

О.В. Гринавцев, В.И.Литвиненко, А.А.Фефелов, В.Г.Шерстюк

МЕТОД СИНТЕЗА НЕЙРОННЫХ СЕТЕЙ С ПОМОЩЬЮ ИММУННЫХ СИСТЕМ ДЛЯ РЕШЕНИЯ ЗАДАЧ ПРОГНОЗИРОВАНИЯ ЭНЕРГОПОТРЕБЛЕНИЯ

1. Введение

Одним из недостатков деятельности областных энергопредприятий является отсутствие эффективной модели энергоснабжения потребителей [1]. Это в свою очередь не позволяет на должном уровне управлять режимами работы электростанций, а это влечет за собой, увеличение расхода топлива, рост потерь энергии. Прогнозирование режимов (нагрузки) энергопотребления играет ключевую роль в обеспечении экономной и безопасной работы электроэнергетической системы. Выполнение многих диспетчерских функций – таких, как выбор состава включенных агрегатов и назначение им заданий, координация работы гидро-, тепловых и атомных станций, оценка надежности энергосистемы в в любой момент времени, а также возможных межсистемных перетоков энергии – требует надежного предсказания нагрузки. Ошибки предсказания оборачиваются экономическими потерями. Недооценка ожидаемой нагрузки приводит к необходимости использования дорогих пиковых станций. Завышенное предсказание выливается в увеличение издержек на поддержание в рабочем состоянии излишних резервных мощностей. Эффективность мероприятий по управлению энергопотреблением, качество планирования и экономичность режимов работы энергосистемы определяется достоверностью прогноза. Повышение точности прогноза энергопотребления обеспечивает экономию энергоресурсов и увеличение прибыли энергопредприятий.

2. Анализ последних исследований

В соответствии с [2], прогнозирование нагрузки относится к такому классу задач, где зависимость между входными и выходными переменными сложна, а нахождение закономерностей в больших объемах данных требует нетривиальных алгоритмов и занимает много времени. На настоящий момент спектр методик прогнозирования

достаточно широк. Сегодня все большее распространение получают нетрадиционные методы, связанные с использованием искусственных нейронных сетей. При решении задач прогнозирования нейронными сетями используется метод окон. Окно, представляет собой некоторое подмножество ретроспективных данных, способно перемещаться с некоторым шагом по временной последовательности исторических данных энергопотребления и формировать обучающую выборку для нейронной сети. Нейронная сеть, обучаясь на имеющихся данных, пытается извлечь закономерности и сформировать в результате требуемую функцию прогноза.

3. Постановка проблемы

По оценкам зарубежных и отечественных систематиков прогнозистики, уже насчитывается свыше 100 методов прогнозирования [3,4].

Поведение энергетических систем в условиях воздействия множества случайных возбуждений различного характера часто характеризуется возникновением нестационарных процессов в этих системах. Нестационарности сопровождаются также нелинейностями, что требует разработки и применения нестандартных подходов для моделирования и прогнозирования. Для обеспечения высокой адекватности создаваемых моделей необходим критический анализ используемых моделей. С другой стороны, улучшение качества прогнозов энергопотребления можно достичь, посредством применения методов построенных на вычислительной парадигме искусственных нейронных сетей. Однако, например, при использовании классических методов, таких как Бокса-Дженкинса (авторегрессии - скользящего среднего), фильтр Калмана и др. основные проблемы связаны с неоднородностью временных рядов, с другой стороны методы, реализованные на нейросетевом базисе связаны с неопределенностью в выборе числа слоев и количества нейронных элементов в слое, медленная сходимость градиентного метода с постоянным шагом обучения, влияние случайной инициализации весовых коэффициентов и т.д. В связи с этим основной целью в данной работе является разработка и реализация методики прогнозирования энергопотребления. Мы полагаем, что разработанная нами технология должна обеспечивать построение адекватных математических моделей процессов энергопотребления и

выбор лучшего прогноза с помощью множества статистических критериев. Для решения поставленной задачи необходимо разработать метод синтеза предиктора на основе искусственных нейронных сетей, осуществляющего предсказание электрической нагрузки по данным предварительных наблюдений. Синтезированный предиктор позволяет прогнозировать нагрузку на выбранный конечным пользователем период.

4. Методы решения

Для решения поставленной задачи нами был разработан подход, основанный на механизмах искусственной иммунной сети [5-7]. Суть метода состоит в синтезе нейроподобных структур для дальнейшего их использования как предикторов прогнозирования энергопотребления в областных энергосистемах. Искусственные нейронные сети представляют собой вычислительные устройства, которые состоят из множества простых соединенных между собой блоков (нейронов), работающих параллельно. Соединения между блоками или узлами обычно взвешиваются с помощью вещественных значений. Веса – это первичный способ обучения в нейронных сетях, и алгоритм обучения обычно используется для настройки весов. Структурно, нейронная сеть имеет три различных класса слоев: входной, скрытый и выходной. Сигнал подается на входной слой и распространяется в прямом направлении от входных нейронов через один или более скрытых слоев к выходному слою. Сигнал, приходящий в слой из других слоев, умножается на веса связей, по которым он распространяется. Весь входящий сигнал затем сводится вместе и нейрон активизируется только, если значение сигнала превысит значение пороговой величины нейрона. Таким образом, основными элементами нейронной сети являются нейроны, веса и пороговые величины. Данные элементы, содержатся в строке антитела, кодирующей нейронную сеть, которая может адаптироваться в выбранном окружении. Полученная антигенная структура может эволюционировать, используя механизмы иммунной сети и обнаруживать новые решения в виде нейронных сетей. Кроме того, по информации, предоставляемой строкой антитела, нейронная сеть может быть полностью восстановлена и пригодна для дальнейшего использования.

4.1. Иммунные принципы

Иммунную систему часто называют “вторым мозгом позвоночных животных” [6]. Она обладает всеми главными особенностями искусственного интеллекта (ИИ): памятью, способностью обучаться, умением распознавать и принимать решения как рассматривать любой чужеродный белок (антиген), даже если последний никогда не существовал прежде на Земле. Основываясь на биологических принципах иммунной системы, в настоящее время возникла быстро развивающаяся область – искусственные иммунные системы (ИИС), которые предлагают мощные и устойчивые возможности в обработке информации для решения сложных задач. Подобно искусственным нейронным сетям, ИИС могут изучать новую информацию, используя уже предварительно изученную и осуществлять распознавание образов высоко децентрализованным способом.

4.2. Иммунная инженерия

Для проектирования искусственных иммунных систем в вычислительном отношении требуется наличие, по крайней мере, следующих основных элементов:

- способ представления компонентов системы;
- процедуры адаптации, которые управляют динамикой системы, т.е. изменением ее состояния во времени.
- множество механизмов позволяющих оценить взаимодействие индивидуумов с окружающей средой и друг с другом.

Окружающая среда обычно моделируется набором входных стимулов, одной или более функций пригодности, или другим критерием. Основной структурой, для проектирования искусственных иммунных систем также является: представление, позволяющие создавать абстрактные (искусственные) модели иммунных органов, клеток и молекул; набор функций, которые называются функциями аффинности, позволяющих определять количественные взаимодействия этих “искусственных элементов”, и множество общих алгоритмов достижения цели для управления динамикой ИИС. Что касается теории иммунной сети, то ее центральной характеристикой является определение молекулярного тождества индивидуумов (внутреннего образа), которое возникает вследствие сетевой организации, сопровождаемой обучением молекулярного состава среды, в которой развивается система [7-8]. Фактически, такие

динамические структуры являются представлением определенного типа памяти, которая не локализована в памяти клеток, а распределена как структура. Сетевой подход особенно интересен для развития компьютерных инструментальных средств, потому что он потенциально обеспечивает точную учетную запись свойств на стадии становления типа обучения и памяти, самотолерантности, управления размером и разнообразием популяции клеток. В общем виде, структура большинства моделей иммунных сетей может быть представлена так:

$$\begin{array}{ccccccc} \text{Уровень} & & & & & & \\ \text{изменения} & = & \text{Стимуляция} & - & \text{Супрессия} & + & \text{Поступление} \\ \text{популяции} & & \text{сети} & & \text{сети} & & \text{новых} \\ & & & & & & \text{элементов} \\ & & & & & & - & \text{Гибель} \\ & & & & & & & \text{нестимулируемых} \\ & & & & & & & \text{элементов} \end{array}$$

Рисунок 1 - Обобщенная модель иммунной сети

Последний термин включает Ab-Ab распознавание и Ag-Ab возбуждение. Это позволяет создавать связанные сети, состоящие из иммунных клеток. Когда иммунная клетка распознает антиген или другую иммунную клетку она стимулируется. С другой стороны, когда иммунная клетка распознается другой иммунной клеткой, она подавляется. Сумма возбуждений и подавлений (супрессий), полученных клетками сети, плюс возбуждение распознанным антигеном соответствует S-уровню возбуждения клетки, который описывается уравнением:

$$S = N_{stim} - N_{sup} + A_{init} \quad (1)$$

N_{stim} – соответствует возбуждению сети; N_{sup} – соответствует супрессии (подавлению) сети; A_{init} – соответствует уровню возбуждения антигена.

Уровень возбуждения иммунной клетки позволяет определить вероятность ее воспроизводства и генетической изменчивости. Существует два основных вида иммунной сети: непрерывный и дискретный. Непрерывные модели иммунных сетей описываются при помощи систем дифференциальных уравнений, каждое из которых соответствует изменению численности и аффинности иммунных клеток. Дискретные иммунные сети управляются уравнениями, которые используются в итерационных процедурах адаптации, изменяя число и аффинность клеток. Обобщенный алгоритм иммунной сети представлен на рисунке 2.

4.3. Иммуные и биологические компоненты их представление и характеристика

4.3.1. Синтез аппроксимирующих конструкций при помощи иммунной сети

Стандартная иммунная сеть (ИС) оперирует строками данных и используется для решения задач классификации, распознавания и оптимизации. Каждая строка данных (антитело) представляет собой одно решение поставленной задачи. В классическом варианте задачи оптимизации сводились к поиску решений в многомерном пространстве с наперед заданной целевой функцией. Решением такой задачи является набор (картеж) переменных, подстановка которых в целевую функцию дает оптимальное значение. В иммунной сети, предназначенной для решения задач аппроксимации, антитела представляют собой не просто вектор переменных, а связанные конструкции, которые можно рассматривать как деревья аналитической зависимости или как компьютерные программы. Причем в первом случае зависимость чаще всего задается в табличной форме. Например, когда требуется свести воедино результаты серии экспериментов и получить зависимость выхода эксперимента от его входа.

- 1. Инициализация:** создание сети иммунных клеток.
- 2. Популяционный цикл:** для каждого антигена выполнить:
 - 2.1. Распознавание антигена:** определить соответствие каждой клетки сети антигену
 - 2.2. Взаимодействие сети:** определить взаимодействующие друг с другом клетки сети
 - 2.3. Метадинамика:** введение новых клеток в сеть и удаление бесполезных (основываясь на некотором критерии).
 - 2.4. Уровень возбуждения:** определить уровень возбуждения каждой клетки сети (по уравнению 1), принимая во внимание результаты, полученные на шаге 2.1, 2.2, 2.3.
 - 2.5. Динамика сети:** модернизация структуры сети согласно уровню возбуждения отдельных клеток.
- 3. Цикл:** повторять Шаг 2, до тех пор, пока не будет достигнут заданный критерий останова.

Рисунок 2 – Обобщенный алгоритм искусственной иммунной сети

Кодирование антител. Все антитела аппроксимирующей ИС представляют собой строки фиксированной длины, состоящие из символов. Символы выбираются из конечного алфавита символов, который в свою очередь состоит из двух частей: функционального алфавита и терминального алфавита. Символьная строка антитела есть не что иное, как последовательная запись древовидной структуры, отображающей математическую зависимость и использующей в качестве символов функционального алфавита знаки математических операций и функций: $\{+, -, *, \sqrt{}, \sin, \cos\}$. В данном множестве буквы Q, S и C означают соответственно операцию взятия квадратного корня, функцию синуса и косинуса. В качестве терминальных символов используются символы, обозначающие переменные-аргументы функции и специальный символ константы «?»: $\{?, a, b, c, d, \dots\}$. Дерево преобразуется в строку путем последовательной записи всех узлов и листьев, начиная с корневого узла слева направо и сверху вниз (рис. 2).

(a) $f(a, b, c, d) = (a - b) * (c + d)$

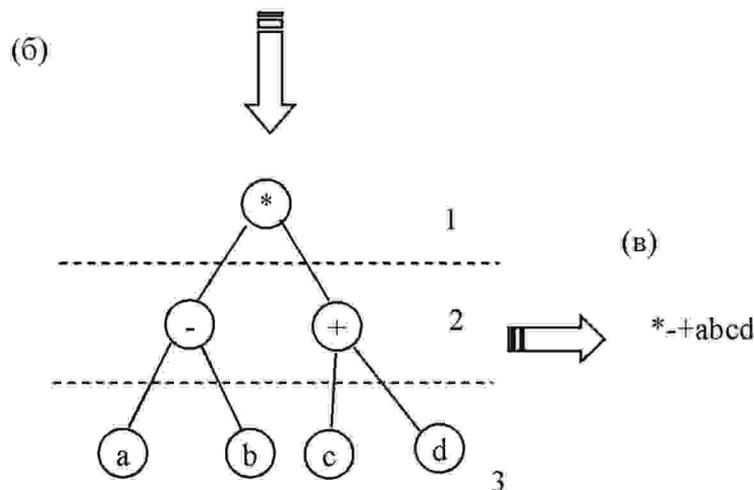


Рисунок 3 – Преобразование математической формулы в символьную строку антитела. (а) – исходная формула; (б) – дерево выражения, разделенное по уровням; (в) – последовательная запись элементов уровней в строку.

Начальная популяция антител создается случайным образом, т.е. строки символов инициализируются символами из функционального и терминального алфавита. Во избежание построения неправильных выражений строки символов делятся условно на две части: голову и хвост. Голова может содержать как терминальные, так и

функциональные символы, хвост – только терминальные символы. Идея заключается в том, чтобы избежать ситуации, синтаксически неправильного выражения, даже в том случае, когда голова полностью состоит из функциональных символов. На этой основе вычисляется общая длина антитела:

$$t = h(n - 1) + 1, \quad (2)$$

где t – общая длина индивидуума; h – длина головы; n – максимальное количество аргументов используемых в функциональном наборе. В нашем случае $n=3$.

4.3.2. Синтез нейроподобных структур при помощи иммунных сетей

Нейронная сеть со всеми ее элементами является довольно сложной структурой, которую нелегко конструировать и обучать. Некоторые исследователи применяли усложненные алгоритмы, в которых ГА использовался для настройки отдельных параметров нейронных сетей, таких как веса, структура сети или обучающий алгоритм [9,10]. Используя приведенное выше представление, можно полностью закодировать нейронные сети различных размеров и форм в линейные антитела фиксированной длины. В дальнейшем, эти сложные структуры будут полнофункциональными, т.е. они смогут адаптироваться в конкретном окружении и, будут выбираться согласно аффинности. А это значит, что популяции с данными объектами могут использоваться для исследования областей в пространстве поиска и, таким образом решать задачи в различных предметных областях. В данном случае строение нейронной сети кодируется по схожей схеме с головой и хвостом. Голова содержит специальные функции, которые в контексте нейронных сетей соответствуют скрытым и выходным нейронам (функциональные блоки) и терминальные блоки, которые представляют собой входные нейроны. Хвост содержит только терминальные блоки. Кроме головы и хвоста эти индивидуумы (антитела, представляющие собой нейронные сети или НС-антитела) содержат два дополнительных домена, D_w и D_t , кодирующих, соответственно, веса и пороговые значения. Структурно D_w следует за хвостом и имеет длину d_w , равную $h*n$, в то время как D_t имеет длину d_t , равную h . Оба домена содержат символы, представляющие веса и пороговые значения нейронной сети. Для каждого НС-антитела веса и пороговые

значения создаются в начале каждого запуска алгоритма, но их перебор гарантируется эволюционными операторами. Для этой цели оператор мутации был адаптирован таким образом, чтобы постоянно поддерживать разнообразие во множестве весов и пороговых значений. Стоит подчеркнуть, что основные генетические операторы, такие как мутация, IS и RIS транспозиция, работающие с доменами Dw и Dt , никогда не выходят за их границы и поэтому не смешивают алфавиты символов различных частей строки антитела.

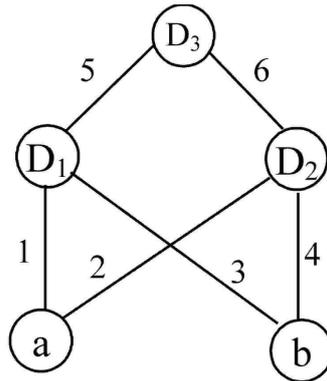


Рисунок 4 – Структура простейшей нейронной сети

Для примера рассмотрим нейронную сеть (рис. 3) с двумя входными нейронами (a и b), двумя скрытыми нейронами (D_1 и D_2), и одним выходным нейроном (D_3) (для упрощения все пороговые значения приняты равными 1 и не указаны). Данная структура может быть представлена в виде дерева (рис. 4).

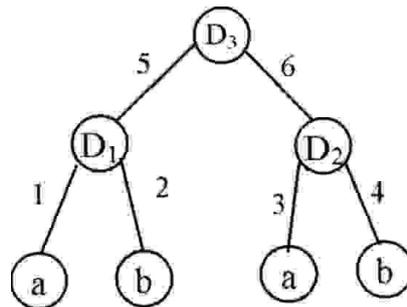


Рисунок 5 – Та же нейронная сеть, представленная в виде дерева

Узлы D_1 , D_2 и D_3 могут функционировать как обычные нейроны, реализуя активационную функцию вида: $y_{D_i} = f(w_1a + w_2b)$. В этой формуле w_1 и w_2 соответственно веса первого и второго потомков функционального узла. Далее мы можем представить вышеуказанное НС-дерево в виде строки следующим образом (рис. 5):

$D_3D_1D_2abab654321$

Рисунок 6 – Представление нейронной сети в виде строки антитела

Часть строки, состоящая из цифр, расположенных в конце антитела используется для кодирования весов. Эти цифры означают индексы реальных значений весов в массиве весов, создающемся вначале работы алгоритма. Этот массив может выглядеть примерно так:

$$W = \{-1.14, 2.3, 0.0, 0.77, -0.9, 3.5\};$$

Во время оценки антитела в синтезированную нейронную сеть вместо индексов, подставляются реальные значения весов и порогов, взятые из соответствующих массивов. В результате получается полностью определенная нейронная сеть, качество которой определяется качеством аппроксимации табличных данных.

4.4. Структура иммунной сети, динамика и метадинамика

Иммунная сеть математически может быть представлена в виде графа, который состоит из множества узлов (клетки сети) и множества взвешенных ребер, означающих связи между клетками. Значение веса ребра соответствует силе связи клеток друг с другом (т.е. близости или степени комплементарности клеток), называемой аффинностью. В иммунных сетях различают два вида аффинности:

- аффинность связи «антиген-антитело» (*Ag-Ab affinity*) – степень различия;
- аффинность связи «антитело-антитело» (*Ab-Ab affinity*) – степень близости.

Формально алгоритм иммунной сети можно представить следующим образом:

$$immNET = (X, C, M, N_C, D, S, n, \zeta, \sigma_d, \sigma_s),$$

где

X - набор данных, состоящий из N_p векторов размерности p – популяция антигенов;

C - матрица, содержащая все клетки (антитела) сети ($C \in \mathbb{R}^{N_i \times p}$) – популяция антител;

M - матрица, состоящая из N клеток памяти ($M \subseteq C$);

N_C - общее количество клонов, создаваемых стимулируемыми клетками в каждом поколении (при активации сети);

D - матрица элементов d_{ij} *Ag-Ab* аффинностей;

S - матрица элементов s_{ij} $Ab-Ab$ аффинностей;

n - количество лучших клеток, отбираемых из C для клонирования и мутации;

ζ - процент улучшенных клеток, отбираемых из популяции клонов для последующей обработки;

σ_d - пороговый коэффициент гибели или стимуляции клетки в зависимости от ее $Ag-Ab$ аффинности;

σ_s - пороговый коэффициент сжатия сети;

Алгоритм работает следующим образом:

1. Случайным образом сгенерировать сеть C ;

2. Цикл для каждого поколения:

2.1. Цикл для каждого антигена x_i :

2.1.1. Вычислить $Ag-Ab$ аффинность (с антигеном x_i) всех клеток сети C , занести ее в матрицу D ;

(2.1.2 – 2.1.5. - Динамика)

2.1.2. Выбрать n (или $n\%$) лучших (с максимальной $Ag-Ab$ аффинностью) клеток сети;

2.1.3. Клонировать выбранные клетки. Количество клонов каждой клетки сети пропорционально ее $Ag-Ab$ аффинности: выше аффинность (лучше клетка) – больше клонов;

2.1.4. Подвергнуть мутации все полученные клоны;

2.1.5. Последовательно применить IS- и RIS-транспозиции ко всем полученным клонам;

2.1.6. Вычислить $Ag-Ab$ аффинность (с антигеном x_i) всех клонов (элементы d_{ij});

2.1.7. Повторно выбрать $\zeta\%$ лучших клеток (с максимальной $Ag-Ab$ аффинностью к антигену x_i) из множества измененных клонов и поместить их во временную популяцию (матрицу) M_p клеток памяти;

2.1.8. Метадинамика. Удалить из популяции M_p те клетки, аффинность которых ниже порогового уровня σ_d , что приведет к уменьшению размера M_p .

2.1.9. Вычислить $Ab-Ab$ аффинности полученной популяции M_p , заполнив матрицу S ;

2.1.10. Удалить из популяции M_p те клетки, аффинность которых (s_{ij}) ниже порога сжатия сети σ_s , что приведет к повторному уменьшению размера M_p (клональное сжатие);//

2.1.11. Конкатенировать исходную сеть C с популяцией M_p ($C \leftarrow [C; M_p]$);

2.2. Вычислить $Ab-Ab$ аффинности всей вновь полученной сети C и удалить те клетки, аффинность которых (s_{ij}) ниже порога сжатия сети σ_s (сетевое сжатие);

2.3. Заменить $r\%$ худших клеток сети C новыми случайно сгенерированными клетками;

2.4. Проверить условие останова.

2.5. В зависимости от результата предыдущего шага вернуться к шагу 2.1. или перейти к шагу 3.

3. Конец.

Очевидно, что иммунная сеть изменяет свою топологию в процессе обучения в зависимости от обучающих данных. Благодаря процедуре сжатия реализуется одно очень важное свойство иммунной сети – способность к обобщению.

4.5. Применение иммунных принципов

Вычисление аффинности каждого антитела. Аффинность антитела – это скалярная величина оценки, показывающая близость результата к оптимальному значению. В зависимости от того решается ли задача максимизации или минимизации, лучшим по популяции считается антитело с самым высоким или низким значением аффинности соответственно. Аффинность антител – главный критерий отбора индивидуумов в алгоритме иммунной сети. Аффинность в рассматриваемом алгоритме иммунной сети вычисляется исходя из таблицы значений аппроксимируемой функции. Эта таблица представляет собой матрицу наборов значений аргументов исследуемой функции и соответствующих им значений самой функции (рис. 6). Во время оценки антитела символьная строка его генетического кода преобразуется в дерево нейронной сети (НС-дерево), и значения аргументов из таблицы подаются на вход этого дерева. Полученные на выходе НС значения сравниваются с соответствующими им табличными (реальными) значениями и,

исходя из степени близости значений друг к другу, строится суждение о качестве аппроксимации антителом заданной функции.

При этом аффинность антитела может быть представлена в виде

среднеквадратической ошибки $RE = \frac{\sum_{i=1}^m \left| \frac{Y' - Y}{Y} \right|}{m}$. Аффинности связей двух

антител рассчитываются исходя из значений коэффициентов линейной корреляции между двумя выходными последовательностями, получаемыми при постановке табличных значений в каждое из антител. Высокий коэффициент корреляции говорит о подобии структур и следовательно о высокой аффинности двух клеток друг к другу. Используя значения межклеточной аффинности иммунная сеть производит операцию сжатия.

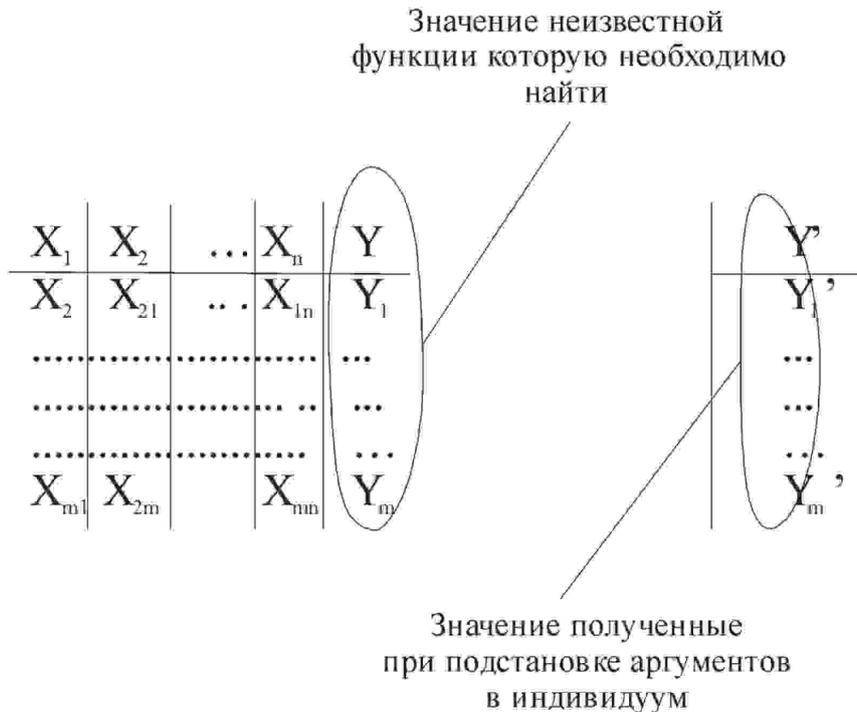


Рисунок 7 – Оценка антитела при помощи таблицы значений функции

Использование IS- и RIS-транспозиций. Транспозиция – перемещение части генетического кода определенной длины. Различают IS-транспозиции (Insertion Sequences transposition) и RIS-транспозиции (Root Insertion Sequences transposition). При IS-транспозиции цепочка символов определенной длины перемещается из любого места индивидуума в головную часть, но не в корень (рис. 7а). При RIS-транспозиции цепочка символов определенной длины во

главе с функциональным символом перемещается в начало (корень) индивидуума (рис. 76).

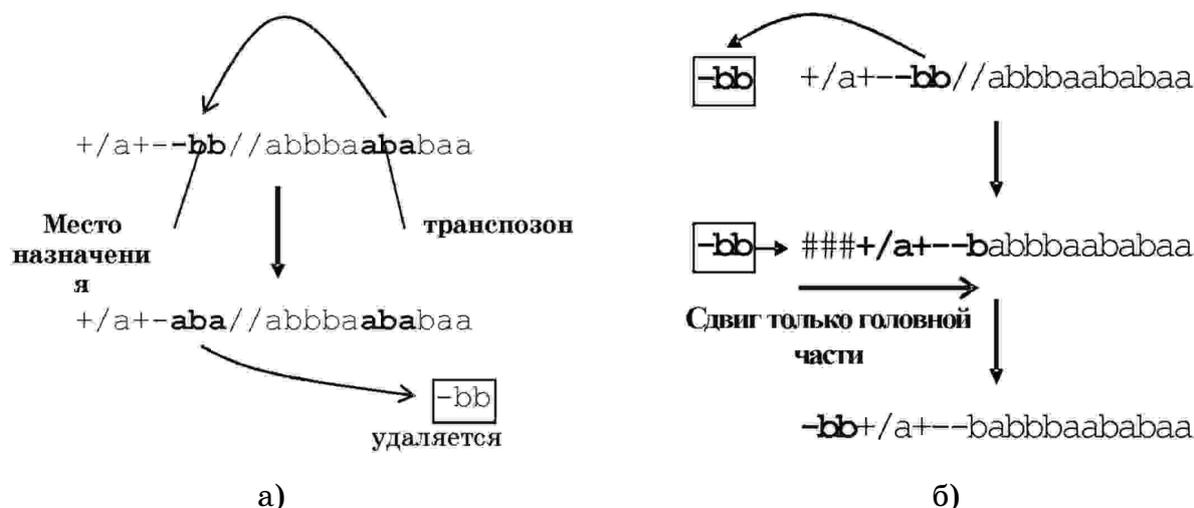


Рисунок 8 – а - IS-транспозиция; б - RIS-транспозиция

Эксперименты показывают, что транспозиции существенно улучшают эффективность работы ИИС. Решение задачи синтеза нейронных сетей требует введение специального типа транспозиции, работа которой ограничивается пределами одного домена. Тем не менее, ее механизм схож с механизмом IS-транспозиции. Оператор случайным образом выбирает антитело, домен Dw или Dt, первую позицию транспозона, длину транспозона и место назначения (но теперь место назначения уже выбирается только в пределах Dw или Dt). Затем происходит перемещение транспозона в место назначения, где он заменяет существующие там символы, которые удаляются.

Использование прямой мутации весов и пороговых значений. Несмотря на то, что транспозиции действуют как операторы перемешивания существующих значений весов и порогов, они неспособны изменить сами значения в наборе. Для этого используется специальный оператор, называемый прямой мутацией весов и порогов, который случайным образом выбирает значение из набора и заменяет его новым вещественным числом. Например, массив

$$W_i = \{-1.14, 2.3, 0.0, \mathbf{0.77}, -0.9, 3.5\},$$

кодирующий веса i -го антитела, был изменен при помощи прямой мутации в позиции 4, т.е. число 0.77 было заменено новым случайным числом 3.79 . При этом новый массив будет выглядеть так:

$$W_i = \{-1.14, 2.3, 0.0, \mathbf{3.79}, -0.9, 3.5\}.$$

Эффект от таких изменений может быть весьма разнообразным. Изменение может быть нейтральным, если нейтральна сама позиция. Например, для антитела:

Dababaa123456

позиция 4 является нейтральной, т.к. строка антитела декодируется в нейронную сеть вида (рис. 9), где позиция 4 является незадействованной.

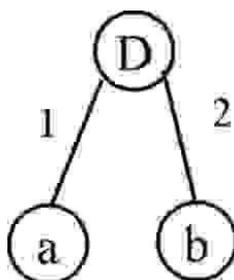


Рисунок 9 – К пояснению нейтральности позиций генетического кода антител

С другой стороны изменения могут быть весьма значительными, если измененная позиция в массиве весов задействована в строке антитела более одного раза, как в приведенном ниже примере:

D₃D₁D₂abab454324

Рисунок 10 – Представление дерева нейронной сети в виде строки

5. Результаты экспериментов

Для проверки работы предложенного алгоритма был выбран временной ряд суточного электропотребления состоящий из 365 значений соответствующих одному году наблюдений. Для обучения были выбраны первые 255 значений ряда, для тестирования – последние 110 значений. В соответствии с автокорреляционной функцией ряд был погружен в многомерное лаговое пространство размерностью 7.

График временного ряда приведен на рис 11. Для настройки иммунной сети использовались следующие параметры (Табл.1). Популяция клеток памяти представляет собой группу нейронных сетей, полученную в результате работы иммунной сети. Каждая отдельно взятая из этих нейронных сетей можно рассматривать как отдельного эксперта. Исходя из тех соображений, что полученные в виде клеток памяти нейронные сети в общем случае имеют разную структуру и настройки весов, можно сделать вывод, что их

предсказания даже при обучении на одной и той же тренировочной выборке будут различными. Поэтому, наиболее целесообразным, в данном случае, является использование метода комитетов нейронных сетей [11].

Таблица 1

Параметры настройки иммунной сети

<i>Наименование параметра</i>	<i>Значение</i>
Длина головы антитела	10
Количество генов в антителе	5
Начальный размер иммунной сети	50
Размер популяции клеток памяти (количество получаемых нейронных сетей)	10
Максимальное количество поколений работы иммунной сети	100
Размер массива весов	30
Левая граница констант в массиве весов	-2.0
Правая граница констант в массиве весов	+ 2.0
Точность представления констант	0.001
Коэффициент отбора лучших клеток сети для последующего клонирования	0.3
Коэффициент отбора лучших клеток уже клонированной сети после мутации и транспозиции	0.5
Коэффициент замещения худших клеток сети в конце поколения	0.4
Коэффициент интенсивности клонирования клеток сети	0.2
Порог подавления измененных клонов, чья аффинность к антигену оказалась ниже порогового значения	0.01
Порог сжатия сети.	0.5
Вероятность мутации	0.8
Интенсивность мутации внутри антитела	5
Вероятность IS-транспозиции	0.3
Минимальное количество точек IS-транспозиции	3
Максимальное количество точек IS-транспозиции	9
Вероятность RIS-транспозиции	0.3
Минимальное количество точек RIS-транспозиции	3
Максимальное количество точек RIS-транспозиции	9

В соответствии с [11] легко показать, что среднее значений комитета, будет давать лучшие предсказания, чем отдельный эксперт.

Для повышения достоверности результатов, было осуществлено по 100 прогонов программы. Результаты предсказаний отдельных экспертов приведены в виде графика на рисунке 12.



Рисунок 11 – График суточного потребления электроэнергии

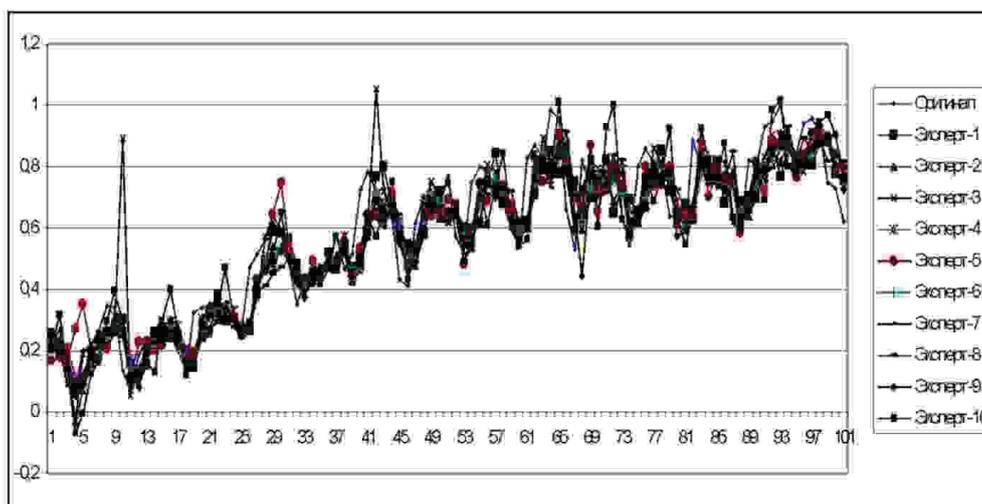


Рисунок 12 – Результаты предсказаний комитетом из 10 экспертов (нейронных сетей).

График среднего прогноза комитета сетей и исходного временного ряда приведен на рисунке 13.

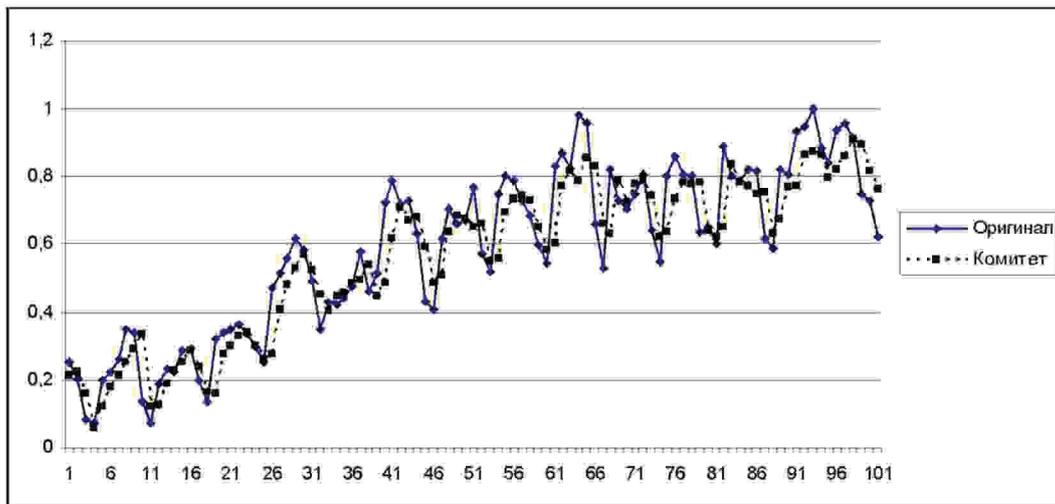


Рисунок 13 – График среднего прогноза комитета сетей

6. Выводы

В работе предложен комбинированный подход синтеза нейронных сетей персептронного типа с помощью гибридного алгоритма искусственной иммунной сети. Описаны иммунные механизмы синтеза ансамбля нейронных сетей с гетерогенной топологией и параметрами настройки. Для повышения качества прогноза предложено использовать такие методы принятия решения как метод комитетов, что значительно повысило устойчивость получаемых результатов.

Проведенные эксперименты показали, что предложенный метод улучшает качество прогнозирования нагрузки и повышает доверие к полученным прогнозам, что в свою очередь позволяет увеличить экономический эффект при производстве и потреблении электроэнергии. Предложенный метод прогноза энергопотребления повышает совершенство моделей прогноза, заключающееся в возможности использования разнообразных входных переменных, при этом функция зависимости выходных параметров модели от выходных переменных может быть сколько угодно сложной.

ЛИТЕРАТУРА

1. Бэнн Д.В., Фармер Е.Д. Сравнительные модели прогнозирования электрической нагрузки: Пер. с англ. – М.: Энергоатомиздат, 1987. – 200 с.
2. Меламед М.А. Современные методы анализа и прогнозирования режимов электропотребления в электроэнергетических системах //

- Итоги науки и техники. Серия Энергетические системы и их автоматизация. 1988,. Т.4.с.4-111.
3. Р.Б.Испариллов, Г.С. Хронусов и др. Краткосрочное прогнозирование расхода электроэнергии и заявляемой мощности промышленных предприятий. Свердловск, 1984.–66 с.
 4. Э.Е.Тихонов, В.А.Кузьмищев Методы и алгоритмы прогнозирования экономических показателей на базе нейронных сетей и модулярной арифметикм: монография.– Невинномысск: Издательство НИЭУП, 2004.– 166 с.
 5. Leandro N. de Castro and Jonathan Timmis. Artificial Immune System: A New Computational Intelligence Approach, Springer-Verlag, 2002, 357 p.
 6. Литвиненко В.И., Фефелов А.А., Горавский С.П. Объектно-ориентированная реализация алгоритма клональной селекции // Радиоелектроніка. Інформатика. Управління/ Запоріжжя, 2003 (9). – с.81-88.
 7. Грицик В.В., Литвиненко В.І., Цмоць І.Г., Стех С.М. Теоретичні і прикладні проблеми застосування штучних імунних систем// Інформаційні технології і системи. –2003 –Т.6.-№1-2, с.7-45.
 8. В.І. Литвиненко Вирішення задач класифікації з використанням механізмів ідіотипичної мережі//Наукові праці: науково-методичний журнал. Т.57. Вип.44. Комп'ютерні технології.– Миколаїв: Вид-во МДГУ ім. П.Могили, 2006. с.136-146.
 9. Shaffer J.D., Whitley L., Eshelman J., Combinations of Genetic Algorithms and Neural Networks: A Survey of the State of the Art, Proceedings of International Workshop on Combinations of Genetic Algorithms and Neural Networks, COGANN-92, 1992/
 10. Whitley D., Applying genetic algorithms to neural network learning, Proceedings of the Seventh Conference of the Society of Artificial Intelligence and Simulation of Behavior, Sussex, England, Pitman Publishing, 1989, pp.137-144
 11. Ежов А.А., Шумский С.А. Нейрокомпьютинг и его приложения в экономике и бизнесе.–М.: Изд-во МИФИ,1998. –224 с.