

# Методы прогнозирования электропотребления в распределительных сетях (обзор)

Абдурахманов А.М., Володин М.В., Зыбин Е.Ю.

ОАО «Научно-технический центр ФСК ЕЭС»

г. Москва, Российская Федерация

[abdurahmanov@ntc-power.ru](mailto:abdurahmanov@ntc-power.ru)

Рябченко В.Н.

Московский государственный технический университет имени Н.Э. Баумана

г. Москва, Российская Федерация

[Ryabchenko.vn@gmail.com](mailto:Ryabchenko.vn@gmail.com)

**Аннотация.** Дается обзор применяемых на практике методов прогнозирования электропотребления в распределительных сетях. Все многообразие методов прогнозирования электропотребления подразделяются на классические и интеллектуальные. К классическим методам прогнозирования отнесены регрессионные, авторегрессионные и вероятностные методы. Интеллектуальные методы прогнозирования объединяют экспертные системы, искусственные нейронные сети, клеточные автоматы, хаотические процессы и другие. Анализируется область применимости, достоинства и недостатки методов прогнозирования электропотребления.

**Ключевые слова:** распределительные электрические сети, электропотребление, методы прогнозирования, регрессионные методы, вероятностные методы, интеллектуальные методы.

## ВВЕДЕНИЕ

Оперативное планирование и эффективное управление режимом функционирования электроэнергетической системы (ЭЭС) невозможны без достоверного прогноза нагрузки в узлах расчетной схемы, проводимого с учетом от нескольких минут до нескольких суток. Прогноз узловых нагрузок необходим для оптимизации предстоящих и коррекции текущих режимов, рассмотрения оперативных диспетчерских заявок, связанных с выводом электроэнергетического оборудования в ремонт, для испытаний и т.п. Особенно большое значение данная проблема приобретает в связи с переходом к конкурентному рынку электроэнергии. Под нагрузками узлов понимается потребление активной и реактивной мощности в схеме замещения электрической сети. Величина нагрузки в узле для каждого момента времени определяется нагрузками множества приемников электрической сети, подключенных к этому узлу ЭЭС, и потерями мощности при передаче электроэнергии к данному узлу [1].

Необходимость в качественном прогнозировании обусловлена технологическими и экономическими причинами [2].

Технологические причины связаны с ключевой ролью прогнозирования в процессах планирования балансов электроэнергии и мощности энергосистемы, определении режимных параметров и технико-экономических показателей электропотребляющих объектов и расчетов электрических нагрузок в энергоузлах и сечениях. Прогнозирование будущих показателей электропотребления позволяет достичь важнейшего принципа формирования надежной и эффективной работы Единой энергетической системы – обеспечения четкого системного баланса производства и потребления электрической энергии при условии одновременной мгновенности этих процессов.

Баланс производства и потребления электроэнергии – основа технологической устойчивости работы энергосистемы, он определяет системную надежность и бесперебойность ее функционирования. В случае нарушений условия баланса ухудшается качество электроэнергии (изменение параметров частоты и напряжения сети), что снижает эффективность работы электропотребляющего оборудования конечных потребителей.

Экономических причин, обуславливающих необходимость качественного прогнозирования, существует достаточно много. Точные расчеты обеспечивают оптимальное распределение нагрузки между электростанциями энергосистемы и повышают качество электроэнергии. Прогнозирование и планирование показателей потребления электроэнергии для крупных потребителей позволяет управлять стоимостью покупки электроэнергии через регулирование загрузки оборудования посредством управления производственными процессами, перевода основных объемов потребления электроэнергии в часы с наименьшей стоимостью, тем самым снижая себестоимость производства и величину платежей энергоснабжающим организациям. Особую актуальность задача прогнозирования приобрела после возникновения в России оптового рынка электроэнергии, правила которого предусматривают необходимость точного прогнозирования объемов электроэнергии с целью осуществления ее покупки на оптовом рынке [3].

Согласно данным правилам участники рынка должны осуществлять прогноз своего планового почасового потребления и в сутки, предшествующие операционным, подавать администратору торговой системы почасовую заявку электропотребления относительно каждого часа операционных суток. Значит, все субъекты рынка должны выполнять прогнозы электропотребления также с почасовой дискретностью на несколько суток вперед.

Некачественная подача предприятием-участником заявок на электроэнергию может привести к значительным экономическим потерям. Ошибки снижают качество управления электроснабжением и ухудшают экономичность ее сложных режимов. За отклонения фактических почасовых показателей от прогнозных на участников накладываются штрафные санкции, увеличивающие стоимость покупной электроэнергии. Это связано с особенностью электроэнергии как товара. Занижение прогноза приводит к необходимости использования аварийных дорогостоящих электростанций. Завышение прогноза приводит к увеличению издержек на поддержание в рабочем состоянии излишних резервных мощностей.

У потребителя, приобретающего электроэнергию на оптовом и (или) розничном рынке, появляется задача со-

ставления достоверной заявки на потребление электроэнергии на некоторый срок вперед. Это связано с тем, что излишнее или недостаточное потребление электроэнергии, заказывающейся по предварительным заявкам предприятия-потребителя, приводит к незапланированным издержкам поставщика в точке генерации. Поэтому увеличение точности прогноза даже на десятые доли процента может привести существенному снижению затрат на оплату отклонений от плана по поставкам электроэнергии [4].

Получается, что задача прогнозирования имеет высокую актуальность для большого количества субъектов, функционирующих в условиях оптового рынка электроэнергии: для гарантирующих поставщиков, обслуживающих потребителей целых регионов, независимых энерго-сбытовых организаций, обслуживающих отдельные промышленные предприятия в различных регионах России, и для крупных хозяйствующих субъектов, покупающих электроэнергию на оптовом рынке для нужд собственного потребления. Поэтому качественное прогнозирование величин электропотребления для субъектов российского оптового рынка является экономически целесообразным и в современных высококонкурентных условиях получает нарастающую актуальность.

Процесс прогнозирования электропотребления затрагивает абсолютно всех участников обращения электрической энергии страны. Качество прогноза напрямую влияет на величину конечных энерготарифов, что в условиях постоянного роста электропотребления и нисходящей динамики повышения тарифов является очень важным. От качества прогнозирования на уровне предприятий зависит величина себестоимости их продукции, а следовательно, и показатели эффективности их работы. Эффективность работы предприятий напрямую влияет на макроэкономические показатели функционирования регионов, ВРП и электроемкость ВРП, которые в свою очередь повышают показатели ВВП, электроемкости ВВП и прочих связанных индикаторов на уровне страны в целом. Таким образом, прогнозирование электропотребления является эффективным инструментом оптимизации затрат на электроэнергию в масштабах как отдельных предприятий и регионов, так и страны в целом. По получаемому эффекту прогнозирование выступает как способ повышения энергетической эффективности национальной экономики.

В процессе своей деятельности субъекты оптового рынка одновременно функционируют в двух влияющих на них средах: технологической и рыночной [2, 5-7].

Технологическая среда субъекта оптового рынка – экономическое пространство, действующее на субъекта со стороны факторов, влияющих на графики электропотребления, производственной программы потребителей, особенностей технологических процессов электропотребляющих объектов. По типу возникновения все факторы технологической среды делятся на метеорологические и социально-экономические (табл. 1) [6].

Метеорологические факторы отражают зависимость графиков электропотребления от погодных явлений, выражающихся в изменении долготы светового дня, времени захода и восхода солнца, температуры воздуха, а также возникновении атмосферных явлений и осадков.

Социально-экономические факторы отражают зависимость графика электрических нагрузок от показателей, вызванных социально-экономическими укладами жизне-

деятельности и экономической активности, например, от типов дней (рабочие, выходные и праздничные), продолжительности рабочих смен, производственных программ предприятий, особенностей графиков электропотребления отдельных объектов, экономической активности хозяйствующих субъектов. Указанные факторы условно можно разделить на три группы: циклические, естественные и случайные. Эта классификация происходит от характера возникновения факторов и отражает их доступность для включения в прогнозную модель [8].

Таблица 1

Факторы влияющие на график нагрузки электропотребления

Факторы	Социально-экономические	Метеорологические
Циклические	1) Время (час суток) 2) День недели 3) Тип дня недели (рабочий, выходной, праздничный, предпраздничный)	1) Температура воздуха 2) Продолжительность светового дня 3) Время восхода и захода солнца.
Естественные	1) Индивидуальная производственная программа работы крупных промышленных объектов, 2) Продолжительность отопительного периода; 3) Использование альтернативных источников электроснабжения, 4) Ввод в эксплуатацию крупных энергоемких объектов.	1) Атмосферное давление, 2) Относительная влажность воздуха, 3) Направление ветра. 4) Скорость ветра; 5) Облачность; 6) Осадки; 7) Горизонтальная дальность видимости.
Случайные	1) Аварии на крупных промышленных объектах	1) Резкие кардинальные изменения погодных условий (наиболее влияющие: температура воздуха и осадки)

Рыночная среда субъекта оптового рынка – экономическое пространство, действующее на внутренние процессы субъекта со стороны оптового рынка электроэнергии.

К рыночным факторам, влияющим на график нагрузки электропотребления, как правило, относят:

- цены и объемы спроса и предложения;
- цены и объемы балансирующего рынка;
- рыночная конъюнктура;
- предложение и спрос рынка;
- конкурентное положение субъекта рынка;
- стратегия функционирования смежных субъектов рынка.

С точки зрения сроков, прогнозирование нагрузки подразделяется на четыре категории [9]:

- долгосрочное прогнозирование с заблаговременностью более одного года;
- среднесрочное прогнозирование с заблаговременностью от одного месяца до одного года;
- краткосрочное прогнозирование нагрузки с заблаговременностью от одних суток до нескольких недель;
- оперативное прогнозирование – от одного до трех часов и до конца текущих суток.

Формирование прогноза на основании прогнозной модели, представленной на рис. 1, производится в три основных этапа [6].

На первом этапе производится учет метеорологических факторов, влияющих на прогнозный график электропотребления. Наиболее значимыми из этих факторов являются температура воздуха, продолжительность светового дня и осадки.




Рис. 1. Графическое изображение факторов и сред, из которых должна состоять модель прогнозирования нагрузок

Вторым этапом построения прогноза является учет в прогнозном графике электропотребления социально-экономических факторов. Наиболее значимыми социально-экономическими факторами являются вводы в работу и выходы крупных энергопотребляющих объектов, индивидуальные производственные программы предприятий.

Третьим этапом формирования прогноза является учет факторов рыночной среды. Он производится на базе прогнозного графика, в котором уже учтены метеорологические и социально-экономические факторы.

### 1. КЛАССИЧЕСКИЕ МЕТОДЫ ПРОГНОЗИРОВАНИЯ НАГРУЗКИ

Прогнозирование нагрузок достаточно сложная задача. Во-первых, потому, что ряды электрических нагрузок сложны и проявляются несколько уровней сезонности. Во-вторых, существует много важных экзогенных переменных, которые должны быть учтены при прогнозировании, особенно переменные, связанные с погодой.

Прогнозирование электропотребления осуществляется посредством различных методов, основанных на анализе ретроспективной динамики электропотребления и действующих на него факторов, выявлении статистической связи между признаками и на построении прогнозных моделей с использованием различных методов и программных средств.

Первые публикации по методам прогнозирования электрической нагрузки ЭЭС появились на рубеже десятих-двадцатых годов прошлого века [10]. До настоящего времени разработано большое число методов и моделей прогнозирования нагрузки ЭЭС. Все они могут быть классифицированы как модели временных рядов, в которых нагрузка моделируется как функция ее наблюдаемых в прошлом значений, и причинные модели, в которых нагрузка моделируется как функция некоторых экзогенных факторов, особенно погодных и социальных. Некоторые из первых моделей являются мультипликативными авторегрессионными, динамическими линейными или нелинейными моделями, пороговыми авторегрессионными, построенными на фильтрах Калмана. Вторые, как правило, являются передаточными функциями Бокса и Дженкинса, оптимизационными моделями, моделями непараметрической регрессии и др. [11].

Несмотря на такое большое количество альтернатив, среди классических методов наибольшее распространение получили линейные регрессионные модели и модели, разлагающие нагрузку на базовую или регулярную и зависящую от погоды составляющие. Эти модели привлекательны тем, что они позволяют более точно прогнозировать нагрузку в периоды перехода от рабочих дней к выходным и наоборот, в нерегулярные (праздничные и примыкающие к ним) дни и ориентированы на существующий в

ЭЭС и ОЭС объем ретроспективной информации. Однако они являются, в основном, линейными моделями, а ряды нагрузки, которые они моделируют – нелинейные функции экзогенных переменных.

Существующие подходы к прогнозированию нагрузок в узлах определяются в первую очередь, уровнем информационной обеспеченности задачи, а именно – достаточностью и достоверностью телеметрических измерений режимных параметров. В практике зарубежных ЭЭС, где имеется достаточная ретроспективная информация о нагрузках в узлах, для их прогнозирования часто применяются те же алгоритмы, что и для прогнозирования суммарных нагрузок ЭЭС. Получаемая точность прогнозирования оказывается сопоставимой с точностью измерения нагрузок подстанций и является вполне достаточной при планировании режимов. В случаях недостаточности телеизмерений режимных параметров информацию для расчета узловых нагрузок составляют результаты контрольных измерений, осуществляемых обычно два раза в год (в июне и декабре каждого года) для характерных интервалов графиков нагрузки ЭЭС. Для прогнозирования активных узловых нагрузок в данном случае применяются методы, в которых тем или иным способом производится распределение суммарных нагрузок ЭЭС по узлам эквивалентной расчетной схемы электрической сети. Коэффициенты пропорциональности определяются по результатам обработки контрольных замеров [1].

В некоторых методах строятся математические модели, связывающие графики нагрузок ЭЭС и отдельных узлов. Наибольшее распространение получили модели узловых нагрузок, использующие линейную регрессионную связь между нагрузками узлов и суммарной нагрузкой ЭЭС. В этом случае при определении коэффициентов пропорциональности учитываются их сезонные изменения и иерархическая структура сети ЭЭС. Для обеспечения баланса узловых нагрузок возникает необходимость учета потерь мощности в сетях ЭЭС. Для этой цели применяются регрессионные модели второго порядка.

Наиболее перспективным считают подход, связывающий задачи прогнозирования узловых нагрузок и оценивания состояния ЭЭС по данным телеизмерения параметров режима ЭЭС при оперативном управлении. Коэффициенты пропорциональности для узловых нагрузок при этом могут определяться и корректироваться по оцененным узловым нагрузкам, накапливаемым за некоторый интервал времени. Нагрузки по реактивной мощности рассчитываются, как правило, на основе прогнозных нагрузок по активной мощности узлов с помощью коэффициентов мощности нагрузки, которые определяются по результатам обработки контрольных замеров или оценивания состояния ЭЭС.

Наиболее важными характеристиками моделей при анализе и выборе наиболее подходящих математических моделей, адекватных процессам потребления электроэнергии, являются следующие характеристики:

- способ моделирования трендовой, сезонной, недельной составляющих временного ряда;
- способ нелинейного моделирования временного ряда;
- способ моделирования внутренних взаимосвязей между конструктивными компонентами, определяемыми при декомпозиции временных рядов на составляющие;
- способ моделирования случайной составляющей временного ряда;



- способ учета влияния внешних факторов на процесс.

От того какой математический аппарат применяется и какое целевое направление, классические способы прогнозирования нагрузки можно разделить на три вида [12-15]:

- методы аналитического прогнозирования;
- методы статистического прогнозирования;
- методы вероятностного прогнозирования.

Большинство алгоритмов прогнозирования электрической нагрузки, разработанных в электроэнергетике, представляют собой комбинацию различных методов [16].

### 1.1. АНАЛИТИЧЕСКИЕ МЕТОДЫ

Аналитические методы на основе выявленных закономерностей (взаимосвязи объекта прогнозирования и факторов, влияющих на него) позволяют построить математическую модель, выраженную системой уравнений. По этой модели рассчитываются прогнозные значения исследуемого явления (например, уровня нагрузки) при тех или иных сочетаниях факторов прогнозного фона. Аналитические методы также называют объективными, экспликативными и казуальными (причинными) [17].

К аналитическим методам относят метод производных, суммирование, операторный метод, и др.

Аналитические методы основаны на характеристике изменения состояния системы в прошлом и экстраполяции полученного результата в будущем. Они включают в себя следующие этапы:

- первичную обработку и преобразование исходного ряда;
- выбор типа эмпирических функций;
- определение параметров эмпирических функций;
- экстраполяцию;
- оценку точности.

Аналитическое (математическое) моделирование работает в том случае, если есть модель. При построении прогноза динамики какой-либо системы по данному методу необходимо получение полного описания всех ее параметров, а также их взаимосвязи и зависимости от внешних для системы факторов.

Модели прогнозирования, которые учитывают производные оператора состояния, имеют неопределенность начальных условий. При стохастических помехах начальная неопределенность возрастает, что усложняет вычисление параметров модели. Вследствие чего, становится хуже точность прогнозирования.

К несовершенству рассмотренного метода можно отнести трудоемкость и сложность вычислений, которые связаны с необходимостью выбора и вычисления по отдельности для каждого параметра аналитического выражения. К недостаткам методов аналитического прогнозирования относят также неточность результатов прогнозирования при неправильном выборе модели и большой объем вычислительных процедур при прогнозировании. Поэтому аналитические методы практически не применяются для решения задач прогнозирования нагрузки в распределительных сетях в виду больших размерностей математических моделей.

### 1.2. СТАТИСТИЧЕСКИЕ МЕТОДЫ

Обычно статистические методы могут достаточно точно предсказать суточный график нагрузки в обычные дни, но им не хватает способности анализировать нагрузку в праздничные или другие дни, в связи с отсутствием гибкости их структуры. Статистические методы включают

множественную линейную и нелинейную регрессию, а также методы, построенные на основе авторегрессионных моделях с линейным и экспоненциальным сглаживанием.

#### Регрессионные методы

Данные методы прогнозирования основаны на применении регрессионного анализа (множественной регрессии) и являются одними из наиболее широко используемыми статистическими методами. Термин множественная регрессия объясняется тем, что анализу подвергается зависимость одного признака (результатирующего) от набора (множества) независимых (факторных) признаков.

Регрессионный анализ используется по двум причинам.

1. Описание зависимости между переменными помогает установить наличие возможной причинной связи;
2. С помощью сравнения регрессии можно предсказывать значения зависимой переменной по значениям независимых переменных, что позволяет определить предиктор для зависимой переменной.

При построении уравнений множественной регрессии основным этапом является отбор наиболее существенных факторов, воздействующих на результирующий признак. Этот этап построения модели множественной регрессии производится на основе качественного теоретического анализа в сочетании с использованием статистических приемов. Обычно отбор факторов проходит две стадии. На первой стадии на основе содержательного анализа намечают круг факторов, теоретически существенно влияющих на результирующий признак. На второй стадии качественный анализ дополняется количественными оценками, которые позволяют отобрать статистически существенные факторы для рассматриваемых конкретных условий реализации связи [9].

При построении регрессионных моделей, прежде всего, возникает вопрос о виде функциональной зависимости, характеризующей взаимосвязи между результирующим признаком и несколькими признаками-факторами. Выбор формы связи должен основываться на качественном, теоретическом и логическом анализе сущности изучаемых явлений.

Чаще всего ограничиваются линейной регрессией, т.е. зависимостью вида:

$$Y = a + b_1 \cdot X_1 + b_2 \cdot X_2 + \dots + b_n \cdot X_n + \varepsilon, \quad (1)$$

где  $Y$  – результирующий признак;  $X_1, \dots, X_n$  – факторные признаки (факторы);  $b_1, \dots, b_n$  – коэффициенты регрессии;  $a$  – свободный член уравнения;  $\varepsilon$  – “ошибка” модели.

Коэффициенты регрессии  $b_j$  определяются таким образом, чтобы рассогласования  $\varepsilon$ , характеризующие степень приближения реальных значений результирующего признака  $Y$  с помощью линейной модели  $a + b_1 \cdot X_1 + b_2 \cdot X_2 + \dots + b_n \cdot X_n$ , были минимальными. Это достигается на основе метода наименьших квадратов.

Методы регрессии обычно используются для моделирования взаимосвязей электропотребления с другими факторами, такими как погодные факторы (температура, влажность, скорость и направление ветра и др.), тип дня и класс потребителей. Модели регрессии включают детерминированные факторы, например, праздничные дни, а также стохастические воздействия, такие как экзогенные факторы, например, метеорологические. Эти методы основаны на экспериментальных данных нагрузки в прошлом,

чтобы установить математическую модель для прогнозирования будущей нагрузки.

В настоящее время наиболее широко используются следующие методы оценки параметров модели многомерной регрессии [18]:

- метод байесовских оценок параметров, он применяется, когда априори известно распределение вероятностей семейства условных распределений;
- метод максимального правдоподобия, который используется, если отсутствует информация о плотности вероятностей, а априори известна лишь условная плотность;
- метод наименьших квадратов, который не требует никакой дополнительной априорной информации о процессе, кроме непосредственно выборок реализаций самого процесса и влияющих факторов.

Для корректного использования регрессионного анализа требуется выполнение определенных условий. Факторные признаки должны быть некоррелированы (отсутствие мультиколлинеарности), они предполагаются измеренными точно, и в их измерениях нет автокорреляции, т.е. значения признаков у одного объекта не должны зависеть от значений признаков у других объектов. Результирующий признак должен иметь постоянную дисперсию. Исследуемая совокупность должна быть в достаточной мере качественно однородной. Существенные нарушения этих условий приводят к некорректному использованию моделей множественной регрессии.

Ограничением в применении линейных регрессионных моделей также является то, что между погодными переменными и нагрузкой существуют нелинейные зависимости. Алгоритм линейной регрессии для динамического процесса с нелинейными связями с метеофакторами не может справиться с задачей точного прогноза.

#### Авторегрессионные методы

Авторегрессионная (AR-) модель (англ. autoregressive model) – модель временных рядов, в которой значения временного ряда в данный момент линейно зависят от предыдущих значений этого же ряда. Авторегрессионный процесс порядка  $p$  (AR( $p$ )-процесс) определяется следующим образом

$$X_t = c + \sum_{i=1}^p a_i \cdot X_{t-i} + \varepsilon_t, \quad (2)$$

где  $a_i$  – параметры модели (коэффициенты авторегрессии);  $c$  – постоянная (часто для упрощения предполагается равной нулю),  $\varepsilon_t$  – белый шум.

Простейшим примером является авторегрессионный процесс первого порядка AR(1)-процесс:

$$X_t = c + a_1 \cdot X_{t-1} + \varepsilon_t. \quad (3)$$

Для данного процесса коэффициент авторегрессии совпадает с коэффициентом автокорреляции первого порядка.

Другой простой процесс – процесс Юла – AR(2)-процесс:

$$X_t = c + a_1 \cdot X_{t-1} + a_2 \cdot X_{t-2} + \varepsilon_t. \quad (4)$$

С помощью AR-моделей можно моделировать сезонность [19]. Такие модели обозначают SAR (Seasonal AR). Например, при наличии квартальных данных и предположении о квартальной сезонности можно построить следующую модель SAR(4):

$$X_t = a_4 \cdot X_{t-4} + \varepsilon_t. \quad (5)$$

Фактически, это обычная AR-модель с ограничением на параметры модели (равенство нулю параметров при лагах менее 4). На практике сезонность может сочетаться с обычной авторегрессией, например:

$$X_t = a_1 \cdot X_{t-1} + a_4 \cdot X_{t-4} + \varepsilon_t. \quad (6)$$

В некоторых случаях оказываются полезными сезонные модели, у которых случайная ошибка, подчиняется некоторому AR-процессу:

$$X_t = a_4 \cdot X_{t-4} + \varepsilon_t, \quad \varepsilon_t = a_1 \cdot \varepsilon_{t-1} + u_t. \quad (7)$$

При работе с рядами наличие шума часто затрудняет анализ структуры ряда. Чтобы исключить его влияние и лучше увидеть структуру ряда, можно использовать методы сглаживания рядов.

#### Авторегрессионные методы со скользящим средним

Самый простой метод сглаживания рядов – скользящее среднее. Модель авторегрессии – скользящего среднего (англ. autoregressive moving-average model, ARMA) – одна из математических моделей, используемых для анализа и прогнозирования стационарных временных рядов в статистике. Модель ARMA обобщает две более простые модели временных рядов – модель авторегрессии (AR) и модель скользящего среднего (MA).

Скользящая средняя, скользящее среднее (англ. moving average, MA) – общее название для семейства функций, значения которых в каждой точке определения равны среднему значению исходной функции за предыдущий период. Скользящие средние обычно используются с данными временных рядов для сглаживания краткосрочных колебаний и выделения основных тенденций или циклов. Математически скользящее среднее является одним из видов свертки, и поэтому его можно рассматривать как фильтр низких частот, используемых в обработке сигналов.

Модель скользящего среднего порядка  $q$ -го порядка MA( $q$ ) – модель временного ряда вида:

$$X_t = \sum_{j=1}^q b_j \cdot \varepsilon_{t-j}, \quad (8)$$

где  $\varepsilon_t$  – белый шум,  $b_j$  – параметры модели ( $b_0$  можно считать равным 1 без ограничения общности).

Также в модель иногда добавляют константу. Тем не менее, поскольку чаще всего модели скользящего среднего используются для моделирования случайных ошибок временных рядов, то константу можно считать параметром основной модели.

Процесс белого шума формально можно считать процессом скользящего среднего нулевого порядка – MA(0).

Чаще всего на практике используют процесс скользящего среднего первого порядка MA(1)

$$X_t = \varepsilon_t + b \cdot \varepsilon_{t-1}. \quad (9)$$

Согласно теореме Волда всякий “регулярный” стационарный процесс может быть представлен как некоторый процесс MA( $\infty$ )-процесс с некоторыми коэффициентами (сумма их модулей должна быть конечной). В частности отсюда следует, что любой “регулярный” стационарный процесс можно сколь угодно точно приблизить некоторым MA( $q$ )-процессом конечного порядка. Тем не менее, такой способ иногда потребовал бы очень большого порядка модели. Сократить количество параметров модели позволяют модели ARMA, которые дополняют MA-модели авторегрессионной частью.

Моделью  $ARMA(p, q)$ , где  $p$  и  $q$  – целые числа, задающие порядок модели, называется следующий процесс генерации временного ряда:

$$X_t = c + \sum_{i=1}^p a_i \cdot X_{t-i} + \sum_{j=1}^q b_j \cdot \varepsilon_{t-j}, \quad (10)$$

где  $c$  – константа,  $\varepsilon_t$  – белый шум, т.е. последовательность независимых и одинаково распределённых случайных величин (как правило, нормальных), с нулевым средним,  $a_i$  и  $b_j$  – действительные числа, авторегрессионные коэффициенты и коэффициенты скользящего среднего, соответственно.

Такая модель может интерпретироваться как линейная модель множественной регрессии, в которой в качестве объясняющих переменных выступают прошлые значения самой зависимой переменной, а в качестве регрессионного остатка – скользящие средние из элементов белого шума.  $ARMA$ -процессы имеют более сложную структуру по сравнению со схожими по поведению  $AR$ - или  $MA$ -процессами в чистом виде, но при этом  $ARMA$ -процессы характеризуются меньшим количеством параметров, что является одним из их преимуществ.

При наличии единичных корней авторегрессионного полинома процесс является нестационарным. Корни меньше единицы на практике не рассматриваются, поскольку это процессы взрывного характера. Соответственно, для проверки стационарности временных рядов один из базовых тестов – тесты на единичные корни. Если тесты подтверждают наличие единичного корня, то анализируются разности исходного временного ряда и для стационарного процесса разностей некоторого порядка (обычно достаточно первого порядка, иногда второго) строится  $ARMA$ -модель. Такие модели называются  $ARIMA$ -моделями (интегрированный  $ARMA$ ) или моделями Бокса-Дженкинса.

Подход  $ARIMA$  к временным рядам заключается в том, что в первую очередь оценивается стационарность ряда. Различными тестами выявляются наличие единичных корней и порядок интегрированности временного ряда (обычно ограничиваются первым или вторым порядком). Далее при необходимости (если порядок интегрированности больше нуля) ряд преобразуется взятием разности соответствующего порядка и уже для преобразованной модели строится некоторая  $ARMA$ -модель, поскольку предполагается, что полученный процесс является стационарным, в отличие от исходного нестационарного процесса (разностно-стационарного или интегрированного процесса порядка  $d$ ). Процесс  $ARIMA(p, d, q)$  эквивалентен процессу  $ARMA(p+d, q)$  с  $d$  единичными корнями.

Для построения модели  $ARMA$  по серии наблюдений необходимо определить порядок модели (числа  $p$  и  $q$ ), а затем и сами коэффициенты. Для определения порядка модели может применяться исследование таких характеристик временного ряда, как его автокорреляционная функция и частная автокорреляционная функция. Для определения коэффициентов применяются такие методы, как метод наименьших квадратов и метод максимального правдоподобия.

В классические  $ARMA$ -модели можно добавить некоторые экзогенные факторы  $x$ . Причем в общем случае в модели участвуют не только текущие значения этих факторов, но и лаговые значения. Такие модели принято обо-

значать  $ARMAX(p, q, k)$ , где  $k$  – количество лагов экзогенных факторов. В операторной форме такие модели можно записать следующим образом (один экзогенный фактор)

$$a(L) \cdot y_t = c \cdot b(L) \cdot \varepsilon_t + d(L) \cdot x_t, \quad (11)$$

где  $a(L)$ ,  $b(L)$ ,  $d(L)$  – полиномы порядка соответственно  $p$ ,  $q$ ,  $k$  от лагового оператора.

Все перечисленные авторегрессионные модели временных рядов ( $AR$ ,  $ARI$ ,  $ARMA$  и т.п.) при построении используют понятия теории вероятности и математической статистики, такие как АКФ, частная автоковариационная функция (ЧАКФ), автокорреляционная и ковариационная матрицы, стационарность случайного процесса и другие. Поэтому при их использовании к моделируемому процессу предъявляются требования выполнения статистических критериев, в частности, критерий стационарности и случайности временного ряда (критерий серий), критерий значимости ковариационных и корреляционных матриц и т.п. [18].

Все перечисленное усложняет применение перечисленных методов к различным типам процессов электропотребления. Кроме того, следует отметить, что применение этих методов адекватно ситуации, если моделируемый процесс практически стационарный или приводится к стационарному взятием однократных разностей. В иных случаях нестационарных процессов электропотребления со значимым детерминированным трендом использование этих моделей часто дает неудовлетворительный по точности результат.

*Авторегрессионные методы с экспоненциальным сглаживанием*

Модели экспоненциального сглаживания и прогнозирования относятся к классу адаптивных методов прогнозирования, основной характеристикой которых является способность непрерывно учитывать эволюцию динамических характеристик изучаемых процессов, подстраиваться под эту динамику, придавая, в частности, тем больший вес и тем более высокую информационную ценность имеющимся наблюдениям, чем ближе они расположены к текущему моменту времени. Смысл термина состоит в том, что адаптивное прогнозирование позволяет обновлять прогнозы с минимальной задержкой и с помощью относительно несложных математических процедур.

Экспоненциальное сглаживание, как и метод скользящих средних, для прогноза использует прошлые значения временного ряда. Сущность метода экспоненциального сглаживания заключается в том, что временной ряд сглаживается с помощью взвешенной скользящей средней, в которой веса подчиняются экспоненциальному закону. Метод экспоненциального сглаживания вычисляет значения сглаженного ряда путём обновления значений, рассчитанных на предыдущем шаге, используя информацию с текущего шага. Информация с предыдущего и текущего шагов берётся с разными весами, которыми можно управлять. При этом все предыдущие значения ряда вносят вклад в текущее сглаженное значение, однако их вклад угасает экспоненциально за счёт роста степени регулируемого параметра.

Взвешенная скользящая средняя с экспоненциально распределёнными весами характеризует значение процесса на конце интервала сглаживания, т.е. является средней характеристикой последних уровней ряда. Именно это свойство и используется для прогнозирования.



- существует несколько вариантов данного метода [20]:
- одинарное сглаживание для рядов, у которых нет тренда и сезонности;
- двойное сглаживание для рядов, у которых есть тренд, но нет сезонности;
- тройное сглаживание для рядов, у которых есть и тренд, и сезонность.

Обычное экспоненциальное сглаживание применяется в случае отсутствия в данных тренда или сезонности. В этом случае прогноз является взвешенной средней всех доступных предыдущих значений ряда; веса при этом со временем геометрически убывают по мере продвижения в прошлое (назад). Поэтому (в отличие от метода скользящего среднего) здесь нет точки, на которой веса обрываются, т.е. зануляются.

Прагматически ясная модель простого экспоненциального сглаживания может быть записана следующим образом:

$$F_{t+1} = \alpha \cdot X_t + (1 - \alpha) \cdot F_t, \quad (12)$$

где  $F_{t+1}$  – прогнозное (сглаженное) значение на период  $t+1$ ;  $\alpha$  – параметр сглаживания (smoothing parameter), или, иначе, фактор демпфирования (damping factor) – ( $0 < \alpha < 1$ );  $X_t$  – текущее значение временного ряда;  $F_t$  – прогнозное значение на период  $t$ , или сглаженное значение для периода  $t-1$ .

Если в данных есть тренд, простое экспоненциальное сглаживание будет “отставать” от него (либо придется брать значения параметров близкими к 1, но тогда сглаживание будет недостаточным). Нужно использовать двойное экспоненциальное сглаживание.

В середине прошлого века Хольт предложил расширить модель простого экспоненциального сглаживания за счет включения в нее фактора роста (growth factor), или иначе тренда (trend factor). Двойное сглаживание использует уже два уравнения – одно уравнение оценивает тренд как разницу между текущим и предыдущим сглаженным значениями, потом сглаживает тренд простым сглаживанием. Второе уравнение выполняет сглаживание как в случае простого варианта, но во втором слагаемом используется сумма предыдущего сглаженного значения и тренда.

В результате модель Хольта может быть записана следующим образом:

$$\left. \begin{aligned} F_{t+1} &= \alpha \cdot X_t + (1 - \alpha) \cdot (F_t + T_t) \\ T_{t+1} &= \gamma \cdot (F_{t+1} - F_t) + (1 - \gamma) \cdot T_t \\ H_{t+m} &= F_{t+1} + m \cdot T_{t+1} \end{aligned} \right\}, \quad (13)$$

где  $T_t$  – оценка тренда;  $\gamma$  – параметр сглаживания для оценки тренда;  $m$  – период, на который осуществляется прогноз;  $H_{t+m}$  – прогноз по Хольту на период  $t+m$ .

Начальные значения сглаженного ряда ( $F_0$ ) и трендовой оценки ( $T_0$ ) вычисляются по следующим формулам:

$$T_0 = \frac{X_n - X_1}{n - 1}, \quad F_0 = X_1 - \frac{T_0}{2}, \quad (14)$$

где  $X_1$  и  $X_n$  – первое и последнее наблюдение ряда, соответственно;  $n$  – длина ряда.

Данный метод позволяет учесть присутствие в данных линейного тренда. Позднее были предложены другие виды трендов: экспоненциальный, демпфированный и др.

Тройное сглаживание включает ещё один компонент – сезонность, и использует ещё одно уравнение. При этом различаются два варианта сезонного компонента – аддитивный и мультипликативный. В первом случае амплитуда

сезонного компонента постоянна и со временем не зависит от базовой амплитуды ряда. Во втором случае амплитуда меняется вместе с изменением базовой амплитуды ряда. Это как раз наш случай, как видно из графика. С ростом ряда амплитуда сезонных колебаний увеличивается.

В частности, Винтерс далее расширил модель Хольта за счет включения в нее дополнительного уравнения, описывающего поведение сезонной компоненты (составляющей). Система уравнений модели Винтерса выглядит следующим образом:

$$\left. \begin{aligned} F_t &= \alpha \cdot \frac{X_t}{S_{t-p}} + (1 - \alpha) \cdot (F_{t-1} + T_{t-1}) \\ T_t &= \gamma \cdot (F_t - F_{t-1}) + (1 - \gamma) \cdot T_{t-1} \\ S_t &= \delta \cdot \frac{X_t}{F_t} + (1 - \delta) \cdot S_{t-p} \\ W_{t+m} &= (F_t + m \cdot T_t) \cdot S_t \end{aligned} \right\}, \quad (15)$$

где  $S_t$  – оценка сезонной компоненты (сезонности);  $\delta$  – параметр сезонного сглаживания;  $p$  – число периодов в сезонном цикле (для года – 12 месяцев);  $W_{t+m}$  – прогноз по Винтерсу на период  $t+m$ ;

Дробь в первом уравнении служит для исключения сезонности из исходного ряда. После исключения сезонности (по методу сезонной декомпозиции Census I) алгоритм работает с “чистыми” данными, в которых нет сезонных колебаний. Появляются они уже в самом финальном прогнозе, когда “чистый” прогноз, посчитанный почти по методу Хольта, умножается на сезонную компоненту (индекс сезонности).

Метод экспоненциального сглаживания удобен при математическом моделировании электропотребления, если моделируемый процесс имеет следующие особенности [18]:

- монотонный характер изменения без резких кратковременных скачков;
- процесс изменения обусловлен действием большого количества внешних факторов, причем степень и характер влияния, состав влияющих факторов изменяется с течением времени;
- процесс изменения является нестационарным в статистическом смысле, а временной ряд процесса относится к коротким временным рядам с числом отсчетов до 100.

Данный метод обладает достаточными робастными свойствами, и зачастую дает положительные результаты в тех случаях, когда применение более сложных моделей для прогнозирования (типа ARX, ARIMA и т.п.) приводит к излишней чувствительности модели и неустойчивости прогнозирования.

Недостатками этого метода являются:

- невозможность прямого учета в модели действия того или иного влияющего фактора (как, например, в ARX-модели);
- использование прогнозирующих полиномов низкого порядка (первого, второго) из-за усложнения формул идентификации и отсутствия аналитически выведенных подобных формул.

Известны также другие методы сглаживания рядов. Для моделей с тригонометрическими выражениями различают также такие разновидности сглаживания как экспоненциально-взвешенная регрессия (EWR – exponentially weighted regression), дисконтированно-взвешенная регрес-

сия (*DWR* – discount weighted regression). В методах *EWR* при МНК оптимизации учитывается единый весовой коэффициент, в то время как в методах *DWR* каждый параметр характеризуется своим весовым коэффициентом. Известны также методы прогнозирования нагрузки, весовые коэффициенты в которых определяются с помощью сплайнов и сингулярного разложения [20].

### 1.3. ВЕРОЯТНОСТНЫЕ МЕТОДЫ

Необходимость вероятностного прогнозирования обуславливается сильным влиянием внутренних и внешних факторов, обладающих случайным характером. К методам вероятностного прогнозирования принадлежат метод статистического градиента, критерия Байеса, фильтрации, гипотез и т.д. Для того чтобы получить непрерывное прогнозирование используются фильтры: для прогнозирования стационарных процессов фильтр Винера-Хопфа, для нестационарных процессов используется фильтр Калмана [17].

Уравнение Винера-Хопфа составляет один из важнейших результатов теории фильтрации Колмогорова-Винера. Известно, методы, построенные на основе данного уравнения, позволяют определять оптимальные параметры фильтра, обеспечивающего воспроизведение полезного сигнала из некоррелированного шума с минимальной среднеквадратической ошибкой. Если при этом сам полезный сигнал и помеха представляют собой стационарные, эргодические центрированные случайные функции [2].

Однако те обстоятельства, что процессы должны отвечать условиям стационарности, эргодичности и иметь нулевое математическое ожидание резко уменьшают их применимость. Нарушение данных допущений зачастую может привести к катастрофическому росту погрешности вследствие необходимости решения некорректной плохо обусловленной задачи.

Кроме того, известно [18], что адаптивная регрессионная *ARMA*-модель, по сравнению с рассмотренной в большинстве случаев, дает лучший результат по погрешности в силе своей адаптивности, хотя в этой модели явно не учитывается нестационарность процесса, как в рассмотренной модели. Поэтому рассмотренная модель в настоящее время имеет ограниченное применение.

Методы, построенные на фильтре Калмана, также имеют ряд существенных недостатков. В частности, алгоритм рекуррентной идентификации является не асимптотически устойчивым по Ляпунову, это означает, что он становится неустойчивым при постоянстве измеренных сигналов, т.е. при неинформативных измерениях происходит накопление ошибок оценки параметров модели. Это обстоятельство определяет только эпизодическое применение данного алгоритма при возникновении в объекте динамических режимов.

Еще одна трудность, возникающая при практическом использовании фильтра Калмана, состоит в проблеме его расходимости. Основными причинами потери устойчивости фильтра являются потеря положительной определенности корреляционной матрицы вследствие вычислительных ошибок, либо при нестационарности или нелинейности моделируемого объекта и когда параметры уравнения объекта априори неизвестны или известны с малой точностью. Перечисленные проблемы оптимальной фильтрации характерны и для процессов электропотребления.

Определение параметров фильтра требует оценки статистических характеристик моделируемого сигнала и по-

мехи. Кроме того, полагают, что эти характеристики неизменны для моделируемого процесса (что не всегда верно для процесса электропотребления). Учет изменчивости характеристик процесса и устранение эффекта расходимости увеличивает число вычислений во время идентификации и требует итерационной настройки фильтра. Это в некоторых случаях приводит к расходимости фильтра вследствие ошибок вычислений. Другая особенность прогнозирующего фильтра Калмана состоит в том, что при моделировании процесса электропотребления не реализуется концепция многомерного моделирования графиков нагрузки.

Результаты прогнозирования методами фильтра Калмана и *ARIMA*-моделью при прогнозировании электропотребления очень близки между собой, это позволяет говорить о взаимозаменяемости моделей. Кроме того, показано, что калмановская фильтрация повышает точность прогнозирования при использовании ее совместно с моделью типа экспоненциального сглаживания [18].

Основное применение вероятностных методов в целом – это выделение и моделирование полезного сигнала на уровне шумов (в том числе оценивание состояния в различных точках электрической сети в реальном масштабе времени, первичная обработка быстро изменяющейся информации и т.п.) при этом процессы линейные и имеют гауссовский характер с известными характеристиками, а входные возмущения и шумы не коррелированы между собой.

## 2. ИНТЕЛЛЕКТУАЛЬНЫЕ МЕТОДЫ ПРОГНОЗИРОВАНИЯ НАГРУЗКИ

Ранее рассматриваемые методы прогнозирования электрической нагрузки на практике сталкиваются с определенными трудностями. Случайный, вероятностный характер изменений нагрузки энергосистемы является одной из существенных особенностей процесса. Вследствие наличия случайной составляющей, естественного роста нагрузки и влияния различных факторов, строгой периодичности в графиках нагрузки нет. Вследствие чего появляются новые методы для прогнозирования нагрузки, основанные на искусственном интеллекте [21].

Основные преимущества интеллектуальных систем прогнозирования: способность получения правильного решения задачи при наличии неполных и искаженных данных после настройки параметров (обучения) сети; возможность учета большого количества дополнительных факторов, влияющих на качество прогнозирования; они обладают устойчивостью к помехам, имеют высокое быстродействие. Основным недостатком данных методов является необходимость обучения. Обзоры интеллектуальных методов прогнозирования нагрузки показывают, что наряду с успехами в их применении, надо еще много поработать, прежде чем эти методы будут признаны в качестве официальной техники прогнозирования нагрузки [4, 22].

Среди интеллектуальных методов прогнозирования нагрузок выделяют экспертные системы, искусственные нейронные сети, клеточные автоматы, методы, основанные на теории хаоса, методы группового учета аргументов, опорных векторов и комбинированные методы.

### 2.1. ЭКСПЕРТНЫЕ СИСТЕМЫ

В зависимости от вида используемых моделей на нижнем (исполнительном) уровне, интеллектуальные системы управления делятся на два класса: интеллектуальные системы логического управления и интеллектуальные регу-



ляторы. В системах первого класса на исполнительном уровне используются логические модели (например, автоматные), а в системах второго класса – модели традиционной теории автоматического управления (регулирования) [23].

Прообразом интеллектуальных систем логического управления в недавнем прошлом служили системы ситуационного управления. Знания об особенностях принятия решения диспетчерским персоналом ЭЭС, для которого собственно и разрабатывались системы ситуационного управления, использовались при поиске управленческих решений задолго до появления развитых программных систем, ориентированных на представление и обработку знаний в системах ситуационного управления. Важной особенностью ситуационного управления является принятие управленческих решений на множестве ситуаций (событий), возникающих в процессе управления. Поэтому системы ситуационного управления действительно были прообразом современных интеллектуальных управляющих систем. Процессы принятия управленческих решений в рассмотренных системах ситуационного управления аналогичны процессам обработки информации в любой интеллектуальной и в частности, экспертной системе.

Прогнозные экспертные оценки отражают суждения специалистов относительно перспектив развития объекта и основаны на мобилизации профессионального опыта и интуиции. Методы экспертных оценок используются для анализа объектов и проблем, развитие которых либо полностью, либо частично не поддается математической формализации, т. е. для которых трудно разработать адекватную модель [8].

Типовая структура экспертной системы может быть представлена следующими блоками: база знаний с механизмами рассуждений; интеллектуальный решатель; интеллектуальный планировщик; подсистема объяснения; интеллектуальный интерфейс с пользователем (рис. 2) [23].

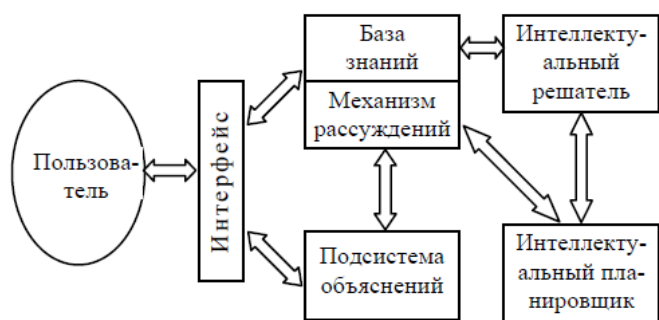


Рис. 2. Типовая структура экспертной системы

Экспертные системы могут существенным образом различаться по архитектуре и выполняемым функциям, но в них всегда в той или иной мере присутствуют указанные блоки.

При этом наиболее сложные функции по принятию решений на базе механизмов рассуждений с использованием информации из базы знаний реализуются в блоке “Интеллектуальный решатель”. В экспертных системах, непосредственно включенных в контур управления, блок интерфейса с пользователем естественным образом заменяется на блок интерфейса с объектом управления.

Применяемые в прогнозировании методы экспертной оценки разделяют на индивидуальные и коллективные. Индивидуальные экспертные методы основаны на использовании мнений экспертов-специалистов соответствующего профиля независимо друг от друга. Наиболее часто применимыми являются следующие два метода формирования прогноза: интервью и аналитические экспертные оценки.

Метод интервью предполагает беседу прогнозиста с экспертом, в ходе которой прогнозист в соответствии с заранее разработанной программой ставит перед экспертом вопросы относительно перспектив развития прогнозируемого объекта. Успех такой оценки в значительной степени зависит от способности интервьюируемого эксперта экспромтом давать заключения по самым различным фундаментальным вопросам.

Аналитические экспертные оценки предполагают длительную и тщательную самостоятельную работу эксперта над анализом тенденций, оценкой состояния и путей развития прогнозируемого объекта. Этот метод дает возможность эксперту использовать всю необходимую ему информацию об объекте прогноза. Свои соображения эксперт оформляет в виде докладной записки.

Основными преимуществами рассматриваемых методов являются возможность максимального использования индивидуальных способностей эксперта и незначительность психологического давления, оказываемого на отдельного работника. Однако эти методы малоприменимы для прогнозирования наиболее общих стратегий из-за ограниченности знаний одного специалиста-эксперта о развитии смежных областей науки.

Методы коллективных экспертных оценок основываются на принципах выявления коллективного мнения экспертов о перспективах развития объекта прогнозирования. В основе применения этих методов лежит гипотеза о наличии у экспертов умения с достаточной степенью достоверности оценить важность и значение исследуемой проблемы, перспективность развития определенного направления исследований, времени свершения того или иного события, целесообразности выбора одного из альтернативных путей развития объекта прогноза и т. д. В настоящее время широкое распространение получили экспертные методы, основанные на работе специальных комиссий, когда группы экспертов за круглым столом обсуждают ту или иную проблему с целью согласования мнений и выработки единого мнения. Этот метод имеет недостаток, заключающийся в том, что группа экспертов в своих суждениях руководствуется в основном логикой компромисса.

В свою очередь, в методе Дельфи вместо коллективного обсуждения той или иной проблемы проводится индивидуальный опрос экспертов обычно в форме анкет для выяснения относительной важности и сроков свершения гипотетических событий. Затем производится статистическая обработка анкет и формируется коллективное мнение группы, выявляются, обобщаются аргументы в пользу различных суждений. Вся информация сообщается экспертам. Участников экспертизы просят пересмотреть оценки и объяснить причины своего несогласия с коллективным суждением. Эта процедура повторяется 3-4 раза. В результате происходит сужение диапазона оценок. Недостатком этого метода является невозможность учета влияния, оказываемого на экспертов организаторами опросов при составлении анкет.

Проблема использования экспертных систем в управлении ЭЭС находится еще в начальной стадии, требуется ее интеграция с традиционными системами управления. Основными ограничениями применения экспертных систем являются их узкая направленность и неспособность к самообучению, что обуславливает сложность обновления правил их функционирования при изменении условий задачи. Кроме того, все еще остается проблемой приведение экспертных знаний к виду, обеспечивающему их эффективную машинную реализацию.

### 2.2. ИСКУССТВЕННЫЕ НЕЙРОННЫЕ СЕТИ

Искусственные нейронные сети – это устройства, основанные на параллельной обработке информации всеми звеньями. Они обладают способностью к обучению и обобщению накопленных знаний. Нейронным сетям присущи черты искусственного интеллекта. Натренированная на ограниченном множестве данных сеть способна обобщать полученную информацию и показывать хорошие результаты на данных, не использовавшихся в процессе обучения. Предпочтение их традиционным моделям обусловлено тем, что при этом не требуется построения модели объекта, не теряется работоспособность при неполной входной информации.

Впервые для моделирования и прогнозирования нагрузки предположили метод искусственной нейронной сети в 1991 году. Нейронные сети, по существу это нелинейные функции, которые имеют способность выполнения аппроксимации нелинейных зависимостей. Выходы искусственной нейронной сети являются линейными или нелинейными математическими функциями ее входов. Входы могут быть выходами других сетевых элементов. Преимуществом технологии нейронных сетей является интеллектуальная обработка, которая может имитировать работу человеческого мозга. Недостатком является то, что процесс обучения является относительно медленным, и это не гарантирует сходимости между фактическими и прогнозными данными. Кроме этого, определение оптимального набора входных переменных и размеры скрытых слоев следует исследовать на практике [1, 4].

Роль нейронной сети при решении задач прогнозирования состоит в предсказании будущей реакции системы по ее предшествующему поведению. Обладая исходной информацией о значениях исследуемой переменной в моменты времени, предшествующие прогнозированию, нейронная сеть вырабатывает решение, каким будет наиболее вероятное значение прогнозируемого параметра в заданный момент времени. Причем процесс прогнозирования, т.е. функционирования нейронной сети, происходит достаточно быстро.

Нейронная сеть – это математическая модель человеческого мозга, состоящая из многих простых вычислительных элементов (нейронов), работающих параллельно, функция которых определяется структурой сети, а вычисления производятся в самих элементах (рис. 3). Считается, что способность мозга к обработке информации в основном обусловлена функционированием сетей, состоящих из таких нейронов.

В состав нейрона входит умножители, сумматоры и нелинейный преобразователь. Синапсы осуществляют связь между нейронами и умножают входной сигнал на число, характеризующее силу связи – веса синапсов (рис. 3).

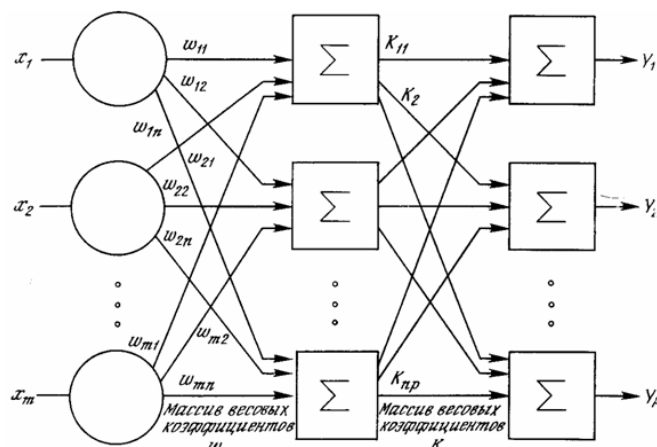


Рис. 3. Двухслойная нейронная сеть

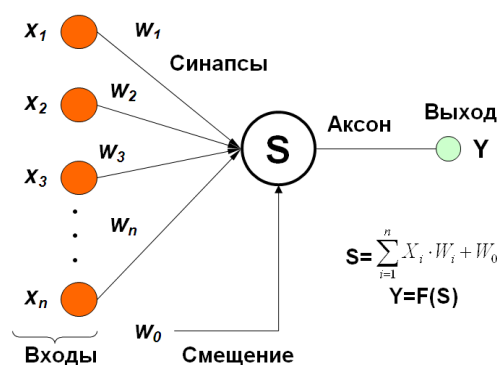


Рис. 3. Структура нейрона

Сумматор выполняет сложение сигналов, поступающих по синаптическим связям от других нейронов или внешних входных сигналов. Нелинейный преобразователь реализует нелинейную функцию одного аргумента – выход сумматора. Это функция называется “функцией активации” или “передаточной функцией” нейрона. Нейрон в целом реализует скалярную функцию векторного аргумента.

Главная задача в процессе разработки нейронной сети, является этап обучения, т. е. корректировки весов сети, для минимизации ошибки на выходе нейронной сети.

При применении нейронной сети для целей прогнозирования, необходимо решить следующие задачи: выбрать архитектуру нейронной сети; определить количество и соединение слоев и элементов; принять решение по использованию двунаправленной или однонаправленной связи и цифрового формата.

Для решения задач прогнозирования нагрузок используют сети прямого распространения, самоорганизующиеся, радиально-базисные и вейвлет-нейронные сети [11, 24-26].

#### Сети прямого распространения

Самой популярной архитектурой искусственной нейронной сети для прогнозирования электрической нагрузки является архитектура прямого распространения.

Эта сеть использует непрерывно оцениваемые функции и обучение с учителем. Фактические числовые данные весов, присваиваемые входам элементов определяются путем сопоставления архивных данных (например, время и погода) с заданными выходами (например, прогнозные данные нагрузки) во время обучения. Искусственные нейронные сети с неконтролируемым обучением не требуют предварительной оперативной подготовки.

Стандартная нейронная сеть прямого распространения приведена на рис. 4, также известна как многослойный перцептрон (MLP).




Рис.4. Структура искусственной нейронной сети прямого распространения

Функционирование многослойной ИНС прямого распространения достаточно простое. Входные сигналы, подаваемые на сеть, поступают на нейроны входного слоя, проходят по очереди через все скрытые слои и выделяются с нейронов выходного слоя. По мере распространения сигналов по сети они претерпевают ряд преобразований, которые зависят от их начального значения, от преобразующей функции и величин весов связей. В классическом многослойном перцептоне, функция преобразования – сигмоида. Сигмоида – это гладкая монотонная нелинейная S-образная функция, которая часто применяется для “сглаживания” значений некоторой величины. Определение структуры ИНС (структуры реализуемой ею функции) сводится к выбору подходящей модели нейрона, достаточного числа нейронов в скрытом слое, входных и выходных параметров и формы их представления на основании результатов экспериментальных расчетов.

Здесь необходимо заметить, что при выборе структуры ИНС важно учитывать ее размерность, т.е. число скрытых слоев и число нейронов в этих слоях. При недостаточном размере сети для решения поставленной задачи ИНС будет плохо обучаться и неправильно работать, а при размере сети, превышающем сложность решаемой задачи, процесс обучения ИНС будет очень длительным или сеть вообще может быть непригодна для решения данной задачи. Этот вопрос в каждом конкретном случае решается экспериментальным путем.

Первоначальное обучение ИНС проводится согласно алгоритму обратного распространения ошибки. В процессе обучения определяются весовые коэффициенты связи между слоями. Алгоритм обратного распространения ошибки показан на рис. 5 в виде блок-схемы.

Принцип функционирования алгоритма обратного распространения ошибки, заключается в использовании метода градиентного спуска и корректировки весов, для минимизации ошибки нейронной сети. Основная идея обратного распространения состоит в том, как получить оценку ошибки для нейронов скрытых слоев. Заметим, что известные ошибки, делаемые нейронами выходного слоя, возни-

кают вследствие неизвестных пока ошибок нейронов скрытых слоев. Чем больше значение синаптической связи между нейроном скрытого слоя и выходным нейроном, тем сильнее ошибка первого влияет на ошибку второго. Следовательно, оценку ошибки элементов скрытых слоев можно получить, как взвешенную сумму ошибок последующих слоев. При обучении информация распространяется от низших слоев иерархии к высшим, а оценки ошибок, делаемые сетью – в обратном направлении, что и отражено в названии метода [11].

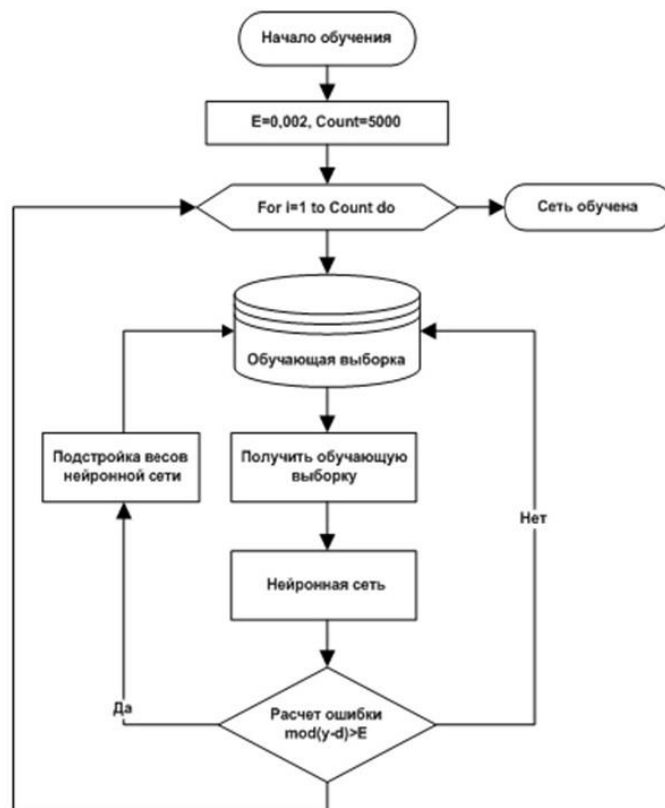


Рис. 5. Алгоритм обучения нейронной сети прямого распространения

### Самоорганизующиеся нейронные сети

Самоорганизующиеся нейронные сети (СНС) – это сети с обучением без учителя, выполняющие задачи визуализации и кластеризации. Являются одной из версий нейронных сетей (карт) Кохонена.

СНС служат, в первую очередь, для визуализации и первоначального (“разведывательного”) анализа данных. Каждая точка данных отображается соответствующим кодовым вектором из решетки. Так получают представление данных на плоскости (“карту данных”). На этой карте возможно отображение многих слоев: количество данных, попадающих в узлы (то есть “плотность данных”), различные функции данных и так далее. Карта данных является подложкой для произвольного по своей природе набора данных. На карте данных близкие объекты обладают близкими свойствами. С помощью карты данных можно визуализировать данные, одновременно нанося на подложку сопровождающую информацию. Карта служит также информационной моделью данных. С её помощью можно заполнять пробелы в данных. Эта способность СНС и используется для решения задач прогнозирования нагрузок.



Основная идея всех алгоритмов СНС заключается в построении вероятностной модели данных на основе представленных системе образов. В процессе обучения алгоритмы класса СНС строят граф, каждая вершина которого лежит в области локального максимума плотности вероятности, а ребра соединяют вершины, относящиеся к одним и тем же классам. Смысл такого подхода состоит в предположении, что классы образуют области высокой плотности вероятности в пространстве, и делается попытка построить граф, наиболее точно описывающий такие области и их взаимное расположение.

Стандартная самоорганизующаяся нейронная сеть представляет собой нейронную сеть с двумя слоями. Первый слой используется для определения топологической структуры кластеров, а второй для определения числа кластеров и выявления узлов-прототипов для них. Сначала обучается первый слой сети, а затем, используя данные полученные при обучении первого слоя, обучается второй слой сети.

Принцип работы СНС может быть описан следующим образом.

Во-первых, для поступающих входных данных строится граф таким образом, чтобы вершины попадали в области локального максимума плотности вероятности. Так получается граф, по каждой вершине которого можно построить некоторую функцию, описывающую распределение входных данных в соответствующей области пространства.

Во-вторых, граф в целом представляет собой смесь распределений, анализируя которую, можно определить число классов в исходных данных, их пространственное распределение и прочие характеристики.

Для представления топологической структуры в задачах обучения рост сети является важным элементом для снижения ошибки и адаптации к меняющимся условиям, сохраняя старые данные. Но в то же время, неконтролируемое увеличение числа узлов приводит к перегрузке сети и “переобучению” её в целом. Поэтому необходимо решать, когда и как добавлять новые узлы в сеть, а когда предотвратить добавление новых узлов.

Для задачи классификации без учителя, необходимо определить, принадлежит ли входной образ одному из ранее полученных кластеров или представляет новый. Для составления связей между нейронами используется конкурентное правило Хебба. Конкурентное правило Хебба может быть описано так: для каждого входного сигнала, объединяются два ближайших узла. Доказано, что каждый граф оптимально представляет топологию входных данных. В задачах обучения, узлы изменяют свое местоположение медленно, но постоянно. Таким образом, узлы, которые являются соседними на ранней стадии, возможно, не являются близкими в более поздней стадии. Тем самым появляется необходимость удаления соединений, которые в последнее время не обновляются.

В общем случае происходит также перекрытие существующих кластеров. Чтобы определить количество кластеров точно, предполагается, что входные данные являются разделяемыми: плотности вероятности в центральной части каждого кластера выше, чем плотность в части между кластерами, а также перекрытие кластеров имеет низкую плотность вероятности. Разделение кластеров происходит путем удаления узлов из регионов с низкой плотностью вероятности.

СНС представляют собой метод проецирования многомерного пространства в пространство с более низкой размерностью (чаще всего, двумерное). В связи с понижением размерности исходной задачи, и предопределенной структурой сети, в СНС возникают дефекты проецирования, анализ которых является сложной задачей.

#### Радиально-базисные нейронные сети

Радиально-базисная сеть (РБС) – искусственная нейронная сеть, которая использует радиальные базисные функции как функции активации. Радиально-базисная сеть имеет фиксированную структуру с одним скрытым слоем и линейными выходными нейронами (рис. 6) [24].




Рис. 6. Интерпретация радиально-базисной нейронной сети: слой 1 – входной слой, на который подаются входные векторы сигналов  $x$  ( $x_1, x_2, \dots, x_N$ ); слой 2 – скрытый слой нейронов с базисными радиальными функциями; слой 3 – выходной слой в виде линейного нейрона

Это сеть с двухслойной структурой, в которой только скрытый слой выполняет нелинейное отображение, реализуемое нейронами с базисными радиальными функциями. Выходной нейрон, как правило, линеен и его роль сводится к взвешенному суммированию сигналов, поступающих от нейронов скрытого слоя. Вес  $w_k$  представляет собой пороговое значение выходного нейрона.

Обучение РБС происходит в несколько этапов. Сначала определяются центры и отклонения для радиальных элементов; после этого оптимизируются весовые параметры линейного выходного слоя. Расположение центров должно соответствовать кластерам, реально присутствующим в исходных данных. Для процедуры кластеризации можно применить алгоритм К-средних, который стремится выбрать оптимальное множество точек, являющихся центрами кластеров в обучающих данных. После определения центров кластеров находятся отклонения. Как правило, отклонения выбираются таким образом, чтобы “колпак” каждой гауссовой функции захватывал несколько соседних центров. После того как выбраны центры и отклонения, параметры выходного слоя оптимизируются с помощью стандартного метода линейной оптимизации – алгоритма обратных матриц (сингулярного разложения).

РБС имеют ряд преимуществ перед многослойными сетями прямого распространения и самоорганизующимися нейросетями. Во-первых, они моделируют произвольную нелинейную функцию с помощью всего одного промежуточного слоя, тем самым избавляя от необходимости решать вопрос о числе слоев. Во-вторых, параметры линейной комбинации в выходном слое можно полностью оптимизировать с помощью хорошо известных методов линейной оптимизации, которые быстро работают и не испытывают трудностей с локальными минимумами, мешающими

при обучении с использованием алгоритма обратного распространения. Поэтому РБС обучаются на порядок быстрее, чем многослойные перцептроны, использующие алгоритм обратного распространения ошибки.

В результате появляется возможность существенно экономить машинное время ЭВМ, увеличить объем информации, подаваемой на вход-выход сети в процессе обучения, просчитать большее количество вариантов сети, варьируя ее параметрами, и из полученных результатов выбрать наилучший. При этом точность работы РБС не уступает точности многослойных и самоорганизующихся нейросетей, а в некоторых случаях превосходит.

#### Вейвлет-нейронные сети

Модели, основанные на методе вейвлет-преобразования временных рядов электропотребления и метеофакторов, могут быть использованы для повышения производительности традиционных ИНС.

Вейвлет-нейронные сети (ВНС) представляют собой архитектуру радиально-базисных нейронных сетей с вейвлет-функциями, заключенными в вейвлет-нейронах, как показано на рис.7, где каждый нейрон имеет  $h$  входов со своей вейвлет-функцией  $\varphi$  и весом  $w$  [9].




Рис. 7. Архитектура вейвлет-нейросети

Как правило, строятся трехуровневые вейвлет-модели; при построении суммирующих узлов используются эволюционные вычислительные алгоритмы. В основном, первый слой вейвлет-узлов разлагает входные сигналы в различные масштабы сигналов, для которых различные весовые значения подаются на второй слой весовых узлов. Наконец, третий слой суммирующих узлов сочетает в себе взвешенные масштабы сигналов выходного слоя.

Вейвлет-нейросети обладают более высокой точностью, чем многослойные и самоорганизующиеся нейронные сети. По сравнению с радиально-базисными нейросетями имеются как преимущества, так и недостатки. Это, во-первых, большая усредненная погрешность вычисления средней ошибки прогноза, во-вторых, лучшая максимальная погрешность максимальной ошибки прогноза за весь период прогнозирования. Также следует отметить, что в практических расчетах ВНС имеют меньшую размерность, чем РБС, и, что весьма положительно для ВНС по сравнению с РБС, – это наличие в ВНС вейвлет-функции, что дает возможность изменять ее тип для подбора оптимальной точности вычисления [6].

#### Нечеткие нейронные сети

Нечеткая логика является обобщением обычной булевой логики, используемой для цифрового проектирования цепей. Нечеткое множество – это такое множество, которое содержит совокупность элементов произвольной природы. Причем относительно этих элементов нельзя с полной определенностью сказать – принадлежит или не принадлежит тот или иной элемент рассматриваемой совокупности данному множеству.

Вход по булевой логике приобретает значение “верно” или “неверно”. По нечеткой логике вход связан с определенными качественными диапазонами. Например, температура дня может быть “низкой”, “средней” или “высокой”. Нечеткая логика позволяет логически вывести выходы из нечетких входов. В этом смысле нечеткая логика является одним из нескольких методов для отображения входа к выходу. С такими правилами условий система нечеткой логики может быть очень эффективной при использовании для прогнозирования. Конечно, во многих ситуациях необходим точный (четкий) выход. В этом случае после логической обработки нечетких входов может быть использована “дефаззификация” для получения таких точных результатов. Нечеткие методы прогнозирования только имитируют рассуждения и суждения экспертов, они не предназначены для определения точной математической модели [9].

Структура ННС в общем виде представлена на рис. 8.




Рис.8. Структура искусственной нейронной сети с элементами нечеткой логики

Сеть состоит из трех слоев: входного, скрытого (слоя правил вида ЕСЛИ-ТО) и выходного слоя. На схеме нейроны, изображенные в виде кругов, представляют собой один узел, а нейроны (квадраты) имеют большее число

узлов. Каждая пара нейронов в скрытом слое составляет нечеткое правило.

Теория нечеткой логики подходит для описания широкого класса неопределенностей, и в то же время, она имеет мощную способность нелинейного отображения, которое может быть извлечено из большого количества данных.

Именно нечеткое управление оказывается наиболее полезным, в том случае если технологические процессы являются слишком сложными для анализа с помощью общепринятых количественных методов или когда исходная информация интерпретируется неточно, неопределенно. Нечеткая логика, на которой основано нечеткое управление, ближе по духу к человеческому мышлению и естественным языкам. Следует отметить, что системы, в которых применяется нечеткая логика, позволяют решать задачи принятия решений, распознавания образов, классификации данных и многие другие. Однако они не могут автоматически обучаться и приобретать новые знания. Для пользователя такие системы являются удобными еще и тем, что они позволяют ему видеть структуру системы нечеткого вывода и производить в ней необходимые изменения [4].

Системы нечеткого вывода являются продолжением экспертных систем. На их основе создаются оптимальные структуры упрощенного нечеткого вывода, которые минимизируют ошибки модели и количество функций принадлежности, для того чтобы понять нелинейное поведение кратковременных нагрузок. Однако системы нечеткого вывода нуждаются в опыте экспертов для генерации нечетких правил.

Искусственные нейронные системы и сети с нечеткой логикой практически эквивалентны друг другу. Это соображение легло в основу аппарата нечетких нейронных сетей. Основная идея нечетких нейронных сетей заключается в том, что используется существующая выборка данных для определения параметров функций принадлежности, которые лучше всего соответствуют некоторой системе логического вывода, то есть выводы делаются на основе аппарата нечеткой логики. А для нахождения параметров функций принадлежности используются алгоритмы обучения нейронных сетей. Такие системы могут использовать заранее известную информацию, обучаться, приобретать новые знания, прогнозировать временные ряды, и кроме этого они являются вполне наглядными для пользователя.

При этом модель прогнозирования нагрузки на основе нейро-нечеткой сети (ННС) дает дополнительные по сравнению с ИНС преимущества, в частности адаптация работы модели к типу дня недели (рабочий, выходной), простота настройки модели (не требуется, как в случае с ИНС, предварительные исследования по определению числа скрытых слоев и количества нейронов в этих слоях).

Процесс прогнозирования нагрузки может состоять из следующих этапов: подбор архитектуры нечеткой нейронной сети; выбор обучающих и тестовых данных; тренинг сети; тестирование сети на контрольном множестве данных; использование сети в качестве средства прогнозирования; возможное дообучение.

Результаты исследований показывают, что при хороших входных данных точность прогноза по моделям ИНС и ННС примерно одинакова. В случае плохих данных, когда график нагрузки не характерен для этого дня, точность прогноза с использованием моделей ННС много выше.

### *Эволюционные нейронные сети*

Среди методов, основанных на эволюционных алгоритмах известны методы, построенные с использованием генетических алгоритмов, роевого интеллекта и искусственных иммунных систем [8, 9].

Совместное использование эволюционных алгоритмов и ИНС позволяет решать задачи настройки и обучения ИНС как по отдельности, так и одновременно. Одним из достоинств такого синтезированного подхода является во многом унифицированный подход к решению разнообразных задач классификации, аппроксимации, управления и моделирования. Использование качественной оценки функционирования ИНС позволяет применять нейроэволюционные алгоритмы для решения задач исследования адаптивного поведения интеллектуальных агентов, поиска игровых стратегий, обработки сигналов.

### *Генетические алгоритмы*

Впервые идея использования генетических алгоритмов для обучения была предложена в 1970-е годы. Во второй половине 1980-х к этой идее вернулись в связи с обучением нейронных сетей. Использование механизмов генетической эволюции для обучения нейронных сетей кажется естественным, поскольку модели нейронных сетей разрабатываются по аналогии с мозгом и реализуют некоторые его особенности, появившиеся в результате биологической эволюции [8].

Генетический алгоритм (ГА) является рандомизированным, итерационным и эволюционным методом поиска для установления механизма естественного отбора и популяционной генетики. Методы, основанные на генетическом алгоритме, имеют способность глобальной оптимизации. Общий генетический алгоритм используется для оптимизации весов ИНС, с целью преодоления попадания в локальные минимумы погрешности, для улучшения точности прогнозов [9].

Генетические алгоритмы дают возможность оперировать дискретными значениями параметров нейронных сетей. Это упрощает разработку цифровых аппаратных реализаций нейронных сетей. При обучении на компьютере нейронных сетей, не ориентированных на аппаратную реализацию, возможность использования дискретных значений параметров в некоторых случаях может приводить к сокращению общего времени обучения.

Основные компоненты генетических алгоритмов – это стратегии репродукций, мутаций и отбор “индивидуальных” нейронных сетей (по аналогии с отбором индивидуальных особей).

Важным недостатком генетических алгоритмов является сложность для понимания и программной реализации. Однако преимуществом является эффективность в поиске глобальных минимумов адаптивных рельефов, так как в них исследуются большие области допустимых значений параметров нейронных сетей. Другая причина того, что генетические алгоритмы не застревают в локальных минимумах – случайные мутации, которые аналогичны температурным флуктуациям метода имитации отжига [8].

Наблюдается достаточно высокая скорость обучения при использовании генетических алгоритмов. Хотя скорость сходимости градиентных алгоритмов в среднем выше, чем генетических алгоритмов.

В рамках “генетического” подхода в последнее время разработаны многочисленные алгоритмы обучения



нейронных сетей, различающиеся способами представления данных нейронной сети в “хромосомах”, стратегиями репродукции, мутаций, отбора.

Несмотря на то, что методы ГА помогают решать проблемы оптимизации, в случае, если задача состоит из большого числа локальных оптимумов, решение ГА будет лишь приближено к глобальному оптимуму. Помимо этого, для поиска решения требуется длительный период обучения. А в случае, когда количество параметров растет, проблема оптимизации приобретает комплексный характер.

#### *Роевой интеллект*

Для устранения недостатков ГА известна архитектура нейронной сети на основе роевого интеллекта (РИ) для целей прогнозирования нагрузки. РИ – это новый эвристический метод, основанный на формировании взаимодействия и соперничества между частицами роя, который был разработан в качестве инструмента для инженерной оптимизации.

РИ – это алгоритм поиска наилучшего решения путем моделирования движения и взаимодействия птиц в стае. Алгоритм работает, произвольно помещая стаю птиц в пространство поиска, при этом каждая птица именуется “частица”. Эти “частицы” движутся с определенной скоростью и, взаимодействуя друг с другом, выбирая наилучшее положение. При каждой итерации частица может изменять вектор своей скорости на основе движущей силы и стремления этой частицы и соседних частиц занять более выгодное положение; по этим параметрам вычисляется новое положение, к которому летит “частица”.

Алгоритм РИ может использоваться для решения тех же задач, что и ГА, но не имеет основных недостатков ГА. По сравнению с ГА, все частицы роя быстрее сходятся к наилучшему решению. Успешное использование методов РЧ для решения нескольких задач оптимизации, таких как минимизация функции и построение структуры нейронной сети с прямой связью, продемонстрировало возможности данного алгоритма. Алгоритм РИ характеризуется высоким потенциалом для поиска самого оптимального результата. Однако, так как алгоритм РИ содержит несколько параметров, корректируемых путем эмпирического подхода, если эти параметры заданы некорректно, поиск будет протекать очень медленно в приближении к глобальному оптимуму.

#### *Искусственная иммунная система*

Особый интерес представляют искусственные иммунные системы (ИИС). Это относительно новая область исследования. Первые попытки разработки ИИС были предприняты в 70-х гг. XX в., масштабные работы начались в 90-х гг. XX в. [21].

Искусственные иммунные сети (ИИС) – информационные методологии, использующие понятия теоретической иммунологии для решения прикладных задач. ИИС – это адаптивные системы для обработки и анализа данных, которые представляют собой математическую структуру, имитирующую некоторые функции иммунной системы человека и обладающую такими свойствами, как способность к обучению, прогнозированию на основе имеющихся временных рядов и принятию решения в незнакомой ситуации. ИИС не нуждаются в заранее известной модели, а строят ее на основе полученной информации в виде временных рядов. Данные системы особенно хорошо подходят для решения плохо алгоритмизируемых задач, таких как прогнозирование нагрузки.

В искусственной иммунной системе в качестве описания взаимодействия компонентов системы (антител) используются меры аффинности, а в качестве механизмов адаптации – иммунные алгоритмы. Чтобы построить такую систему, необходимо знать область применения или целевую функцию. В [27] разработаны математические основы биологического подхода ИИС. Базовым элементом системы является пептид (белок). Биологическим прототипом ИИС являются иммунная система человека и обработка информации молекулами белков на основе результатов самосборки. В основу подхода ИИС положена идея взаимодействия между белками иммунной системы человека и чужеродными антигенами, т.е. возможность произвольного связывания (молекулярного узнавания) посредством определения минимальной энергии связи между формальными пептидами. Искусственная иммунная система обладает основными свойствами искусственного интеллекта – памятью, способностью к обучению и принятию решений в незнакомой ситуации.

При реализации интеллектуальных систем, основанных на указанных принципах, возникает ряд проблем. Основная трудность заключается в создании алгоритмов безошибочного распознавания образов, так как ошибки энергетических оценок не позволяют добиться стопроцентного распознавания. Так же как и в искусственных нейронных сетях, существует проблема создания эффективных и простых методик обучения ИИС. Необходимо из множества факторов уметь выделять главные, которые оказывают наибольшее влияние на процесс обработки информации, выделять информативные признаки, обучать ИИС и оценивать процесс обучения. Проблема значительно усложняется при увеличении размерности системы и времени на ее обучение. Следует также отметить, что в настоящее время ИИС в условиях реального времени для прогнозирования поведения и управления нестационарными, нелинейными, многомерными объектами с различными видами неопределенности параметров практически не разработаны.

### 2.3. КЛЕТочНЫЕ АВТОМАТЫ

В процессе описания физического явления при помощи совокупности дифференциальных уравнений происходит замена физической реальности, часто носящей дискретный характер (молекулы в газодинамике, элементарные заряды в электричестве и т. д.), непрерывной моделью. При переходе к разностным схемам пространство и время в этой непрерывной модели делаются вновь дискретными, а после реализации их на компьютере все величины рассматриваются с ограниченной точностью. Отсюда напрашивается вывод о том, что целесообразно сразу строить дискретные модели физических явлений. Одним из классов таких моделей являются клеточные автоматы.

Клеточные автоматы являются дискретными динамическими системами, поведение которых полностью определяется в терминах локальных зависимостей, в значительной степени так же обстоит дело для большого класса непрерывных динамических систем, определенных уравнениями в частных производных. В этом смысле клеточные автоматы в информатике являются аналогом физического понятия “поля”.

Клеточные автоматы изобретались много раз под разными названиями, и несколько отличающиеся друг от друга понятия употреблялись под одним и тем же названием. В чистой математике их можно обнаружить как один из

разделов топологической динамики, в электротехнике они иногда называются итеративными массивами.

Клеточный автомат представляет собой математическую модель физического процесса, в которой время и пространство дискретны (совокупность значений, принимаемых пространственными координатами, называется полем клеточного автомата), а все зависимые величины могут принимать конечный набор значений. Клеточный автомат обладает свойством локальности, т. е. на каждом временном шаге новое состояние некоторой точки зависит лишь от состояния точек в небольшой её окрестности. Кроме того, эта зависимость однородна в пространстве, и в каждой точке применяются одни и те же правила.

Клеточные автоматы образуют общую парадигму параллельных вычислений, подобно тому, как это делают машины Тьюринга для последовательных вычислений.

В обычных моделях вычислений, таких как машина Тьюринга, различают структурную часть компьютера, которая фиксирована, и данные, которыми компьютер оперирует; они являются переменными. Компьютер не может оперировать своей собственной “материальной частью”; он не может себя расширять или модифицировать, строить другие компьютеры. В клеточном автомате и объекты, которые могут быть интерпретированы как пассивные данные, и объекты, которые могут быть интерпретированы как вычислительные устройства, собираются из одного типа структурных элементов и подчиняются одним и тем же “мелкозернистым” законам; вычисление и конструирование являются просто двумя возможными типами активности.

Известные клеточные автоматы не обладают достаточным быстрым действием для моделирования неоднородных динамических систем в больших масштабах и на подробных сетках. Поэтому необходимо дальнейшее совершенствование данных методов для эффективного прогнозирования нагрузки распределительных сетей.

#### 2.4. МЕТОД ГРУППОВОГО УЧЕТА АРГУМЕНТОВ

В настоящее время большую популярность для задач прогнозирования приобретает, так называемый, метод группового учета аргументов (МГУА), представляющий собой дальнейшее развитие метода регрессионного анализа. Он основан на некоторых принципах теории обучения и самоорганизации, в частности на принципе “селекции”, или направленного отбора [8].

Метод реализует задачи синтеза оптимальных моделей высокой сложности, адекватной сложности исследуемого объекта (здесь под моделями понимается система регрессионных уравнений). Так, алгоритмы МГУА, построенные по схеме массовой селекции, осуществляют перебор возможных функциональных описаний объекта. Рассматриваются различные сочетания входных и промежуточных переменных, и для каждого сочетания строится модель, причем при построении рядов селекции используются самые регулярные переменные.

Понятие регулярности является одним из основных в методе МГУА. Регулярность определяется минимумом среднеквадратической ошибки переменных на отдельной проверочной последовательности данных (исходный ряд делится на обучающую и проверочную последовательности). В некоторых случаях в качестве показателя регулярности используется коэффициент корреляции. Ряды строятся до тех пор, пока регулярность повышается, т. е. сни-

жается ошибка или увеличивается коэффициент корреляции. Таким образом, из всей совокупности моделей выбирается такая, которая является оптимальной с точки зрения выбранного критерия.

#### 2.5. МЕТОД ОПОРНЫХ ВЕКТОРОВ

Метод опорных векторов (SVM – support vector machines) – это метод машинного обучения, целью которого является попытка классифицировать входные наборы данных в один из двух классов [2, 9].

Он построен на основе структурного принципа минимизации риска и теории размерности. Для эффективной работы метода сначала необходимо использовать обучающую выборку, состоящую из входных и выходных данных, которая необходима для построения модели метода опорных векторов, и которую в дальнейшем можно будет использовать для классификации новых данных. Метод опорных векторов позволяет получить функцию классификации с минимальной верхней оценкой ожидаемого риска (уровня ошибки классификации). Он также делает возможным использовать линейный классификатор для работы с нелинейно разделяемыми данными.

В последние годы при использовании метода опорных векторов новое развитие получил способ прогнозирования на основе регрессионных моделей, альтернативный интеллектуальному подходу. Для построения модели метода опорных векторов нужно взять обучающие входные данные, отобразить их в многомерное пространство, а затем использовать регрессию, чтобы найти гиперплоскость (поверхность в многомерном пространстве, которая разделяет его на два подпространства), которая лучше всего разделяла бы два класса входных данных. После обучения модели она способна классифицировать новые входные данные в один из классов при помощи разделяющей гиперплоскости.

По существу, метод опорных векторов является методом входов/выходов. Теоретически, число входов для метода опорных векторов лежит в диапазоне от одного до бесконечности. Однако, в практическом применении, есть определенные ограничения на размер входной выборки, которые зависят от вычислительной мощности.

Основное отличие опорных векторов от нейросетей заключается в том, что для нейросети количество настраиваемых коэффициентов должно априорно задаваться на основании некоторых эвристических соображений. В методе опорных векторов количество настраиваемых параметров автоматически определяется во время настройки и обычно меньше, чем число векторов в обучающей последовательности. Ненулевыми остаются коэффициенты у опорных векторов, с помощью которых строится разделяющая гиперплоскость.

В отличие от нейросети, которая находит лишь один из возможных способов разделения классов, который, не является оптимальным, метод опорных векторов заключается в построении разделяющей поверхности, наиболее удаленной от всех разделяемых точек. Преимуществом метода опорных векторов является то, что параметры регрессионной модели определяются на основе решения задачи квадратичного программирования, имеющей единственное решение.

Способность обобщения метода SVM делают его более эффективным по устойчивости модели, чем у искусственных нейронных сетей. Время сходимости алгоритма регрессии SVM при краткосрочном прогнозировании мень-

ше чем у искусственных нейронных сетей, алгоритм имеет более высокую точность прогнозирования и более просто определяется структура модели. Для этого не нужно слишком много предварительной информации и данных, что имеет значительные преимущества.

Таким образом, можно предположить, что качество распознавания с помощью опорных векторов должно быть выше, чем у нейронной сети. Критерий останова для обучения нейронной сети – нулевая ошибка на обучающем множестве, а критерий останова для метода опорных векторов – близость построенной разделяющей гиперплоскости к оптимальной. Прикладные исследования в области прогнозирования электрической нагрузки показывают перспективность и широкое применение SVM.

Ограничение использования метода опорных векторов связано с отсутствием рекомендаций по выбору параметров ядерной функции, наиболее подходящих для решения конкретной задачи. Недостатком метода опорных векторов также является неустойчивость по отношению к шуму в исходных данных.

## 2.6. МЕТОД ИНФОРМАЦИОННОЙ ПРОХОДКИ

Информационная проходка (ИП) (Data Mining) – особая междисциплинарная область анализа, раскрывающая свой потенциал в процессе поиска эмпирических закономерностей, опираясь на прикладную статистику, распознавание образов, теории баз данных и искусственного интеллекта. В узком смысле под ИП подразумеваются приемы, способы, алгоритмы извлечения (“добычи”, “раскопки”) новых, потенциально полезных свойств данных, процедуры выявления эмпирических закономерностей, взаимосвязей между переменными в больших массивах. Сюда можно отнести инструменты распознавания образов, регрессионного анализа, корреляционного анализа, факторного анализа, поиска ассоциаций, выбросов, аномалий в данных, а также специальные математико-статистические, эвристические алгоритмы и соответствующие им компьютерные программы.

Информационная проходка представляет собой процесс, который исследует информационные данные в большой базе данных, чтобы обнаружить правила, знания и т.д. Использование метода ИП для прогнозирования нагрузок основано на применении гибридной модели, включающей регрессию и искусственную нейронную сеть. В соответствии с данным методом диапазон изменения нагрузки разделяется на несколько классов и определяется к какому классу принадлежит прогнозируемая нагрузка в соответствии с правилами классификации. Затем многослойный перцептрон используется для обучения каждого класса [9].

В отличие от статистических методов, которые более сосредоточены на теоретической проверке гипотез, и нейронных сетей, основанных на эвристическом обучении агентов, в методах ИП происходит интеграция теории и эвристики, и концентрация на едином процессе анализа данных, который включает очистку данных, обучение, интеграцию и визуализацию результатов.

Поскольку данная технология является мультидисциплинарной областью, для разработки алгоритмов ИП необходимо задействовать специалистов из разных областей, а также обеспечить их качественное взаимодействие.

## 2.7. ХАОТИЧЕСКИЕ МЕТОДЫ

Как и классическая теория нелинейных колебаний, теория хаоса изучает поведение динамической системы с помощью фазового портрета. Однако, в теории колебаний фазовый портрет, строится на основе системы дифференциальных уравнений. В теории же хаоса изучаются объекты, для которых система уравнений не известна, и единственно доступной информацией о динамическом объекте является временной ряд. В этом случае по временному ряду может быть реконструирован фазовый портрет (аттрактор), топологические свойства которого совпадают со свойствами неизвестного нам объекта, который генерирует наблюдаемый ряд. Теоретической основой реконструкции фазовых портретов по временным рядам является специальный раздел теории хаоса, именуемый эмбедологией (embedology) [28, 29] (от англ. embedding – вложение), объединяющий элементы теории размерности, теории информации, топологии, дифференциальной динамики и теории динамических систем.

Точного определения понятию хаос не существует. Хаос можно характеризовать как крайнюю непредсказуемость постоянного нелинейного и нерегулярного сложного движения, возникающего в динамической системе [26].

Теория динамического хаоса построена на противопоставлении хаотичности и стохастичности (случайности). Динамика хаоса не случайна, хотя и полностью непредсказуема. Непредсказуемость хаоса можно объяснить зависимостью от начальных условий. Другими словами, даже самые малые ошибки при измерениях параметров системы могут привести к неверным предсказаниям и прогнозам. Эти ошибки, как правило, возникают из-за незнания абсолютно всех начальных условий.

Хаотические ряды только выглядят случайными, но, как детерминированный динамический процесс, вполне допускают краткосрочное прогнозирование. Невозможность делать долгосрочные прогнозы можно объяснить “эффектом бабочки”. Неточности в результате исследования и расчетов, на первый взгляд, не слишком существенные, могут привести к неверной работе системы. Таким образом, начальные условия оказывают огромное влияние на конечный результат.

Теория хаоса исследует порядок хаотической системы и затем строит модель такой системы для лучшего понимания поведения, не ставя перед собой задачу точного прогнозирования поведения хаотической динамической системы в будущем. Один из главных результатов теории хаоса, применительно к прогнозированию, можно описать так: “будущее предсказать невозможно, так как всегда будут ошибки измерения, порожденные, в том числе, и незнанием всех условий и факторов”.

## ЗАКЛЮЧЕНИЕ

Обзор современных методов прогнозирования нагрузок в распределительных сетях позволяет сделать следующий вывод: одного универсального, удовлетворяющего всем требованиям, не обладающего недостатками метода, прогнозирования не существует. Каждый подход и каждый метод имеют свои достоинства, недостатки, границы применения.

Так, к ограничениям аналитических методов относят трудоемкость и сложность вычислений, которые связаны



с необходимостью выбора и вычисления по отдельности для каждого параметра аналитического выражения, а также неточность результатов прогнозирования при неправильном выборе модели.

Для корректного использования регрессионного анализа требуется выполнение определенных условий. Факторные признаки должны быть заданы точно и некоррелированы, в их измерениях не должно быть автокорреляции и они должны быть однородны. Результирующий признак должен иметь постоянную дисперсию. Ограничением в применении линейных регрессионных моделей также является то, что между погодными переменными и нагрузкой существуют нелинейные зависимости.

Ко всем авторегрессионным моделям временных рядов предъявляются требования выполнения статистических критериев: критерий стационарности и случайности временного ряда (критерий серий), критерий значимости ковариационных и корреляционных матриц и т.п.

Метод экспоненциального сглаживания применяется, если моделируемый процесс имеет монотонный характер изменения без резких кратковременных скачков, а временной ряд процесса относится к коротким временным рядам с числом отсчетов до 100. Недостатками этого метода является невозможность прямого учета в модели действия конкретного влияющего фактора, а также необходимость использования прогнозирующих полиномов низкого порядка (первого, второго) из-за усложнения формул идентификации и отсутствия аналитически выведенных подобных формул.

Часть вероятностных методов эффективна, если полезный сигнал и помеха представляют собой стационарные, эргодические центрированные случайные функции. Другие алгоритмы становятся неустойчивым при постоянстве измеренных сигналов или расходятся при нестационарности или нелинейности моделируемого объекта и когда параметры уравнения объекта априори неизвестны или известны с малой точностью. Необходимо наличие оценок статистических характеристик моделируемого сигнала и помехи, более того такие характеристики должны быть неизменны для моделируемого процесса. Основное применение вероятностных методов - процессы линейные и имеют гауссовский характер с известными характеристиками, а входные возмущения и шумы не коррелированы между собой.

Общим недостатком искусственных нейронных сетей является проблема создания эффективных и простых методов обучения. Ограничением многослойной искусственной нейронной сети прямого распространения является большое количество нейронов, которые многократно участвуют в обработке данных. Кроме того для эффективной работы таких сетей требуются специальные условия, гарантирующие сходимость вычислений.

В эволюционных нейронных сетях, построенных с применением генетических алгоритмов, решение лишь приближено соответствует глобальному оптимуму. Помимо этого, для поиска решения требуется длительный период обучения. Роевые алгоритмы требуют точного задания их параметров, иначе поиск будет протекать очень медленно в приближении к глобальному оптимуму.

Основная трудность искусственных иммунных систем заключается в создании алгоритмов безошибочного рас-

познавания образов, так как ошибки энергетических оценок не позволяют добиться стопроцентного распознавания. Следует также отметить, что в настоящее время искусственные иммунные системы в условиях реального времени для прогнозирования поведения и управления нестационарными, нелинейными, многомерными объектами с различными видами неопределенности параметров практически не разработаны.

Известные клеточные автоматы не обладают достаточным быстродействием для моделирования неоднородных динамических систем в больших масштабах и на подробных сетках. Ограничение использования метода опорных векторов связано с отсутствием рекомендаций по выбору параметров ядерной функции, наиболее подходящих для решения конкретной задачи. Недостатком метода опорных векторов также является неустойчивость по отношению к шуму в исходных данных.

Таким образом, можно сделать вывод, что для эффективного решения задач прогнозирования нагрузок в распределительных сетях необходимо использовать комбинацию различных методов как традиционных, так и интеллектуальных.

#### ЛИТЕРАТУРА

1. Шумилова Г.П. Прогнозирование активной и реактивной нагрузки узлов ЭЭС с использованием инверсии искусственной нейронной сети / Г.П. Шумилова, Н.Э. Готман, Т.Б. Старцева // Управление электроэнергетическими системами – новые технологии и рынок: Сб. науч. тр. – Сыктывкар: Коми НЦ УрО РАН, 2004. – С. 115-122.
2. Поляхов Н.Д. Прогнозирование электропотребления на основе метода опорных векторов с использованием эволюционных алгоритмов оптимизации / Н.Д. Поляхов, И.А. Приходько, Е. Ван // Современные проблемы науки и образования. – 2013. – №2.
3. Об утверждении Правил оптового рынка электрической энергии и мощности и о внесении изменений в некоторые акты Правительства Российской Федерации по вопросам организации функционирования оптового рынка электрической энергии и мощности: Постановление Правительства РФ от 27 декабря 2010 г. № 1172.
4. Шумилова Г.П. Прогнозирование электрических нагрузок с применением методов искусственного интеллекта / Г.П. Шумилова, Н.Э. Готман, Т.Б. Старцева. – URL: <http://www.energy.komisc.ru/seminar/StShum1.pdf>. (дата обращения 12.12.2015).
5. Казаринов Л.С. Метод прогнозирования электропотребления промышленного предприятия / Л.С. Казаринов, Т.А. Барбасова и др. // Вестник Южно-Уральского государственного университета. Серия: Компьютерные технологии, управление, радиоэлектроника. – 2014. – Т. 14, №1. – С. 5-13.
6. Соловьева И.А. Прогнозирование электропотребления с учетом факторов технологической и рыночной среды / И.А. Соловьева, А.П. Дзюба // Научный диалог. – 2013. – №7(19).
7. Щелкалин В.Н. Трендовый и декомпозиционный подходы прогнозирования процессов потребления электроэнергии / В.Н. Щелкалин, А.Д. Тевяшев // Вост.-Европ. журн. передовых технологий. – 2011. – № 5/4. – С. 30-37.

8. Тихонов Э.Е. Методы прогнозирования в условиях рынка: учебное пособие. – Невинномысск, 2006.
9. Аль Зихери Баласим Мохаммед. Повышение точности краткосрочного прогнозирования электрической нагрузки потребителей региона с учётом метеофакторов на основе метода опорных векторов. дисс. ... канд. техн. наук. – Новочеркасск, 2015.
10. Шумилова Г.П. Прогнозирование нагрузки ЭЭС на базе новых информационных технологий / Г.П. Шумилова, Н.Э. Готман, Т.Б. Старцева // Новые информационные технологии в задачах оперативного управления электроэнергетическими системами: Сб. научн. тр. – Екатеринбург: УрО РАН, 2002. – С.127-156.
11. Чернецов В.И. Прогнозирование потребления электрической энергии с использованием нейронных сетей / В.И. Чернецов, Е.Н. Казаковский // Надежность и качество: Междунар. сб. научн. тр. – 2006. – Т. 1. – С. 199-201.
12. Alfares H.K. Electric load forecasting: literature survey and classification of methods / H.K. Alfares, M. Nazeeruddin // International Journal of Systems Science. – 2002. – Vol. 33, no.1. – P. 23-34.
13. Filik U.B. Hourly Forecasting of Long Term Electric Energy Demand Using a Novel Modeling Approach / U.B. Filik, O.N. Gerek, M. Kurban // Fourth International Conference on Innovative Computing, Information and Control (ICICIC). – 2009. – P. 115-118.
14. Ghods L. Different Methods of Long-Term Electric Load Demand Forecasting; A Comprehensive Review / L. Ghods, M. Kalantar // Iranian Journal of Electrical & Electronic Engineering. – 2011. – Vol. 7. – P. 249-259.
15. Paoletti S. Load forecasting for active distribution networks / S. Paoletti, M. Casini, A. Giannitrapani, A. Facchini, A. Garulli, A. Vicino // 2nd IEEE PES International Conference and Exhibition on Innovative Smart Grid Technologies (ISGT Europe). – 2011. – P. 1-6.
16. Манусов В.З. Краткосрочное прогнозирование электрической нагрузки на основе нечеткой нейронной сети и ее сравнение с другими методами / В.З. Манусов, Е.В. Бирюков // Изв. Томского политехнического университета. – 2006. – №6. – С. 153-158.
17. Пальчиков А.С. Существующие способы прогнозирования электропотребления объектов в металлургической отрасли // Современные научные исследования и инновации. – 2012. – №9. – URL: <http://web.snauka.ru/issues/2012/09/16877> (дата обращения 12.12.2015).
18. Галустов Г.Г. Статистические прогнозные математические модели: учебн. пособие. / Г.Г. Галустов, С.П. Бровченко, С.Н. Мелешкин. – Таганрог: ТТИ ЮФУ, 2011.
19. Taylor J.W. Triple seasonal methods for short-term electricity demand forecasting // European Journal of Operational Research. – 2010. – Vol. 204, no.1. – P. 139-152.
20. Christiaanse W.R. Short-Term Load Forecasting Using General Exponential Smoothing // Power Apparatus and Systems, IEEE Transactions on, V. PAS-90. – 1971. – no.2. – P. 900-911.
21. Самигулина Г.А. Разработка интеллектуальных экспертных систем прогнозирования и управления на основе искусственных иммунных систем // Теоретическая информатика. – 2009. – Вып. 4. – С. 15-22.
22. Hippert H.S. Neural networks for short-term load forecasting: a review and evaluation / H.S. Hippert, C.E. Pedreira, R.C. Souza // IEEE Trans. PAS. – 2001. – Vol. 16, no.1.
23. Чукреев Ю.Я. Прототип экспертной системы советчика диспетчера региональной ЭЭС // Новые информационные технологии в задачах оперативного управления электроэнергетическими системами: Сб. научн. тр. – Екатеринбург: УрО РАН, 2002. – С. 43-59.
24. Мошенский И.В. Прогнозирование электрических нагрузок промышленных предприятий с помощью радиально-базисных нейронных сетей / И.В. Мошенский, И.Л. Лебединский, В.С. Ноздренков // Вісник Сумського державного університету. – 2011. – №1. – С. 147-153.
25. Мошенский И.В. Прогнозирование электрических нагрузок промышленных предприятий с помощью вейвлет-нейронных сетей / И.В. Мошенский, И.Л. Лебединский, В.С. Ноздренков // Вісн. Сум. держ. ун-ту. Сер. Техн. науки. – 2011. – №3. – С. 53-58.
26. Ротштейн А.П. Нечётко – хаотическое прогнозирование временных рядов / А.П. Ротштейн, Д.И. Кательников // Оптико-електронні інформаційно-енергетичні технології. – 2014. – №1. – С. 42-55.
27. Tarakanov A.O. Formal peptide as a basic of agent of immune networks: from natural prototype to mathematical theory and applications // Proc. of the 1st Intern. workshop of Central and Eastern Europe on multi-agent systems. – 1999. – P. 123-127.
28. Takens F. Detecting strange attractor in turbulence. / F. Takens, D.A. Rand, L.S. Young. – Berlin: Springer, 1981.
29. Sauer T. Embedology / T. Sauer, J.A. Yorke, M. Casdagli // J. Stat Phys. – 1991. – Vol. 65. – P. 579-616.

# Forecasting Methods in Electricity Distribution Networks (review)

Abdurahmanov A.M., Volodin M.V., Zybin E.Yu.

R&D Center FGS UES  
Moscow, Russian Federation  
[abdurahmanov@ntc-power.ru](mailto:abdurahmanov@ntc-power.ru)

Ryabchenko V.N.

Bauman Moscow State Technical University  
Moscow, Russian Federation  
[ryabchenko.vn@gmail.com](mailto:ryabchenko.vn@gmail.com)

**Abstract.** A review of the methods used in practice in forecasting electricity distribution networks. All variety of forecasting methods of electricity is divided into classical and intelligent. The classic methods of forecasting attributed regression, autoregressive and probabilistic methods. Intelligent forecasting techniques combine expert systems, artificial neural networks, cellular automata, chaotic processes, and others. Analyzes the domain of applicability, advantages and disadvantages of methods of forecasting energy consumption.

**Keywords:** power distribution networks, power consumption, forecasting methods, regression methods, probabilistic methods, intellectual methods.

## REFERENCES

1. Shumilova G.P., Gotman N.E., Startseva T.B. Prediction of active and reactive load nodes EPS using an artificial neural network inversion [Prognozirovaniye aktivnoy i reaktivnoy nagruzki uzlov EES s ispolzovaniyem inversii iskusstvennoy neyronnoy seti], *Upravleniye elektroenergeticheskimi sistemami – novyye tekhnologii i rynok [Power systems management - new technologies and market]*, Syktyvkar, Komi NTs UrO RAN, 2004, pp. 115-122. (in Russ.)

2. Polyakhov N.D., Prikhodko I.A., Van Ye. Forecasting electricity consumption based on support vector using evolutionary optimization algorithms [Prognozirovaniye elektropotrebleniya na osnove metoda opornykh vektorov s ispolzovaniyem evolyutsionnykh algoritmov optimizatsii], *Sovremennyye problemy nauki i obrazovaniya [Modern problems of science and education]*, 2013, no.2. (in Russ.)

3. Russian Federation Government Resolution. *Ob utverzhdenii Pravil optovogo rynka elektricheskoy energii i moshchnosti i o vnesenii izmeneniy v nekotorye akty Pravitel'stva Rossiyskoy Federatsii po voprosam organizatsii funktsionirovaniya optovogo rynka elektricheskoy energii i moshchnosti* [On approval of the wholesale market of electric power and capacity of the Rules and on Amendments to Certain Acts of the Government of the Russian Federation on the issues of functioning of the wholesale electricity and capacity market], 2010, no.1172. (in Russ.)

4. Shumilova G.P., Gotman N.E., Startseva T.B. Prediction of electrical loads using artificial intelligence techniques [Prognozirovaniye elektricheskikh nagruzok s primeneniym metodov iskusstvennogo intellekta]. Available at: <http://www.energy.komisc.ru/seminar/StShum1.pdf>. (accessed 12 December 2015). (in Russ.)

5. Kazarinov L.S., Barbasova T.A. i dr. The prediction method of electricity for industrial enterprises, *Bulletin of the South Ural State University. Ser. Computer technology, control, radio electronics*, 2014, no.1 (14), pp. 5-13. (in Russ.)

6. Solovyeva I.A., Dzyuba A.P. Forecasting electricity consumption, taking into account the factors of technological and market environment [Prognozirovaniye elektropotrebleniya s uchedom faktorov tekhnologicheskoy i rynochnoy sredy], *Nauchnyy dialog [Scientific dialogue]*, 2013, no.7(19). (in Russ.)

7. Shchelkalin V.N., Tevyashev A.D. Trend decomposition approaches and forecasting processes in electricity consumption [Trendovyy i dekompozitsionnyy podkhody prognostirovaniya protsessov potrebleniya elektroenergii], *Vost.-Yevrop. zhurn. peredovykh tekhnologiy [Eastern European advanced technology magazine]*, 2011, no.5/4, pp. 30-37. (in Russ.)

8. Tikhonov E.Ye. *Metody prognostirovaniya v usloviyakh rynka: uchebnoye posobiye* [Forecasting methods in market conditions: study guide], Nevinnomyssk, 2006. (in Russ.)

9. Al Zikheri Balasim Mokhammed. *Povysheniye tochnosti kratkosrochnogo prognostirovaniya elektricheskoy nagruzki potrebiteley regiona s uchedom meteofaktorov na osnove metoda opornykh vektorov. diss. ... kand. tekh. nauk* [Improving the accuracy of short-term forecasting of electric load consumers in the region taking into account the meteorological factors based on support vector. diss. ... Cand. tekh. sciences], Novocherkassk, 2015. (in Russ.)

10. Shumilova G.P., Gotman N.E., Startseva T.B. The load forecasting power system on the basis of new information technologies [Prognostirovaniye nagruzki EES na baze novykh informatsionnykh tekhnologiy], *Novyye informatsionnyye tekhnologii v zadachakh operativnogo upravleniya elektroenergeticheskimi sistemami [New information technologies in problems of operational management of power systems]*, Yekaterinburg, UrO RAN, 2002, pp. 127-156. (in Russ.)

11. Chernetsov V.I., Kazakovskiy Ye.N. Forecasting electricity consumption by using neural networks [Prognostirovaniye potrebleniya elektricheskoy energii s ispolzovaniyem neyronnykh setey], *Nadezhnost i kachestvo [Reliability and quality]*, 2006, (1), pp. 199-201. (in Russ.)

12. Alfares H.K., Nazeeruddin M. Electric load forecasting: literature survey and classification of methods, *International Journal of Systems Science*, 2002, no.1(33), pp. 23-34.

13. Filik U.B., Gerek O.N., Kurban M. Hourly Forecasting of Long Term Electric Energy Demand Using a Novel Modeling Approach, *Fourth International Conference on Innovative Computing, Information and Control (ICICIC)*, 2009, pp. 115-118.

14. Ghods L., Kalantar M. Different Methods of Long-Term Electric Load Demand Forecasting; A Comprehensive Review, *Iranian Journal of Electrical & Electronic Engineering*, 2011, (7), pp. 249-259.



15. Paoletti S., Casini M., Giannitrapani A., Facchini A., Garulli A., Vicino A. Load forecasting for active distribution networks, *2nd IEEE PES International Conference and Exhibition on Innovative Smart Grid Technologies (ISGT Europe)*, 2011, pp. 1-6.

16. Manusov V.Z., Biryukov Ye.V. Short-term forecasting of electric load based on fuzzy neural network and its comparison with other methods, *Bulletin of the Tomsk Polytechnic University*, 2006, no.6, pp. 153-158. (in Russ.)

17. Palchikov A.S. Existing methods for forecasting electricity facilities in the steel industry [Sushchestvuyushchiye sposoby prognozirovaniya elektropotrebleniya obyektov v metallurgicheskoy otrasli], *Sovremennyye nauchnyye issledovaniya i innovatsii [Modern scientific research and innovation]*, 2012, no.9. Available at: <http://web.snauka.ru/issues/2012/09/16877>. (accessed 12 December 2015). (in Russ.)

18. Galustov G.G., Brovchenko S.P., Meleshkin S.N. *Statisticheskiye prognoznyye matematicheskiye modeli: uchebn. posobiye* [Statistical predictive mathematical models: study guide], Taganrog, TTI YuFU, 2011. (in Russ.)

19. Taylor J.W. Triple seasonal methods for short-term electricity demand forecasting, *European Journal of Operational Research*, 2010, no.1(204), pp. 139-152.

20. Christiaanse W.R. Short-Term Load Forecasting Using General Exponential Smoothing, *Power Apparatus and Systems, IEEE Transactions on*, V. PAS-90, 1971, no.2, pp. 900-911.

21. Samigulina G.A. Developing intelligent expert forecasting and management systems based on artificial immune systems [Razrabotka intellektualnykh ekspertnykh sistem prognozirovaniya i upravleniya na osnove iskusstvennykh immunnykh sistem], *Teoreticheskaya informatika [Theoretical computer Science]*, 2009, (4), pp. 15-22. (in Russ.)

22. Hippert H.S., Pedreira C.E., Souza R.C. Neural networks for short-term load forecasting: a review and evaluation, *IEEE Trans. PAS*, 2001, no.1(16).

23. Chukreyev Yu.Ya. A prototype expert system advisor Regional Manager of EPS [Prototip ekspertnoy sistemy so-vetchika dispetchera regionalnoy EES], *Novyye informatsionnyye tekhnologii v zadachakh operativnogo upravleniya elektroenergeticheskimi sistemami [New information technologies in problems of operational management of power systems]*, Yekaterinburg, UrO RAN, 2002, pp. 43-59. (in Russ.)

24. Moshenskiy I.V., Lebedinskiy I.L., Nozdrenkov V.S. Prediction of electrical loads of industrial enterprises with the help of radial-basis neural networks [Prognozirovaniye elektricheskikh nagruzok promyshlennykh predpriyatiy s pomoshchyu radialno-bazisnykh neyronnykh setey], *Visnik Sumskogo derzhavnogo universitetu [News Sumskogo sovereign universitetu]*, 2011, no.1, pp. 147-153. (in Russ.)

25. Moshenskiy I.V., Lebedinskiy I.L., Nozdrenkov V.S. Prediction of electrical loads of industrial enterprises c using wavelet neural networks [Prognozirovaniye elektricheskikh nagruzok promyshlennykh predpriyatiy c pomoshchyu veyvlet-neyronnykh setey], *Visn. Sum. derzh. un-tu. Ser. Tekhn. nauki [Visn. Sum. Keep. the University. Ser. Tech. science]*, 2011, no.3, pp. 53-58. (in Russ.)

26. Rotshteyn A.P., Katelnikov D.I. Fuzzy - chaotic time series prediction [Nechetko – khaoticheskoye prognozirovaniye vremennykh ryadov], *Optiko-yelektronni informatsiyno-yenergetichni tekhnologii [Optical elektronni informatsiyno-energetichni tehnologii]*, 2014, no.1, pp. 42-55. (in Russ.)

27. Tarakanov A.O. Formal peptide as a basic of agent of immune networks: from natural prototype to mathematical theory and applications, *Proc. of the 1st Intern. workshop of Central and Eastern Europe on multi-agent systems*, 1999, pp. 123-127.

28. Takens F., Rand D.A., Young L.S. *Detecting strange attractor in turbulence*, Berlin, Springer, 1981.

29. Sauer T, Yorke J.A., Casdagli M. Embedology, *J. Stat Phys.*, 1991, (65), pp. 579-616.

---

#### Библиографическое описание статьи

Абдурахманов А.М. Методы прогнозирования электропотребления в распределительных сетях (обзор) / Абдурахманов А.М., Володин М.В., Зыбин Е.Ю., Рябченко В.Н. // *Электротехника: сетевой электронный научный журнал*. – 2016. – Т.3, №1. – С. 3-23.

#### Reference to article

Abdurahmanov A.M., Volodin M.V., Zybin E.Yu., Ryabchenko V.N. Forecasting methods in electricity distribution networks (review), *Russian Internet Journal of Electrical Engineering*, 2016, vol.3, no.1, pp. 3-23.