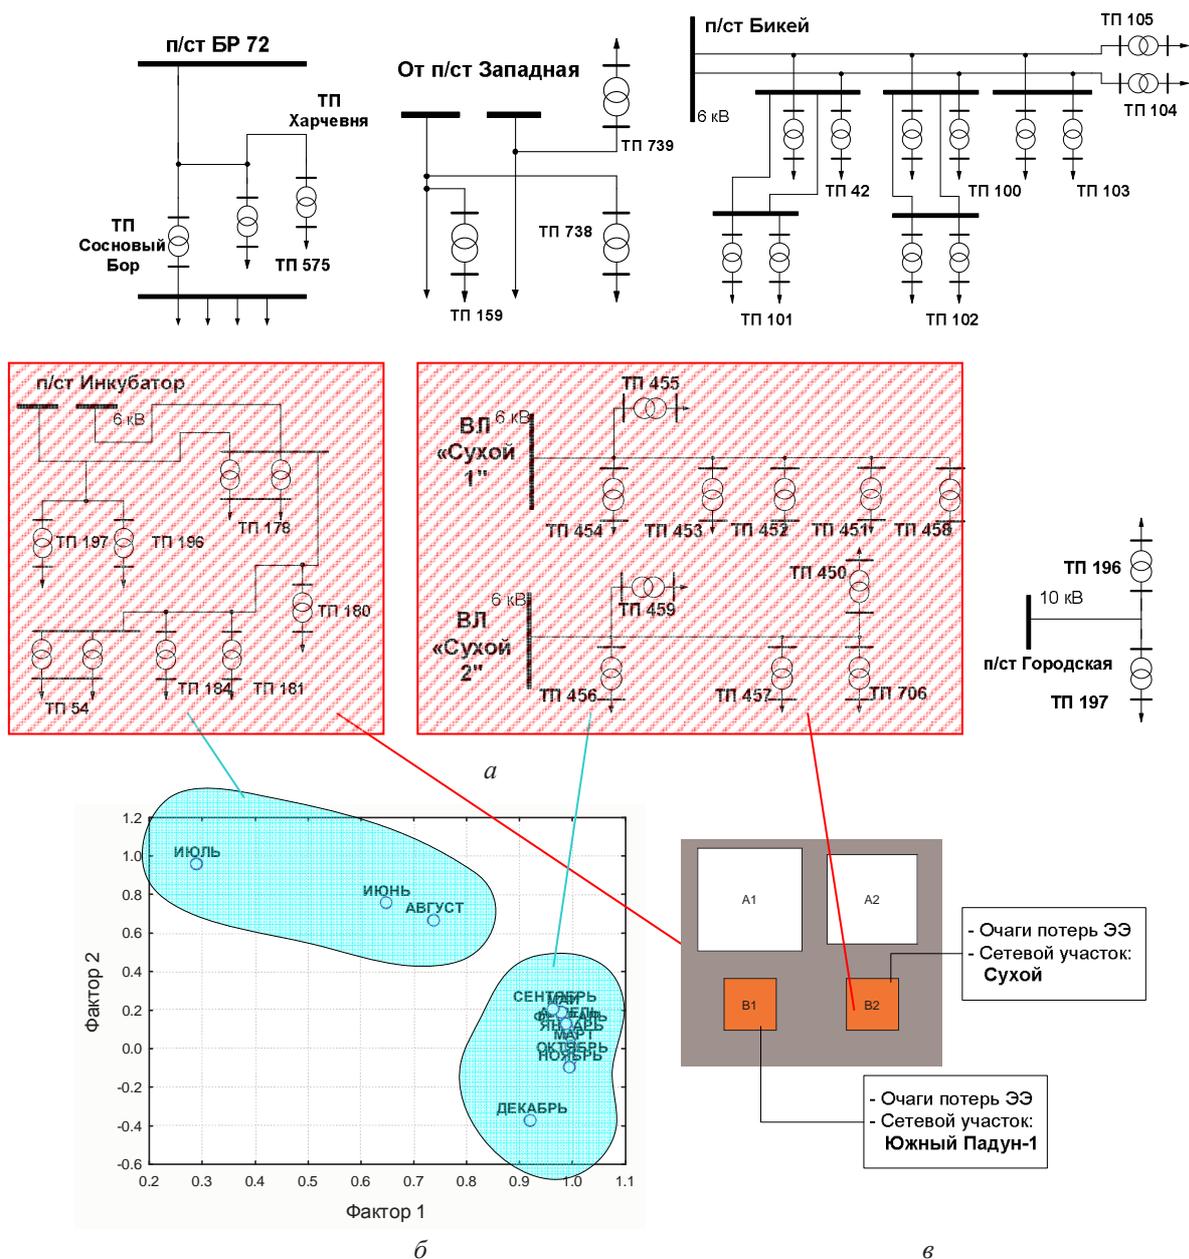


Рис. 2. Анализ потерь электроэнергии в распределительных электрических сетях г. Братска: а – сетевые участки энергорайона г. Братска; б – факторный анализ РСА; в – кластеризация потерь ЭЭ

Кроме того, проведённые практические исследования показывают, что в современных условиях эффективнее осуществлять прогнозирование в рамках принципа «декомпозиции», согласно которому сложные вычислительные задачи решаются при помощи их разбиения на множество более простых задач с последующим объединением полученных решений. При обучении полученной прогнозной модели вычислительная простота достигается за счёт распределения задачи среди множества экспертов. Комбинации таких экспертов формируют ассоциативную машину (СА) [22].

Эффективность разработанного подхода подтверждена многочисленными экспериментальными

расчётами по прогнозированию различных параметров режима и технологических характеристик (электрической нагрузки, СПЭ, температуры наружного воздуха и т.д.) в электрических сетях ОЭС Сибири [20; 23; 24].

В частности, в задаче прогнозирования СПЭ в электрических сетях Братского энергорайона, реализация процесса содержала значительную нерегулярную составляющую и имела сильную «зашумлённость» (рис. 3), что приводило к большим ошибкам прогноза в рамках традиционных моделей.

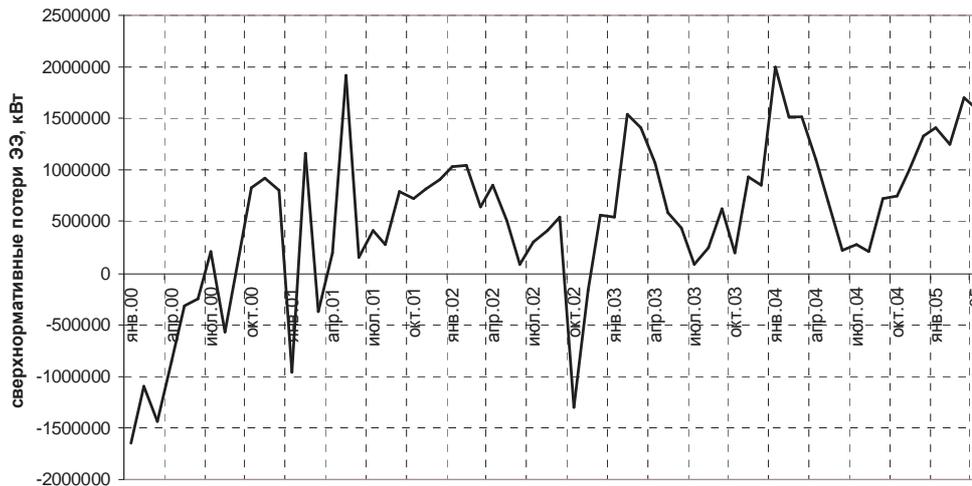


Рис. 3. График изменения СПЭ в электрических сетях сетевого участка Порожский

Для проведения сравнительного анализа в решении этой задачи были использованы несколько прогнозных моделей:

1. АРПСС (класс параметрических прогнозных моделей, описывающих в том числе и нестационарные ряды) (2,0,0) (2,2,0) [18; 19] – в качестве входных значений использовались данные за прошлые годы только по СПЭ, ввиду ограничения регрессионных моделей на количество входных параметров.

2. ИНС типа MLP (многослойный перцептрон, обученный по методу *обратного распространения ошибки*, MLP обладает оригинальными свойствами воспроизводить достаточно сложные зависимости, которые сопутствуют плохо формализуемым задачам) (5-5-1) – для обучения использовались следующие входные параметры: закуп ЭЭ, технологические потери ЭЭ,

плановая реализация ЭЭ, фактическая реализация ЭЭ и номер месяца. Выходным значением ИНС являлись СПЭ.

3. Структура СА – состояла из 3 нейросетей-экспертов типа MLP различной архитектуры. Набор входных и выходных значений такой же, как и в предыдущем пункте.

Как видно из табл. 3, модель АРПСС имеет очень высокую ошибку прогноза. В то же время прогноз с помощью структуры СА практически в 2 раза точнее прогноза «одиночной» ИНС.

Кроме того, результат прогноза, в рамках предложенного подхода, может быть уточнен на основании заранее проведенного анализа прогнозируемых данных по методу SOM и PCA.

Таблица 3

Прогноз сверхнормативных потерь ЭЭ в сетевом участке Порожский различными прогнозными моделями

Прогнозная модель	Относительная ошибка за месяцы, %												Средняя ошибка, %
	1	2	3	4	5	6	7	8	9	10	11	12	
АРПСС	43,9	43,5	49,1	42,9	45,8	35,9	35,6	43,8	40,1	44,1	40,1	49,3	<b>42,8</b>
ИНС	2,3	0,4	2,5	4,9	8,3	8,3	30,0	12,5	1,2	0,5	1,4	1,3	<b>6,1</b>
СА	1,0	1,5	2,8	3,9	4,3	4,6	16,5	8,1	0,6	0,3	0,2	1,2	<b>3,7</b>

К примеру, для сетевого участка Сухой факторным анализом PCA было выявлено, что высокие значения потерь для этого района наблюдаются в летние месяцы. Это обстоятельство отражается на точности прогноза СПЭ в летние месяцы (табл. 3) для моделей ИНС и СА, особенно в июле (ИНС – 30,0 %, СА – 16,5 %), который имеет наибольшее отклонение на графике PCA. Исходя из этого для повышения точности прогноза СА в обучающую выборку был введен допол-

нительный входной параметр, а именно значения коэффициента корреляции фактора 1 (с.у. Сухой), полученные при анализе потерь ЭЭ (табл. 4).

Результаты прогнозирования СПЭ с учетом коррекции PCA и SOM приведены в табл. 5. Как явствует из таблицы, прогноз с учетом выполненного ранее анализа дал более точные результаты: в частности, наблюдается значительное снижение погрешности прогнозирования для «проблемных» в этом районе летних месяцев (табл. 5).

Таблица 4

Значения коэффициента корреляции фактора 1 в различные месяцы для с.у. Сухой

Месяцы											
1	2	3	4	5	6	7	8	9	10	11	12
0,996	0,991	0,999	0,989	0,980	0,648	0,289	0,738	0,964	0,997	0,995	0,920

Прогноз сверхнормативных потерь ЭЭ в сетевом участке «Сухой» моделями «обычной» СА и СА с коррекцией PCA и SOM

Прогнозная модель	Относительная ошибка за месяцы, %												Средняя ошибка, %
	1	2	3	4	5	6	7	8	9	10	11	12	
СА	1,0	1,5	2,8	3,9	4,3	<b>4,6</b>	<b>16,5</b>	<b>8,1</b>	0,6	0,3	0,2	1,2	<b>3,7</b>
СА с коррекцией PCA и SOM	0,5	0,01	0,4	1,7	2,5	<b>2,3</b>	<b>2,4</b>	<b>0,1</b>	0,6	0,4	0,5	2,9	<b>1,2</b>

**Принцип построения «интеллектуальных» ПВК для решения электроэнергетических задач.** Развитие и усложнение систем электроэнергетики, и в первую очередь на низшем уровне иерархии, приводят к необходимости применения мощного аппарата анализа данных с использованием сложных математических методов и подходов. К сожалению существующие специализированные программно-вычислительные комплексы (ПВК), ориентированные на решение задач электроэнергетики, используют, как правило, достаточно ограниченное количество математических методик и подходов, что не позволяет в должной степени учесть особенности и специфику систем электроэнергетики.

Несмотря на ряд существенных достоинств специализированных российских ПВК, к примеру «РАП-95» и «ПРОГНОЗ» [4; 17], использующих как традиционные подходы, так и новые информационные технологии, принцип их действия при обработке информации не в должной мере отражает современные экономические требования

и реалии. Как правило, такие ПВК носят узкий, специализированный характер.

Определённым выходом из такой ситуации является создание специализированного ПВК на базе макросов (самостоятельных программных блоков последовательности команд и функций, реализуемых, как правило, на языке Visual Basic) пользовательских приложений. При таком подходе в качестве основных вычислительных модулей используются готовые процедуры и блоки уже созданной интегрированной программной системы (ИПС) (рис. 4). Другими словами, за основу берётся ИПС, которая написана специалистами в области статистического анализа и обработки данных, где реализуется большой спектр современных математических методов, и для которой формируется определённая макрос-программа с соответствующим интерфейсом, ориентированная под конкретный круг электроэнергетических задач. В дальнейшем подобная макрос-программа в соответствии с заложенным набором команд и функций обращается к тому или иному вычислительному блоку ИПС.



Рис. 4. Общая структура специализированного ПВК в рамках концепции макрос-приложений

Авторами разработан специализированный ПВК «АНАПРО» (рис. 1) [25], где в качестве ИПС используется программный комплекс Statistica Neural Networks, представляющий современную интегрированную систему статистического анализа и обработки данных в среде Windows. Эффективность предложенного подхода связана как с возможностью работать со многими моделями, так и со способностью выбирать оптимальную модель, соответствующую качественному решению определённой электроэнергетической задачи. В качестве основного языка макрос-программы

применяется объектно-ориентированный язык программирования Visual Basic.

## Заключение

1. Сложная система взаимоотношений на современном электроэнергетическом рынке, необходимость получения «прозрачной картины» по обслуживаемым электрическим сетям, ужесточение требований к точности планирования расхода электроэнергии обусловили применение в энергосбытовых организациях эффективных ме-

тодов анализа и прогнозирования параметров режима и технологических характеристик.

2. Проведённые многочисленные исследования и практические разработки показывают, что наиболее эффективно электроэнергетические задачи в новых условиях рынка можно решить путем применения новых информационных технологий, в первую очередь искусственных нейронных сетей.

3. Показано, что применение кластерного анализа на базе ИНС Кохонена (в частности, совместно с факторным анализом PCA) позволяет выделить ряд особенностей и различий в режимах поведения энергосистемы, а также ненормальные режимы работы.

4. Применение «интеллектуального» подхода при системном прогнозировании параметров режима и технологических характеристик дает возможность получить более точные и устойчивые прогнозы по сравнению с одиночными структурами ИНС и традиционными регрессионными моделями.

5. Предложен ПВК на базе макросприложений, позволяющий из имеющихся математических «программно-готовых» моделей выбирать наиболее оптимальную для решения конкретной электроэнергетической задачи.

#### Литература

1. Манов, Н.А. Новые информационные технологии в задачах оперативного управления электроэнергетическими системами / Н.А. Манов, Ю.Я. Чукреев, М.И. Успенский [и др.]. – Екатеринбург: УрО РАН, 2002. – 205 с.
2. Оссовский, С. Нейронные сети для обработки информации / С. Оссовский; пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2004. – 344 с.
3. Бирюков, Е.В. Прогнозирование электрической нагрузки в энергосистемах на основе нечётких нейронных сетей / Е.В. Бирюков, В.З. Манусов // Вестник УГТУ–УПИ. – Энергосистема: управление, качество, конкуренция. – Екатеринбург: Изд-во УГТУ–УПИ, 2004. – № 12 (42). – С. 187–190.
4. Демура, А.В. Прогнозирование электропотребления в энергосистеме с учётом температуры воздуха и освещённости / А.В. Демура [и др.] // Электрика. – 2005. – № 3. – С. 18–21.
5. Воропай, Н.И. Развитие методов адаптации нечётких АРВ для повышения динамической устойчивости сложных электроэнергетических систем / Н.И. Воропай, П.В. Этингов // Электричество. – № 11. – 2003. – С. 2–10.
6. Haykin S. Neural networks. A comprehensive foundation. Second edition / S. Haykin. – Williams Publishing House, 2006. – 1104 p.
7. Горбань, А.Н. Нейроинформатика / А.Н. Горбань [и др.]. – Новосибирск: Наука. Сибирское предприятие РАН, 1998. – 296 с.
8. Kohonen T. Exploration of very large databases by self-organization maps / T. Kohonen. – 1997 International Conference on Neural Networks, 1997, vol. I, p. PL1-PL6, Houston.
9. Курбацкий, В.Г. Анализ потерь электрической энергии на базе современных алгоритмов искусственного интеллекта / В.Г. Курбацкий, Н.В. Томин // Электричество. – № 4. – 2007. – С. 5–12.
10. Курбацкий, В.Г. Управление в электроэнергетике с использованием методов искусственного интеллекта / В.Г. Курбацкий, Н.В. Томин // Электрика. – 2005. – № 9. – С. 20–28.
11. Курбацкий, В.Г. Практика использования новых информационных технологий для прогнозирования и анализа отдельных характеристик сетевых энергопредприятий / В.Г. Курбацкий, Н.В. Томин // Проблемы энергетики. – 2007. – № 3–4. – С. 84–91.
12. Томин, Н.В. Анализ и прогнозирование режимных параметров и характеристик на базе методов искусственного интеллекта / Н.В. Томин. – Системные исследования в энергетике. – Иркутск: ИСЭМ СО РАН, 2006. – 294 с.
13. Kurbatsky V.G. Application of methods of the artificial intellect at formation of tariffs on electric and thermal energy / V.G. Kurbatsky, N.V. Tomin // Asian Energy Cooperation: Mechanisms, Risks, Barriers // Proceedings of the International Conference. – Irkutsk: Energy Systems Institute, 2007. – 220 p.
14. Зиновьев, А.Ю. Визуализация многомерных данных / А.Ю. Зиновьев. – Красноярск: ИПЦ КГТУ, 2000. – 168 с.
15. Kurbatsky V.G. Methods of artificial intelligence in electric power systems / V.G. Kurbatsky, N.V. Tomin // Liberalization and Modernization of Power Systems: Risk Assessment and Optimization for Asset Management. The 3<sup>rd</sup> International Workshop Proceedings. Edited by N.I. Voropai and E.J. Handschin. – Irkutsk: Energy Systems Institute, 2006. – 223 p.
16. Diamantaras K. Principal component neural networks, theory and applications / K. Diamantaras S., Kung . – N. Y.: Wiley, 1996.
17. Артемьев, А.В. Расчёт, анализ и нормирование потерь электроэнергии в электрических сетях: руководство для практических расчётов / А.В. Артемьев, Ю.С. Железко, О.В. Савченко. – М.: Изд-во НЦ ЭНАС, 2003. – 280 с.
18. Боровиков, В.П. Прогнозирование в системе STATISTICA в среде Windows: основы теории и интенсивная практика на компьютере: учеб. пособие / В.П. Боровиков, Г.И. Ивченко. – 2-е изд., перераб. и доп. – М.: Финансы и статистика, 2006. – 368 с.
19. Bunn D.W., Farmer E.D. Comparative models for electrical load forecasting / D.W. Bunn, E.D. Farmer, John Wiley & Sons, 1985. – 200 p.
20. Курбацкий, В.Г. Прогнозирование электрической нагрузки с использованием искусственных нейронных сетей / В.Г. Курбацкий, Н.В. Томин // Электрика. – 2006. – № 7. – С. 26–32.
21. Курбацкий, В.Г. Управление в электроэнергетике с использованием методов искусственного интеллекта / В.Г. Курбацкий, Н.В. Томин // Электрика. – 2005. – № 9. – С. 20–28.
22. Nilsson N.J. Learning Machines: Foundations of Trainable Pattern-Classifying Systems / N.J. Nilsson. – New York: McGraw-Hill, 1965.
23. Курбацкий, В.Г. Применение нейросетевых моделей в задаче формирования тарифов на тепловую и электрическую энергию: сборник трудов IV Всероссийской научно-технической конференции с международным участием. В 2 т. / В.Г. Курбацкий, Н.В. Томин, В.Б. Шуманский. – Благовещенск: АмГУ, 2005. – С. 32–38.
24. Курбацкий, В.Г. Прогнозирование характеристик потерь энергии при формировании тарифов на основе нейросетевых моделей / В.Г. Курбацкий, Н.В. Томин // Энергетик. – 2007. – № 3. – С. 5–12.
25. Курбацкий, В.Г. Разработка «интеллектуального» комплекса анализа и прогнозирования режимных переменных и характеристик в системах электроэнергетики / В.Г. Курбацкий, Н.В. Томин. – Нейроинформатика, её приложения и анализ данных: материалы XV Всероссийского семинара, ИВМ СО РАН. – Красноярск, 2007. – С. 73–75.