

# КРАТКОСРОЧНОЕ ПРОГНОЗИРОВАНИЕ ОБЪЕМА ГАЗОПОТРЕБЛЕНИЯ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Агаев Н.Б.

*Азербайджанский архитектурно-строительный университет, г. Баку*

*В работе предлагается специальная методика для краткосрочного прогнозирования объема потребления газа. Для получения более точного графика объема газопотребления в прогнозируемый период используются результаты трех независимых нейронных сетей. Первая нейронная сеть прогнозирует значение объема потребляемого в каждом интервале рассматриваемого периода с использованием метода окон или метода Z. Вторая нейронная сеть предсказывается с использованием максимального и минимального значения нагрузок в прогнозируемом периоде. Третья нейронная сеть предсказывает будущий тренд на основе оптимальной экстраполяции стохастической функции газопотребления.*

*Ответы, полученные от трех нейронных сетей, обрабатываются в специальном блоке. Задачами этого блока являются анализ точности прогнозирования нейронных сетей в предыдущий момент времени и корректировка ответов одной нейронной сети по результатам другой. На основании результатов полученных выходов трех нейронных сетей формируется выход как взвешенное среднее.*

*Использование результатов трех независимых нейронных сетей улучшает качество прогнозирования объема газопотребления и повышает доверие к полученным прогнозам. Анализ и обработка результатов показывает, что предлагаемая нейронная сеть повышает точность прогнозирования примерно на 0.5%, что позволяет увеличить экономический эффект при оперативно-диспетчерском управлении систем газоснабжения.*

## Введение

Краткосрочное прогнозирование объема газопотребления составляет основную исходную информацию для принятия решений в процессе планирования режимов потребления и оперативно-диспетчерского управления.

Так как своевременное получение информации о предстоящем объеме газопотребления имеет большое значение для оценки надежности и предельных режимов, а также для достижения оптимального режима в системе транспорта и распределения газа. Точность краткосрочного прогноза объема потребляемого газа существенно влияет на эффективность работы газотранспортных систем. Недооценка нагрузки может привести к росту использования пикового объема, что, в свою очередь, ведет к снижению резервов, а завышенный прогноз нагрузки может привести к необоснованному увеличению резерва, и, следовательно,

себестоимости газа. Поэтому очень важным является качество оперативного прогнозирования графика нагрузки сети.

Известно, что на величину объема потребляемого газа влияют такие факторы, как степень охвата и структура потребителей, производственная и бытовая активность населения, метеорологические факторы и т.д.

Поэтому для того чтобы спрогнозировать объем газопотребления обрабатывается следующая информация:

- *Прогнозная метеорологическая информация.* Необходимо учитывать метеорологическую обстановку, которая ожидается в момент прогноза. Эти данные расплывчаты и не дифференцируемы по отдельным категориям потребителей.

- *Регистрационная информация.* Информация об объеме потребляемого газа в системе в предшествующий период.

- *Факторы неопределенности.* Непредусмотренные изменения в объеме газа, потребляемого крупными потребителями; аварийные ситуации в системе транспорта газа.

В настоящее время существуют много методов, способных прогнозировать нагрузку в газотранспортной системе [1]. Решение задачи прогнозирования традиционным способом состоит из двух этапов:

- Построение математической модели нагрузок газотранспортных систем, с помощью которой обрабатываются данные о нагрузках за прошедший период времени.

- Получение прогноза на базе построенной модели.

Качество прогноза во многом зависит от выбранной математической модели. Основным недостатком существующих методов является необходимость построения модели нагрузки и постоянное уточнение готовой модели. Другим недостатком этих методов является неточное установление соотношения между входными и выходными переменными, так как зависимости между ними нелинейные.

В последнее время для решения задачи прогнозирования используются регрессионные модели [1], но в последние десятилетия были предложены модели на основе искусственных нейронных сетей [2]. Предпочтение их традиционным

статистическим моделям при одинаковой точности прогнозирования обусловлено возможностью использования большего количества разнообразных входных переменных, в том числе и лингвистических. При этом функция зависимости выходных параметров модели от входных переменных, характеризующих режимы газопотребления и различные факторы, влияющие на его величину, может быть какой угодно сложной т.е. имеет способность восстанавливать нелинейные функциональные зависимости. При использовании нейронной сети для прогнозирования объема газопотребления нет необходимости построения модели объекта. Нейронная сеть имеет хорошую работоспособность в условиях неполных данных, возможно использование малых обучающих выборок, не обеспечивающих получение статистически достоверных результатов классическими методами.

### **Теоретические исследования**

В работе используется специальная методика для краткосрочного прогнозирования объема потребления газа. Согласно данной методике, информация о погодных условиях не используется, так как, во-первых, обучающая выборка формируется из ретроспективных данных, измеренных в течение одного интервала регистрации (часовые, дневные, месячные) и, во-вторых, нейронные сети переобучаются после каждого поступления новой информации. Обучение сети происходит вне реального времени.

Чтобы решить задачу с помощью искусственной нейронной сети необходимо выбрать конфигурацию нейронной сети и сформировать правила, при которых будет работать данная нейронная сеть. Под формированием правил понимается реализация следующих этапов (рис. 1):

- создание обучающей выборки;
- обучение нейронной сети;
- тестирование нейронной сети.

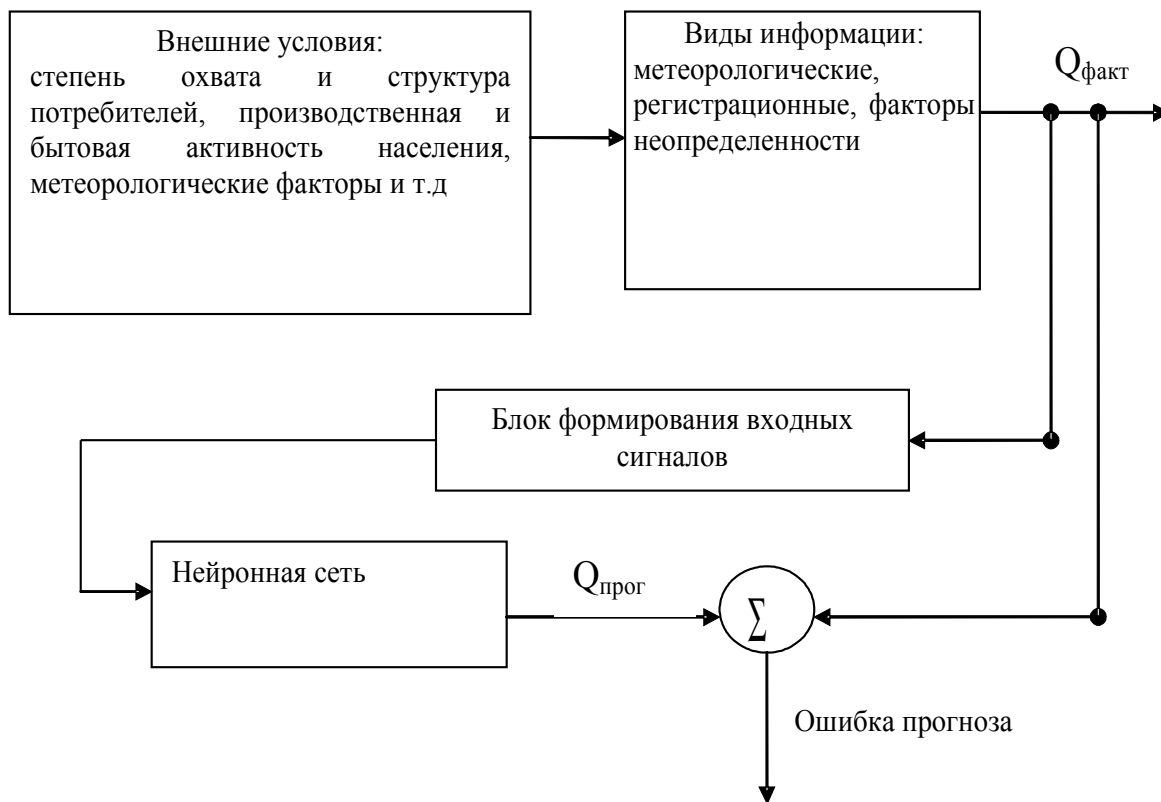


Рис.1 Этапы решения краткосрочного прогнозирования объема газопотребления

Обучающая выборка состоит из множества данных регистрации. Каждое множество данных представляет собой индивидуальный набор признаков. Для прогнозирования объема газопотребления в качестве входных параметров в данной работе используются значения объема потребляемого газа предыдущих интервалов времени, а заранее известным результатом являются нагрузки прогнозируемого периода. Информация, поступающая в нейронную сеть, обрабатывается в следующем порядке. В блоке предобработки выполняется классификация входных данных и проверяются полнота, равномерность и противоречивость каждого класса обучающей выборки. Классифицируемые данные поступают на первый слой нейронов, задачей которого является

распределение входных данных между нейронами второго слоя. Нейроны второго слоя суммируют информацию, полученную от нейронов первого слоя, преобразуют ее и передают нейронам третьего слоя. Нейроны третьего слоя выполняют аналогичные действия, с той разницей, что выходные сигналы поступают в интерпретатор ответов. Перед составлением обучающей выборки должен быть проведен анализ данных, выбранных для её формирования. Целью этого анализа является классификация входных данных и исключение из обучающей выборки противоречивых и резко выделяющихся из всех остальных данных. Классификация проводится в соответствии с традициями управления газотранспортными системами с учетом сезонности использования газового топлива. Так как, если в качестве входных данных используются месячные данные, тогда их группируем в два класса – первый относится к зимнему периоду использования газа, т.е. от ноября до апреля следующего года, второй к летнему периоду использования газа, т.е. от апреля месяца до ноября. Если прогнозируется дневной объем газопотребления, то различают рабочие и выходные (праздничные) дни. После классификации проверяются такие характеристики, как полнота, равномерность, противоречивость и повторяемость обучающей выборки. Полнота выборки определяется обеспеченностью классов обучающими наборами. Обычно количество обучающих наборов для класса должно быть в 3-5 раз больше, чем используемое в наборе число признаков класса. Равномерность обучающей выборки показывает, на сколько равномерно распределены обучающие наборы по классам, а повторяемость-показатель, характеризующий количество одинаковых наборов в рамках одного класса.

Типовой график объема газопотребления для каждого класса характеризуется следующими компонентами: средняя величина объема, максимальное и минимальное значения и случайная составляющая. Иногда изменение объема газопотребления внутри класса представляет собой неперiodические процессы, относительно быстро изменяющихся во времени. Особенно на границе класса эти явления более ярко выражаются. Существующие системы прогнозирования в большинстве своем оказываются неспособными работать с такими процессами. Такие изменения в поведении прогнозируемой величины требуют дообучения сети, а иногда и переформирования ее структуры.

При этом необходимо заметить, что обучение одной такой нейронной сети –это десятки часов машинного времени. Такие временные затраты недопустимы для краткосрочного прогнозирования. Кроме того, существующие средства и подходы уменьшения времени обучения нейронных сетей либо дают выигрыш во времени, но не дают возможность сети экстраполировать свои выводы за область известных данных, либо имеют существенные ограничения на условия решаемой задачи и на структуру нейронной сети. Сама же система моделирования из-за специфики своей направленности не может быть использована в качестве полноценной системы прогнозирования.

Одной нейронной сети сложно установить закономерности между входными и выходными параметрами, учитывая все вышеуказанные перечисленные моменты. Решение этой проблемы возможно, если обучить несколько нейронных сетей одновременно.

Для получения более точного графика нагрузки в прогнозируемый период нами используются результаты трех независимых нейронных сетей. Первая нейронная сеть прогнозирует значение нагрузки в каждом интервале рассматриваемого периода с использованием метода окон или метода Z. Вторая нейронная сеть предсказывает с использованием максимальных и минимальных значений нагрузок в прогнозируемый период. Третья нейронная сеть предсказывает будущий тренд на основе оптимальной экстраполяции стохастических функции газопотребления. Кроме прогнозируемых значений, каждая нейронная сеть предоставляет информацию о точности прогнозирования нагрузки в предшествующий период времени.

Ответы, полученные от трех нейронных сетей, обрабатываются в специальном блоке (рис. 2). Задачей этого блока является анализ точности прогнозирования нейронной сети в предыдущий момент времени и корректировка ответов одной нейронной сети по результатам другой. Наибольшее доверие оказывается нейронной сети ответы которой точнее совпадают с реальными данными, т.е. имеют меньшую ошибку прогнозирования в предыдущий момент времени. На основании результатов, полученных на выходе трех нейронных сетей, формируется выход как взвешенное среднее. На рис. 2 показан алгоритм получения графика нагрузки газотранспортных систем. Предлагаемая нами

методика краткосрочного прогнозирования объема газопотребления с различными нейронными сетями позволила выявить те аспекты данного процесса, которые в основном приводят к значительным затратам времени. Однако идеально обученной, считается такая сеть, глобальная ошибка которой равно нулю. Но для реальных задач обучение нейронной сети до такой степени представляет собой достаточно трудоемкую задачу, а нередко и вовсе неразрешимую. Рассматривая эту задачу с точки зрения практики, можно сказать, что далеко не всегда необходима 100%-я точность. Каждая конкретная нейронная сеть имеет свои требования и ограничения по скорости и качеству получения результатов в зависимости от применяемого алгоритма обучения. Поэтому обучение предлагается проводить до момента успешного достижения некоторого достаточного значения функции ошибки для всех нейронных сетей. Рассмотрим с этой точки зрения процесс обучения каждой нейронной сети в отдельности. Отметим что большинство используемых сегодня алгоритмов обучения нейронных сетей базируются на оценочной функции, которая дает представления о качестве работы всей сети в целом. При этом имеется некоторый алгоритм, который в зависимости от полученного значения этой оценки каким-то образом подстраивает изменяемые параметры системы и производится пересчет всех параметров. Можно сказать, что такой подход к обучению обладает высокой насыщенностью причинно-следственных связей, что одно событие неизбежно влечет за собой другое. В данном случае изменение параметра одной связи сети предполагает выполнение такой же процедуры и для всех остальных связей. Это приводит к тому, что обычно нельзя подавать сети входные данные в их истинном диапазоне величин и получать от сети результаты в требуемом диапазоне. Поэтому перед подачей в сеть входных данных их необходимо нормировать, например в диапазоне значений  $[-1,1]$  или  $[0,1]$ , либо делать так, чтобы выходные сигналы не слишком сильно выходили за пределы этих отрезков.

Наиболее часто нормировку можно выполнять следующим образом. Каждая компонента входного класса данных  $Q_i$  заменяется величиной

$$Q_i = \frac{Q_i - \min Q_i}{\max Q_i - \min Q_i} \quad (1)$$

где  $\max Q_i$  и  $\min Q_i$  соответственно максимальное и минимальное значения, вычисленные по всей обучающей выборке.

По этой же формуле пересчитываются и компоненты векторов ответов. Обычно в качестве *min* и *max*-величины берут их данные, существующие на настоящий момент, и в дальнейшем нормировку не меняют, а если предполагается, что в дальнейшем поступят сильно отличающиеся данные, то *min* и *max*-величины задается пользователем по его оценке. Иными словами эти величины должны вводиться в момент создания сети и в дальнейшем не зависеть от обучающей выборки.

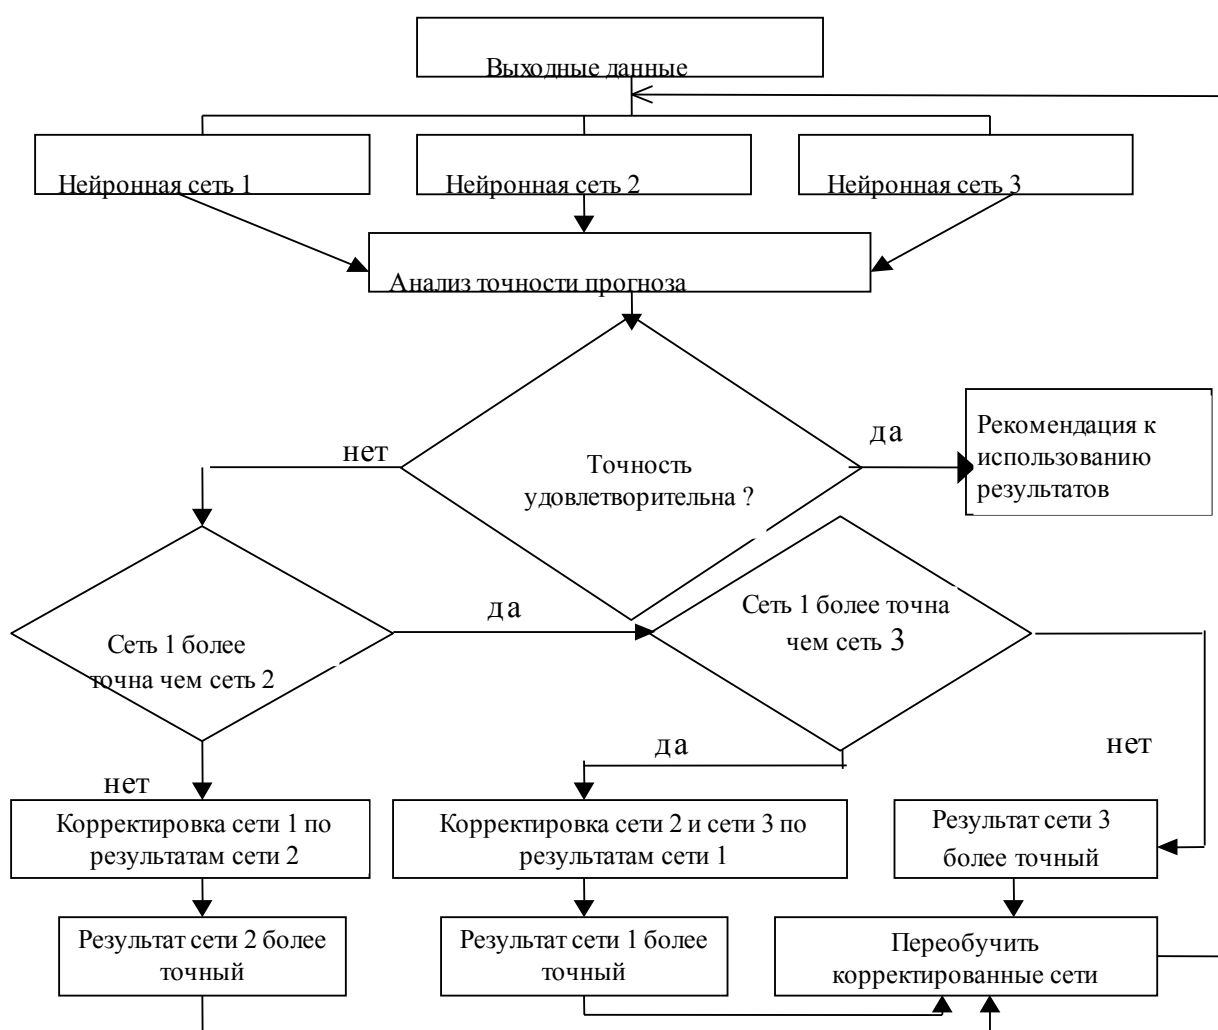


Рисунок 2. Алгоритм получения прогнозных значений комбинированным искусственным нейронным сетям



### Алгоритм обучения нейронной сети 1

Для нейронной сети 1 предлагаем следующий алгоритм обучения, который в литературе назывался метод окон [3] или Z- метод. Z- метод предполагает использование двух окон - базовой и компетентной - с фиксированными размерами. В алгоритме выделяются три этапа его работы:

- формирование базовых окон;
- поиск компетентных окон;
- прогнозирование.

До обучения базовых окон входные данные выше сказанным путем сгруппировались по классам и нормализуются. Из этих данных составляется матрица с размером  $n \times m$ , где  $n$ -число классов, а  $m$ -число данных в классе. Самые свежие данные имеют индекс  $i=1$ , данные за предшествующий период  $i=2$  и т.д. до индексам  $i=m$ . Среди  $k$  первых элементов матрицы выделим  $G$  элементов и назовем его базовым окном мощностью  $G$ . Если индекс  $i$  увеличить на число, то получится окно той же мощности. Если коэффициент корреляции между этим и базовым окном превышает некоторый заданный порог, например  $r=0.90$ , то это окно принимается как компетентное окон.

В базовые окна добавим новый прогнозируемой элемент с индексом  $i=0$ , значение которого неизвестно. Получается новое базовое окно с мощностью  $G+1$ . Аналогично увеличим мощность компетентного окна и подставим в него элемент с индексом  $q-1$ . Если построить прогнозную модель между  $G$  прежними элементами компетентных окон и подставить в него элемент с индексом  $q-1$  получим прогнозный элемент с индексом  $i=q$ . Этот элемент принимает один из вариантов прогноза для элемента  $i=0$ . Следует отметить, что в качестве прогнозирующих моделей можно использовать линейные регрессионные модели. При этом учитываются закономерности, обнаруживаемые в таблицах данных, описывающих прошлые факты.

Если используем  $p$  компетентных окон, то получаем  $p$  вариантов прогноза. Из вариантов прогноза составим вектор с размером  $p$ . Вычислим дисперсию  $D_1$ , среднее значение  $M_1$  и характеристику компетентности окна  $h_1 = \frac{1}{1 + D_1}$ . Для

каждого нового  $t$ -го базового окна найдем значение  $D_t$ ,  $M_t$  и  $h_t$  и получаем средневзвешенное значение прогнозируемого элемента  $Q(0,j)$ :

$$Q(0,j) = \frac{\sum_t M_t h_t}{\sum_t h_t} \quad (2)$$

Эту процедуру поочередного переноса элементов базовых окон можно продолжить сколь угодно долго. Однако ясно, что с удалением от прогнозируемого периода точность прогноза будет падать, причем скорость нарастания ошибок зависит от характера наблюдаемого процесса.

### Алгоритм обучения нейронной сети 2

Нейронная сеть 2 предсказывает новые значения объема потребляемого газа с использованием максимальных и минимальных значений нагрузок в прогнозируемый период. Так как все обучающие классы различаются между собой по двумя параметрам- максимальное и минимальное значения элементов. Поэтому в качестве прогнозирующей модели примем функцию отклика в форме линейного фильтра

$$Q_i^{oblx} = \sum_{k=1}^{n_i} a_k Q_{ik} \quad (3)$$

где

$Q_i^{oblx}$  -выход  $i$ -го класса

$Q_{ik}$  - $k$ -го значения объема потребляемого газа  $i$ -го обучающего класса

$$a_k = w_{ik} f(\sigma_k, Q_{ik}, \mu_k) \quad (4)$$

$w_{ik}$  -  $k$ -го значения весового коэффициента  $i$ -го нейрона

$n_i$  –число элементов  $i$ -го класса.

$$f(\sigma_k, Q_{ik}, \mu_k) = \frac{1}{\sqrt{2\pi}\sigma_k} e^{-\frac{(Q_{ik}-\mu_k)^2}{2\sigma_k^2}} \quad (5)$$

-функция нормального распределения

$\mu_k$  -среднее арифметическое распределение  $i$ -ого класса

$\sigma_k$  -стандартное отклонение распределения  $i$ -ого класса

Для обучения нейронной сети воспользуемся методом выпуклой комбинации [2]. Этот метод полезен при обучении, чтобы правильно распределить плотность ядер коэффициентов веса в соответствии с плотностью входных векторов. Для этого присваиваем всем весам одно и тоже начальное значение:

$$w_{ik} = \frac{1}{\sqrt{n_i}} \quad (6)$$

Задаем обучающую выборку и проводим обучение класса  $Q_{ik}$ , но не с элементами этого класса, а с элементами

$$w_{ik} = \frac{\beta}{\sum_i Q_{ik}} + \frac{1-\beta}{\sqrt{n_i}} \quad (7)$$

где  $\beta$ -монотонно возрастающая функция, меняющаяся от 0 до 1 по мере обучения. В качестве функции  $\beta$  можно взять линейную функцию. В начале обучения  $\beta=0$  и все обучающие элементы совпадают с весом. В процессе обучения сети  $\beta$  постепенно возрастает, приближаясь к единице. Это позволяет разделять входные векторы и окончательно приписывает им их истинные значения. После определения выхода сети вычисляется разность между выходом сети и требуемым выходом т.е. контрольными данными. Корректируются веса сети так, чтобы минимизировать ошибку и повторять процедуру для каждого набора обучающих выборок до тех пор, пока ошибка на всем множестве не достигнет приемлемого уровня.

### Алгоритм обучения нейронной сети 3

Как сказано выше, нейронная сеть 3 предсказывает будущий тренд объема потребляемого газа на основе оптимальной экстраполяции стохастических функции газопотребления и она контролирует корректность прогнозов, предложенных первой и второй нейронными сетями. Процесс обучения проводится согласно методике [4.]. Алгоритм расчета состоит в следующем:

**Шаг 1.** По ряду обучающей выборки  $Q(t), Q(t-1), Q(t-2), \dots, Q(t-n)$  вычисляется корреляционная функция  $R_{Q(t)Q(t)}(\tau)$ .

**Шаг 2.** По вычисленному значению корреляционной функции находятся неизвестные коэффициенты  $\alpha$  и  $\beta$  в аппроксимирующих функциях:  $e^{-\alpha t} \cos \beta t$

**Шаг 3.** Коэффициент  $\varphi_k$  в формуле

$$Q(t+T) = \sum_{k=0}^n \varphi_k Q(t-k) \quad (9)$$

определяем как значение оптимальной передаточной функции

$$l(t) = \left[ \cos \beta T + \frac{\sqrt{\alpha^2 + \beta^2} - \alpha}{\beta} \sin \beta T \right] e^{-\alpha T} \delta(t) - \frac{2(\alpha^2 + \beta^2 - \alpha \sqrt{\alpha^2 + \beta^2})}{\beta} \sin \beta T e^{-\alpha T} e^{-\sqrt{\alpha^2 + \beta^2} t} \quad (10)$$

при замене в ней  $t$  на  $t-k$

**Шаг 4.** Вычисляется прогнозируемое значение при  $T=1$ .

**Шаг 5.** Результат добавим в обучающую выборку, а начало выборки сдвинем на один элемент влево и получим новую обучающую выборку  $Q(t+1), Q(t), Q(t-1), \dots, Q(t-n+1)$

**Шаг 6.** Процесс повторяется с шагом 2, до тех пор, пока не будут вычислены все прогнозные значения объема газопотребления.

### Алгоритм работы обученной нейронной сети

Следует отметить, что обученные нейронные сети сохраняются и используются в требуемый момент времени. Ниже описывается алгоритм работы обученной нейронной сети.

**Шаг 1.** Определяется к какому классу относятся данные об объеме газопотребления.

**Шаг 2.** Формируются обучающие и контрольные элементы из этих значений для трех нейронных сетей.

**Шаг 3.** Инициализируются три нейронные сети, проводится процесс обучения.

**Шаг 4.** Анализируются результаты трех нейронных сетей.

**Шаг 5.** При удовлетворительной ошибке прогнозирования переход на шаг 7.

**Шаг 6.** Рекомендуется переобучить нейронные сети.

**Шаг 7.** Выполняется корректировка ответов одной из нейронных сетей по результатам другой. При этом более точные результаты принимаем как контрольную выборку для корректируемой сети.

**Шаг 8.** Выдается значение объема газопотребления в прогнозируемый период.

## Результаты исследования

Модель месячного прогнозирования объема газопотребления была исследована на данных г. Баку за 1994-2004 гг. (табл. 1).

Таблица 1  
Объем газопотребления в .Баку за 1994-2004 гг.( тыс. м<sup>3</sup>)

	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004
Январь	297165	321055	297345	273634	257180	263463	252690	269669	286648	277272	261309
Февраль	279731	286546	272472	258398	241241	225748	237968	245487	253005	250245	234410
Март	286293	279582	271604	263625	253539	227367	244308	248203	252099	271409	229844
Апрель	211742	202823	199891	196958	191637	169657	161038	179245	197452	199847	177002
Май	177496	146299	144869	143439	147341	139189	131388	142129	152869	136137	134726
Июнь	141823	117173	117713	118252	124933	103915	104606	106455	108303	99440	96983
Июль	137449	115191	115839	116486	109555	97823	92836	91052	89268	89577	86877
Август	129634	111112	109643	108174	108479	99543	89120	86251	83381	82927	80728
Сентябрь	130181	118237	111999	105761	114948	106361	98334	83611	86889	90351	88133
Октябрь	151958	145207	131201	117195	136793	127862	124825	113981	103138	110118	121363
Ноябрь	223176	178346	173742	169137	188202	198995	182968	173095	163222	193134	172538
Декабрь	296175	275020	247756	220492	263502	246678	248258	270220	292182	255630	259473

В соответствии с вышеуказанным, данные каждого года разделены на два класса. При всех случаях данные 2004 г. принимались как контрольная выборка.

Все нейронные сети состоят из входного, скрытого и выходного слоёв. В входном слое данные группируются по классам и если требуется нормализуются. В скрытом слое, в соответствие с вышеуказанным нейроалгоритмом обрабатываются входные данные. В выходном слое формируются прогнозные значения и она подаются на блок анализа результатов трех нейронных сетей. Отметим, что в зависимости от принятия решения, блок анализа каждой нейронной сети имеет возможность использовать результат другой нейронной сети в качестве входного сигнала.

### Обучение по сети 1

В дальнейшем для сети 1 множество данных классов для каждого года будем называть окном соответствующего года. Каждое окно в скрытом слое принимается как один нейрон. В входном слое активизируются все окна и они подаются в скрытый слой, начиная от самого ближнего, т.е. с индексом 1 до самого крайнего, т.е. с индексом  $n$ . В начале работы скрытый слой сети в

качестве базового окна выбрал первое активное окно, в нашем случае данные за 2003 г., потом он постепенно переходит к предыдущему году до 1994 г. Для определения компетентных окон скрытый слой активизирует остальные нейроны входного слоя и вычисляет коэффициенты корреляции между данными базовыми и этими нейронами. Компетентные окна выбраны из условия, когда коэффициент корреляции больше 0,9. Исследованиями установлено, что в начале обучения условия компетентности не выполнены для 1995 г. по классу 1 и для 2000 г. по классу 2. Отметим, что эти нейроны на данном этапе обучения не активизировались.

Для каждого компетентного окна в скрытом слое для обоих классов сконструирована трендовая прогнозная модель в виде трехчлена  $at^2 + bt + c$ . Следует отметить, что выбор трехчлена в качестве трендовой модели исходит из результатов исследования [1]. После определения соответствующих неизвестных коэффициентов трендовой модели, вычислены прогнозные значения по месяцам и на этом основании определены параметры компетентного окна- дисперсия, среднее значение и характеристика компетентности. Эти параметры вычислены для всех компетентных окон с соответствующими базовыми окнами. В таблице 2 показаны значения параметров компетентного окна для первой и второй итерации обучения. По формуле (2) определены прогнозные значения и проверена точность полученных результатов по контрольным окнам. Если результат удовлетворителен, то обучение прекращается. Прогнозные значения полученные по сетям 1 показаны на рис 3.

## Обучение по сети 2

Скрытый слой от входного слоя принимает все обучающие данные. Каждые данные принимаются как один нейрон. Обучение начинается с вычисления среднего арифметического и стандартного отклонения распределения объема газопотребления по месяцам от 1994 до 2003 гг. для каждого класса. На их основе вычислена функция нормального распределения по формуле (5). В начале обучения весовые коэффициенты принимались одинаковыми, вычисленными по формуле (6), а последующие итерации

вычислены по формуле (7). Принимается следующий вид функции  $\beta$  :

$$\beta = \frac{i}{N} \quad (8)$$

где:

$N$ - достаточно большое число, которое принималось при исследованиях в качестве общего числа всех итерации;

$i$ - номер итерации.

Таблица 2

Параметры компетентного окна в конце обучения

класс 1							
Базовые годы	Параметры компетентного окна	Номер элемента					
		1	2	3	4	5	6
2002	$h_t$	$1,82*10^{-08}$	$2,58*10^{-07}$	$4,93*10^{-08}$	$1,33*10^{-08}$	$6,88*10^{-09}$	$4,69*10^{-09}$
	$M_t$	140396,3	110259,8	93170,93	89129,7	98136,13	120190,2
	$D_t$	$5,49*10^{+07}$	$3,87*10^{+06}$	$2,03*10^{+07}$	$7,52*10^{+07}$	$1,45*10^{+08}$	$2,13*10^{+08}$
2003	$h_t$	$3,53*10^{-08}$	$2,04*10^{-08}$	$9,48*10^{-09}$	$5,57*10^{-09}$	$3,89*10^{-09}$	$3,06*10^{-09}$
	$M_t$	139134,1	112842,8	99063,68	97796,7	109041,9	132799,2
	$D_t$	$2,83*10^{+07}$	$4,90*10^{+07}$	$1,05*10^{+08}$	$1,8*10^{+08}$	$2,57*10^{+08}$	$3,27*10^{+08}$
класс 2							
2002	$h_t$	$6,75*10^{-09}$	$6,52*10^{-09}$	$5,22*10^{-10}$	$1,45*10^{-10}$	$5,87*10^{-11}$	$2,89*10^{-11}$
	$M_t$	290220,2	253000,3	242842,8	259747,7	303714,8	374744,3
	$D_t$	$1,48*10^{+08}$	$1,53*10^{+08}$	$1,92*10^{+09}$	$6,91*10^{+09}$	$1,7*10^{+10}$	$3,46*10^{+10}$
2003	$h_t$	$3,69*10^{-09}$	$1,49*10^{-08}$	$1,17*10^{-08}$	$1,54*10^{-08}$	$5,43*10^{-08}$	$6,52*10^{-09}$
	$M_t$	286074,5	244555	219810,5	211841	220646,5	246227
	$D_t$	$2,71*10^{+08}$	$6,71*10^{+07}$	$8,58*10^{+07}$	$6,49*10^{+07}$	$1,84*10^{+06}$	$1,53*10^{+08}$

Таблица 3

Весовые коэффициенты  $w*10^{-06}$  по сети 2 в конце обучения

годы	класс 1				класс 2						класс 1	
	1	2	3	4	5	6	7	8	9	10	11	12
1994	3,08	1,63	1,18	1,53	3,21	6,53	7,72	9,24	1,14	1,12	4,21	0,86
1995	5,50	4,45	1,89	2,88	9,80	7,49	5,23	4,59	3,48	2,24	6,09	2,54
1996	3,06	2,53	2,81	3,31	9,84	7,38	5,08	4,91	4,84	4,92	5,42	2,54
1997	4,62	3,99	3,52	3,67	9,76	7,25	4,92	5,21	5,67	4,45	4,49	0,52
1998	2,87	3,42	3,67	4,04	9,68	5,11	6,28	5,15	4,23	4,00	6,10	3,08
1999	3,70	1,52	1,14	1,80	8,80	6,33	6,25	6,17	5,63	5,21	4,16	2,46
2000	2,26	3,04	2,99	0,77	5,35	6,55	5,32	5,07	5,47	5,25	6,35	2,57
2001	4,36	3,82	3,35	3,26	9,57	7,09	4,90	4,45	2,46	3,84	5,31	2,85
2002	4,33	4,14	3,61	3,61	8,08	7,51	4,47	3,77	3,20	1,65	3,16	1,13
2003	4,72	4,09	2,83	3,31	7,59	4,74	4,54	3,66	4,00	3,02	5,38	0,30

Вычислены параметры  $a_k$  по формуле (4) и выход нейрона по формуле (3). Отметим следующие особенности обучения нейронной сети 2:

- В отличие от нейронной сети 1, все нейроны одновременно активизируются.

- В каждой итерации принимаются новые значения функции  $\beta$  и выход проверяется, сравнивается с результатами предыдущей итерации. Если эти результаты не отличаются, то итерация прекращается и результат принимается как выход скрытого слоя.

- Выход сети получается в виде нормированной единицы, поэтому нужно перевести полученные результаты в натуральные единицы с помощью формулы (1).

Весовые коэффициенты в конце обучения показаны в табл. 3. Как видно из таблицы, весовые коэффициенты для 2-го класса в несколько раз больше весовых коэффициентов для 1-го класса.

### Обучение по сети 3

Скрытый слой от входного слоя принимает все обучающие данные. Данные сгруппировались по месяцам. Для каждой группы вычисляются автокорреляционные функции. Эти функции аппроксимировались в виде  $e^{-\alpha t} \cos \beta t$ . После определения неизвестных коэффициентов  $\alpha$  и  $\beta$  вычислены коэффициенты  $\varphi_k$  (табл. 4). Следует отметить, что при вычислении использованы аппроксимированные формулы дельта-функций. Вычисляются прогнозные значения при  $T=1$ . Если полученные прогнозные значения удовлетворяют точности предъявляемой к результатам, то эти значения принимаются как выход сети, в обратном случае увеличиваем число входных данных и процесс повторяется с вычислением автокорреляционных функций.

Исследования показывают, что предварительная обработка данных, из которых формируется обучающая выборка, позволяет увеличить точность нейросетевого прогнозирования. Увеличение ошибки обработанных данных объясняется увеличением противоречивости обучающих данных. Анализ и обработка результатов трех нейронных сетей после первой итерации показывает, что более



точные результаты получены для второй сети, примерно в среднем 5 %. Результаты этой сети добавим в обучающие выборки первой и третьей сети и обучим их. В результате повышается их точность прогнозирования на 0.5 % в среднем. Это означает, что использование результатов трех независимых нейронных сетей улучшает качество прогнозирования объема газопотребления и повышает доверие к полученным прогнозам. На рис. 3. показана гистограмма ошибок нейронных сетей.

Таблица 4

Значение коэффициентов  $\varphi_k$  для нейронной сети 3

Класс 1						
значение аргумента	номер элемента					
	1	2	3	4	5	6
11	7,0710	9,2385	9,5090	9,7092	9,5931	9,0096
10	7,0710	9,2382	9,5079	9,7090	9,5919	9,0093
9	7,0709	9,2376	9,5058	9,7086	9,5898	9,0089
8	7,0706	9,2362	9,5024	9,7078	9,5862	9,0078
7	7,0696	9,2334	9,4963	9,7062	9,5803	9,0055
6	7,0668	9,2276	9,4858	9,7032	9,5702	9,0002
5	7,0583	9,2156	9,4676	9,6974	9,5533	8,9887
4	7,0329	9,1908	9,4359	9,6862	9,5247	8,9633
3	6,9569	9,1393	9,3810	9,6645	9,4766	8,9071
2	6,7298	9,0327	9,2856	9,6225	9,3956	8,7828
1	6,0508	8,8120	9,1202	9,5415	9,2590	8,5080
Класс 2						
11	7,0710	9,2385	9,5090	9,7092	9,5931	9,0096
10	7,0710	9,2382	9,5079	9,7090	9,5919	9,0093
9	7,0709	9,2376	9,5058	9,7086	9,5898	9,0089
8	7,0706	9,2362	9,5024	9,7078	9,5862	9,0078
7	7,0696	9,2334	9,4963	9,7062	9,5803	9,0055
6	7,0668	9,2276	9,4858	9,7032	9,5702	9,0002
5	7,0583	9,2156	9,4676	9,6974	9,5533	8,9887
4	7,0329	9,1908	9,4359	9,6862	9,5247	8,9633
3	6,9569	9,1393	9,3810	9,6645	9,4766	8,9071
2	6,7298	9,0327	9,2856	9,6225	9,3956	8,7828
1	6,0508	8,8120	9,1202	9,5415	9,2590	8,5080

Результат алгоритма работы обученной нейронной сети показан на рис.4.




Рис.3. Гистограмма ошибок нейронных сетей

месяц




Рис.4. Прогнозные данные за 2004, вычисленные по нейронным сетям

— — —	потребление в 2004 г	— — —	по нейронной сети 1
- - -	по нейронной сети 2	— — —	по нейронной сети 3
— — —	результат нейронной сети		

Нетрадиционный подход к краткосрочному прогнозированию объема газопотребления с использованием трех нейронных сетей повышает совершенство моделей прогноза, заключающееся в возможности использования предлагаемой методики для прогнозирования потребляемого газа различными категориями потребителей. Такие модели легко адаптируются к изменениям в системе газопотребления и независимы от состава потребителей.

### Литература

1. Агаев Н.Б. Проблемы создания прогностических моделей объема газопотребления //Азербайджанское Нефтяное Хозяйство. 1998, №4, с. 33-37.
2. Уоссерман Ф. Нейрокомпьютерная техника: теория и практика. М., Мир, 1992. 256 стр.
3. Елкина В.Н., Загоруйко Н.Г., Новоселов Ю.А. Математические методы агроинформатики. ИМ СО АН СССР, Новосибирск, 1987 г.
4. Агаев Н.Б. Об одном методе стохастического прогнозирования объема газопотребления //Азербайджанское Нефтяное Хозяйство. 2004, №4, с. 51-54.