

УДК 556.16

**Н.С. Лобода, проф., Н.Д. Довженко, асп.**

*Одесский государственный экологический университет*

## **МОДЕЛИРОВАНИЕ БЫТОВОГО СТОКА ПРИ НАЛИЧИИ ВОДОПОТРЕБЛЕНИЯ ЗА СЧЕТ МЕСТНЫХ ВОДНЫХ РЕСУРСОВ С ПРИМЕНЕНИЕМ НЕЙРОННЫХ СЕТЕЙ**

*Приводятся результаты нейросетевого моделирования бытового стока р. Салгир – г. Симферополь в условиях забора воды из местных водных ресурсов с целью снабжение населения водой.*

**Ключевые слова:** *нейронная сеть, бытовой сток.*

**Вступление.** Для расчетов и прогнозов состояния водных ресурсов в условиях водохозяйственных преобразований широко используется имитационное моделирование. В Одесском государственном экологическом университете разработана стохастическая модель годового стока при наличии таких антропогенных воздействий как орошение, осушение, переброска стока, водопотребление [4, 6]. Основной задачей моделирования является получение «функций отклика» водосборов на водохозяйственные преобразования. При имитационном стохастическом моделировании функция отклика представлялась в виде графической зависимости статистических параметров стока от основных количественных показателей масштабов водохозяйственного освоения территории (например, относительной площади орошаемых земель, относительной площади искусственных водоемов и т.д.) [5]. При значительном числе показателей уровня водохозяйственного освоения водосборов было выполнено аналитическое обобщение результатов имитационного моделирования, при котором были построены уравнения множественных регрессий, описывающие изменения большого числа показателей орошаемых водосборов (относительная площадь орошения, относительное увлажнение почвы, положение орошаемых массивов относительно водозабора и т.д.) [4]. Определенный интерес при построении «функций отклика» представляет нейросетевое моделирование. Преимущество последнего состоит в оперативном получении этой функции после тщательного обучения системы.

Целью данной работы является применение нейросетевого моделирования к построению «функций отклика» водосборов на водохозяйственные мероприятия.

**Материалы и методы исследований.** Под нейронными сетями подразумеваются вычислительные структуры, которые моделируют простые биологические процессы [1,2]. Адаптируемые и обучаемые, они представляют собой распараллельные системы, способные к обучению путем анализа входных воздействий. Элементарным преобразователем в данных сетях является нейрон. С помощью нейронных сетей можно решить ряд задач, а именно:

- Классификация образов. Задача состоит в указании принадлежности входного образа, представленного вектором признаков, одному или нескольким предварительно определенным классам.
- Кластеризация (категоризация). Алгоритм кластеризации основан на сходимости образов и размещает близкие образы в один кластер.

- Аппроксимационная функция. Задача аппроксимации состоит в нахождении неизвестной функции. Аппроксимация функции необходима при решении многочисленных инженерных и научных задач моделирования.
- Предсказание (прогноз).
- Оптимизация. Задачей алгоритма оптимизации является нахождение такого решения, которое удовлетворяет системе ограничений и максимизирует или минимизирует целевую функцию.
- Память, адресуемая по содержанию. Ассоциативная память, или память, адресуемая по содержанию, чрезвычайно желательна при создании мультимедийных информационных баз данных.
- Управление. В системах управления с эталонной моделью целью управления является расчет такого входного воздействия, при котором система следует по желаемой траектории, диктуемой эталонной моделью.

**Материалы и методы исследований.** В работе использован метод стохастического моделирования и метод нейросетевого моделирования. Для обучения нейросети использованы результаты стохастического моделирования (статистические параметры бытового стока за год), полученные при применении стохастической модели вида

$$Y_{B,E} = Y_{E,P} - \frac{d_{P,100-P} \times N_{HAC}}{F} \times K_{разм}, \quad (1)$$

где  $Y_{B,P}$ ,  $Y_{E,P}$  - естественный и бытовой сток с заданной обеспеченностью  $P$ , выраженный мм;

$d_{P,100-P}$  - норма водопотребления, выраженная л/чел/сутки;

$N_{HAC}$  - количество населения, чел.;

$F$  - площадь водосбора;

$K_{разм}$  - коэффициент размерности, равный 3.16.

Функция отклика при этом имеет следующий графический вид.

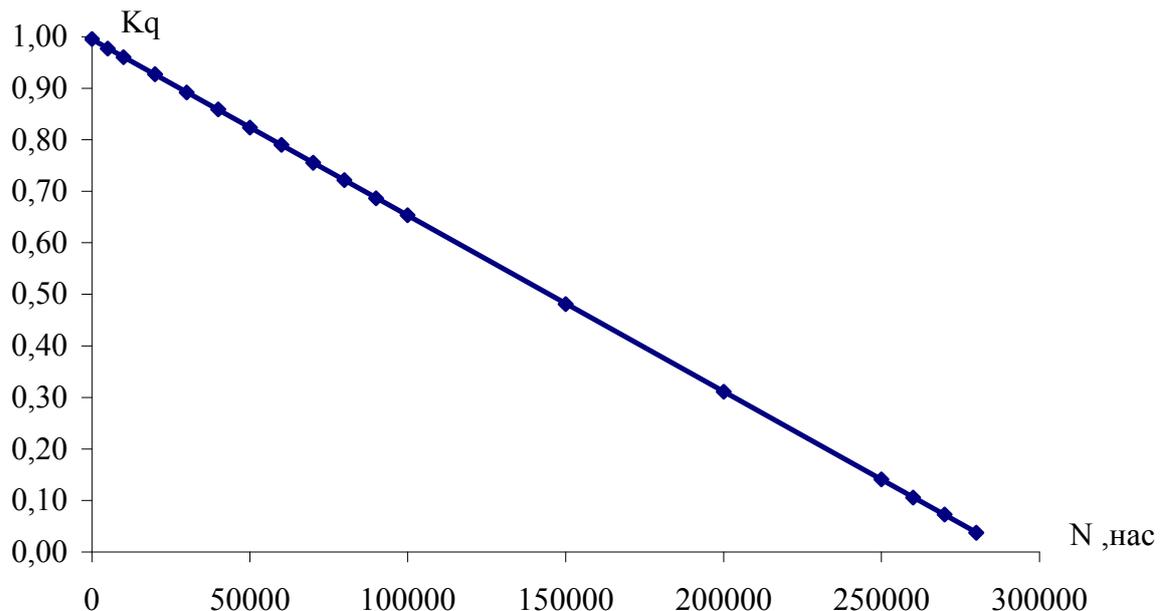


Рисунок 1 – Функция антропогенного влияния на норму стока, полученная в результате моделирования бытового стока в условиях забора воды из местных водных ресурсов (р. Салгир) на снабжение жителей г. Симферополь водой.

На входе в нейросеть в качестве входного сигнала использовано количество населения  $N$ ; на выходе – обучающие выборки в виде среднесуточных величин бытового стока и коэффициентов вариации, полученных в результате имитационного стохастического моделирования. Нейрон – это составная часть нейронной сети [7]. В состав нейрона входят множители (синапсы), сумматор и нелинейный преобразователь. Синапсы осуществляют связь между нейронами и умножают входной сигнал на число, характеризующее силу связи, - вес синапса. Сумматор выполняет сложение сигналов, поступающих по синаптическим связям от других нейронов, и внешних входных сигналов. Нелинейный преобразователь реализует нелинейную функцию одного аргумента – выхода сумматора. Эта функция называется «функция активации» или «передаточная функция» нейрона. Нейрон в целом реализует скалярную функцию векторного аргумента. Математическая модель нейрона описывается соотношениями

$$S = \sum_{i=1}^n w_i x_i + b, \quad (2)$$

где  $w_i$  - вес синапса ( $i = 1, \dots, n$ );

$b$  – значение смещения;

$S$  – результат суммирования;

$x_i$  – компонента входного вектора (входной сигнал) ( $i = 1, \dots, n$ ).

В общем случае входной сигнал, весовые коэффициенты и значения смещения могут принимать действительные значения. Выход определяется видом функции активации и может быть как действительным, так и целым.

Синаптические связи с положительными весами называют возбуждающими, с отрицательными весами – тормозящими.

На входной сигнал ( $S$ ) нелинейный преобразователь отвечает выходным сигналом  $f(S)$ , который представляет собой выход нейрона  $y$ .

Одной из наиболее распространенных является нелинейная функция с насыщением, так называемая логистическая функция или сигмоид

$$f(S) = \frac{1}{1 + e^{-as}}. \quad (3)$$

Следует отметить, что сигмоидная функция дифференцируема на всей оси абсцисс, что используется в некоторых алгоритмах обучения. Кроме того, она обладает свойством усиливать слабые сигналы лучше, чем большие, и предотвращает насыщение от больших сигналов, так как они соответствуют областям аргументов, где сигмоид имеет пологий наклон.

Необходимо отметить принцип параллельной обработки в нейронных сетях, который достигается путем объединения большого числа нейронов в так называемые слои и соединения определенным образом нейронов различных слоев, а также, в некоторых конфигурациях, и нейронов одного слоя между собой, причем обработка взаимодействия всех нейронов ведется послойно.

Одно из главных преимуществ нейронных сетей заключается в том, что они предполагают наличие правил, с помощью которых сеть может программироваться автоматически. Типичной формой обучения является управляемое обучение, когда для каждого набора данных, подающегося в процессе обучения на вход сети, соответствующий выходной набор известен. Обычно в начале обучения весовые коэффициенты устанавливаются равными случайным малым значениям, например, из

диапазона  $(-0,3, +0,3)$ , так что в первый раз при предъявлении сети учебного образца оказывается весьма маловероятным, чтобы сеть произвела правильный вывод. Расхождение между тем, что даст сеть, и тем, что для данного учебного набора должно быть получено на самом деле, составляет ошибку, которая может использоваться для корректировки весов. Данные, используемые для обучения нейронной сети, обычно разделяют на две категории: одни данные используют для обучения, а другие – для тестирования. На самом деле реальные качества нейронной сети выявляются только во время тестирования, поскольку успешное завершение обучения сети должно означать отсутствие признаков неправильной работы сети во время ее тестирования. Процесс тестирования разрабатывается так, чтобы в его ходе для данной сети можно было бы оценить ее способность обобщать полученные знания. Обобщение в данном случае означает способность сети правильно выполнять задачу с данными, которые оказываются хотя и аналогичными данными, но все же отличными от них.

Один из самых распространенных алгоритмов обучения – алгоритм обратного распространения ошибки [8]. Это итеративный градиентный алгоритм обучения, который используется с целью минимизации среднеквадратического отклонения текущего выхода и желаемого выхода многослойных нейронных сетей.

Алгоритм обратного распространения используется для обучения многослойных нейронных сетей с последовательными связями вида рис. 2.

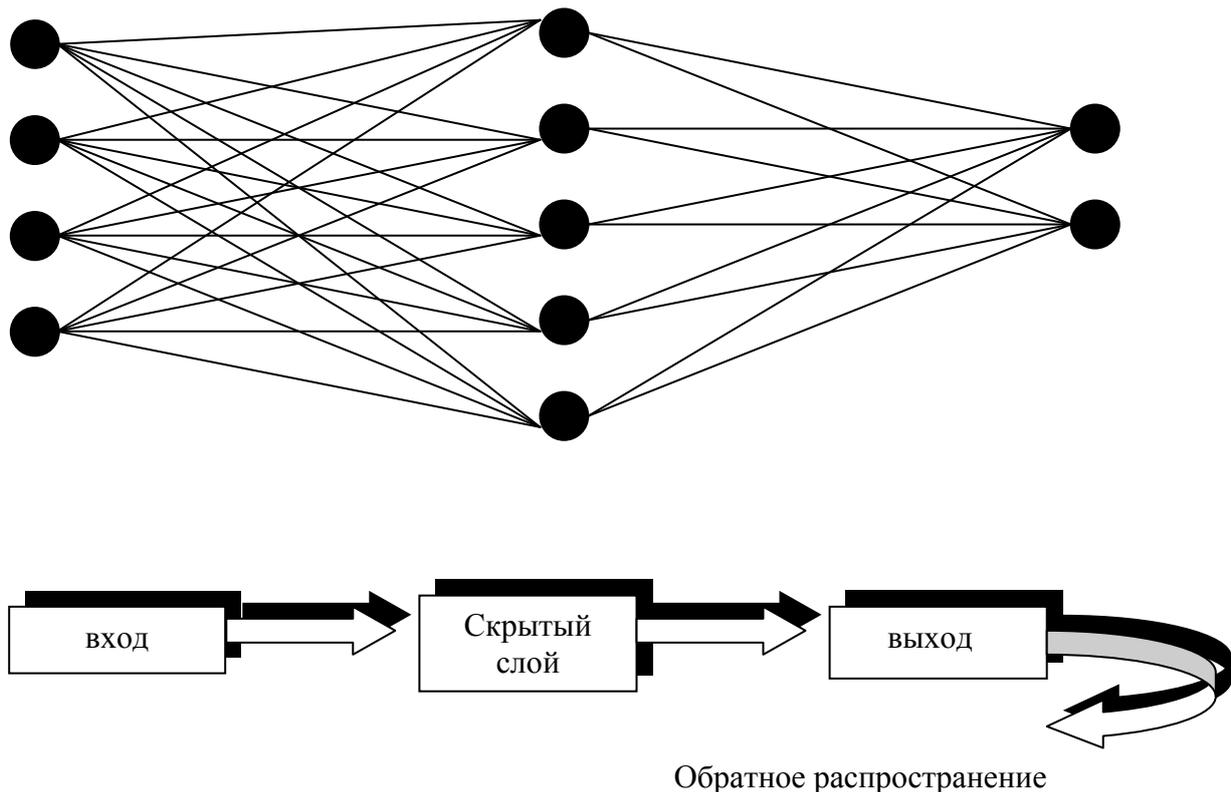


Рисунок 2 – Схема нейронной сети с применением алгоритма обратного распространения (с одним скрытым слоем).

В данном алгоритме функция ошибки представляет собой сумму квадратов рассогласования (ошибки) желаемого выхода сети и реального. При вычислении элементов вектора-градиента использован своеобразный вид производных функций активации сигмоидального типа. Алгоритм действует циклически (итеративно), и его

циклы принято называть эпохами. На каждой эпохе на вход сети поочередно подаются все обучающие наблюдения, выходные значения сети сравниваются с целевыми значениями и вычисляется ошибка. Значение ошибки, а также градиента поверхности ошибок используется для корректировки весов, после чего все действия повторяются. Начальная конфигурация сети выбирается случайным образом, и процесс обучения прекращается, либо когда пройдено определенное количество эпох, либо когда ошибка достигнет некоторого определенного уровня малости, либо когда ошибка перестанет уменьшаться (пользователь сам может выбрать нужное условие остановки).

**Результаты исследования и анализ.** В работе использовались результаты имитационного стохастического моделирования бытового стока при наличии водопотребления за счет местных водных ресурсов. Целью данной работы было моделирование бытового стока с помощью нейронных сетей. В качестве входных сигналов использовалось количество населения. В данном случае применялась линейная нейронная сеть. Линейная модель обычно задается уравнением

$$Y=XW+B, \quad (4)$$

где  $W$  – матрица весов сети,

$B$  – вектор смещения.

На языке нейронных сетей линейная модель представляется сетью без промежуточных слоев, которая в выходном слое содержит только линейные элементы. Веса соответствуют элементам матрицы, а пороги – компонентам вектора смещения. Во время работы сеть фактически умножает вектор входов на матрицу весов, а затем к полученному вектору прибавляет вектор смещения.

Моделирование бытового стока с помощью нейросети производилось для р. Салгир – г. Симферополь. Результаты испытаний и их сравнение с результатами стохастического моделирования сведены в табл. 1.

Таблица 1 – Результаты нейросетевого моделирования бытового стока и их сравнение с результатами стохастической модели для р. Салгир – г. Симферополь

N, Количество населения	Параметры стохастической модели		Параметры нейронной сети		Ошибка нейронной сети	
	$q$	$Cv$	$q$	$Cv$	$q$	$Cv$
5000	4,71	0,521	4,7132	0,50691	-0,0032	0,01409
10000	4,63	0,532	4,6308	0,52352	-0,0008	0,00848
20000	4,47	0,557	4,4661	0,55674	0,0039	0,00026
30000	4,3	0,583	4,3013	0,58996	-0,0013	-0,00696
40000	4,14	0,611	4,1366	0,62318	0,0034	-0,01218
50000	3,97	0,642	3,9718	0,6564	-0,0018	-0,0144
60000	3,81	0,676	3,807	0,68962	0,003	-0,01362
70000	3,64	0,712	3,6423	0,72284	-0,0023	-0,01084
80000	3,48	0,752	3,4775	0,75606	0,0025	-0,00406
90000	3,31	0,796	3,3128	0,78928	-0,0028	0,00672
100000	3,15	0,845	3,148	0,82249	0,002	0,02251

Как видно из табл. 1, нейронная сеть моделирует достаточно точно. Но при этом все смоделированные значения могут быть представлены линейной функцией, что не всегда отвечает действительности. В таких случаях необходимо сменить функцию

обучения нейросети. Более практично использовать нейронную сеть с алгоритмом обратного распространения.

Алгоритм работает по следующему принципу:

Шаг 1. Весам сети присваиваются небольшие начальные значения.

Шаг 2. Выбирается очередная обучающая пара (X, Y) из обучающего множества; вектор X подается на вход сети.

Шаг 3. Вычисляется выход сети.

Шаг 4. Вычисляется разность между требуемым (целевым, Y) и реальным (вычисленным) выходом сети.

Шаг 5. Веса сети корректируются так, чтобы минимизировать ошибку.

Шаг 6. Шаги со 2-го по 5-й повторяются для каждой пары обучающего множества до тех пор, пока ошибка на всем множестве не достигнет приемлемой величины.

Шаги 2 и 3 подобны тем, которые выполняются в уже обученной сети.

Вычисления в сети выполняются послойно. На шаге 3 каждый из выходов сети вычисляется из соответствующей компоненты целевого вектора с целью получения ошибки. Эта ошибка используется на шаге 5 для коррекции весов сети.

Шаги 2 и 3 можно рассматривать как «проход вперед», так как сигнал распространяется по сети от входа к выходу. Шаги 4 и 5 составляют «обратный проход», поскольку здесь вычисляемый сигнал ошибки распространяется обратно по сети и используется для подстройки весов.

Для обучения алгоритма обратного распространения использовалась TRAINLM функция. Она возвращает веса и смещения нейросети, используя алгоритм оптимизации Левенберга-Марквардта. Для настройки сети применялась функция LEARNNGDM. Функции данной группы являются вспомогательными при работе с некоторыми функциями обучения нейронной сети, а также используются при настройках однослойных нейросетевых структур. LEARNNGDM – функция корректировки весов и смещений, реализующая градиентный метод с инерционной составляющей. В качестве функции активности использовалась сигмоидальная функция. Примером может служить логистическая функция, показанная на рис. 3.

$$f(net) = \frac{1}{1 + \exp(-net)} \quad (5)$$

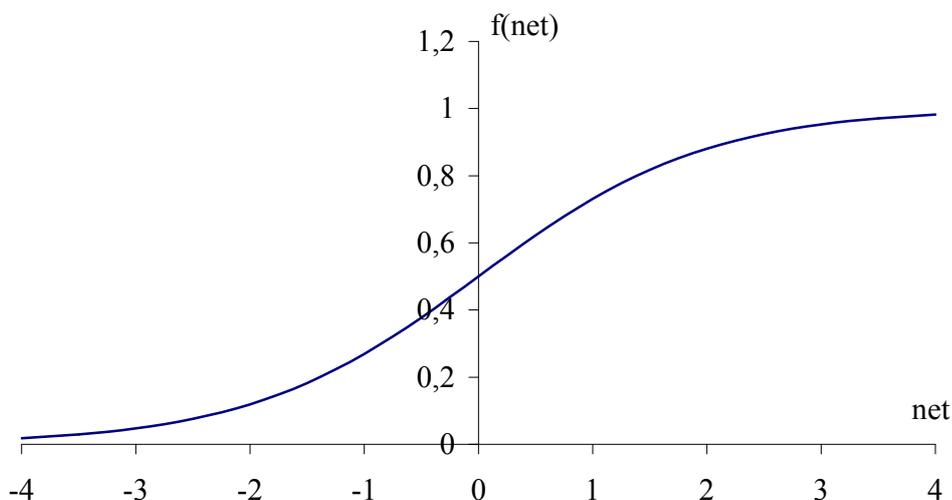


Рисунок 3 – Сигмоидальная функция.

Алгоритм обратного распространения с приведенными выше параметрами был применен для моделирования коэффициента вариации. По результатам стохастического моделирования значения искомого параметра могут быть описаны экспоненциальной функцией. Применение линейной нейронной сети не дал ожидаемого результата. В случае использования алгоритма обратного распространения смоделированные коэффициенты вариации приведены в табл. 2.

Таблица 2 – Сравнение коэффициентов вариации, полученных при стохастическом и нейросетевом моделировании

Количество населения	5000	10000	20000	30000	40000	50000	60000	70000	80000	90000	100000
Результаты стохастического моделирования	0,521	0,532	0,557	0,583	0,611	0,642	0,676	0,712	0,752	0,796	0,845
Результаты нейросетевого моделирования	0,52411	0,53364	0,55508	0,5799	0,60835	0,64049	0,67621	0,71503	0,75611	0,79814	0,83944

Как видно из табл. 2 нейронная сеть с применением алгоритма обратного распространения дает удовлетворительные результаты. К тому же они могут быть описаны нелинейной функцией, чего необходимо было достичь.

**Выводы.** Решения на основе нейронных сетей становятся более усовершенствованными, и, без сомнения, возможности по разработке соответствующих устройств вырастут за счет понимания их основных принципов. Необходимо отметить, что нейронная сеть может обучаться исполнению поставленной задачи, и обычно не программируется. Обучение заключается в изменении значений весовых коэффициентов.

Основным недостатком аппарата нейронных сетей являются: отсутствие строгой теории по выбору структуры нейронной сети; практически невозможность извлечения приобретенных знаний из обученной нейросети (нейронная сеть практически всегда – «вещь в себе», черный ящик для исследователя).

### Список литературы

1. Глушков А.В., Лобода А.В., Свиначенко А.А. Теория нейронных сетей на основе фотонного эха.- Одесса. – ТЭС. –2004. – 172 с.
2. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика.- М.: Горячая линия - Телеком, 2001. -382с.
3. Лобода Н.С. Системный подход и функции отклика гидрологической системы на антропогенные воздействия при математическом моделировании бытового стока // Міжвід. наук. зб. України. - Метеорологія, кліматологія та гідрологія. - Одеса. - 2004. – Вип. 48. - С. 416 – 424.

4. Лобода Н.С. Расчеты и обобщения характеристик годового стока рек Украины в условиях антропогенного влияния: Монография.–Одесса: Экология, 2005. 208 с.
5. Лобода Н.С., Гопченко Є.Д. Стохастичні моделі у гідрологічних розрахунках. - Навчальний посібник.– Одеса: Екологія, 2006. – 200 с.
6. Лобода Н.С., Довженко Н.Д. Моделирование рядов бытового стока при наличии водопотребления за счет местных водных ресурсов // Вестник одесского государственного экологического университета – Одесса. – 2006. – Вып. 3. – С. 151-159.
7. Chetan, M. and K..P. Sudheer A hybrid linear-neural model for river flow forecasting // Water resources research,42,W04402,doi:10.1029/2005WR004072.
8. Loboda N.S. Neural networks and multi-fractal modelling of non-linear complex systems // Науковий вісник Ужгородського університету. – Ужгород. – 2002. – Вип. 10. – С.119-121.

**Моделирование бытового стока при наличии водокористування за рахунок місцевих водних ресурсів з використанням нейронних мереж. Лобода Н.С., Довженко Н.Д.**

*Приводяться результати нейромережевого моделювання побутового стоку р. Салгір – м. Сімферополь в умовах забору води з місцевих водних ресурсів з метою постачання населення водою.*

**Ключові слова:** нейронна мережа, побутовий стік.

**The modeling of lifeconditioned runoff in the presence of waterusing owing to local water resources using neural network. Loboda N.S., Dovzhenko N.D.**

*Results of neural network modeling of r. Salgir –s. Simferopol's lifeconditioned runoff in the conditions of water fencefrom local water resources for supply the populations of water are presented.*

**Keywords:** neural network, lifeconditioned runoff