



УДК 62-50:61

© Д. А. Королев, В. Г. Суфиянов, 2007

НЕЙРОЭВОЛЮЦИОННЫЙ ПОДХОД К ОПТИМИЗАЦИИ ВНУТРЕННЕЙ СТРУКТУРЫ НЕЙРОННЫХ СЕТЕЙ

Королев Д. А. – асп. кафедры «Математическое моделирование процессов и технологий»; *Суфиянов В. Г.* – канд. физ.-мат. наук, доц. кафедры «Математическое моделирование процессов и технологий» (ИжГТУ)

В статье рассматривается применение генетического алгоритма для оптимизации топологии искусственной нейронной сети. Проведенные исследования на тестовых задачах аппроксимации и экстраполяции показали эффективность применения эволюционного подхода для нахождения оптимального количества нейронов в «скрытых» слоях и количества связей между нейронами сети.

In the article application of genetic algorithm for optimization of topology of an artificial neural net is considered. Carried out research on test tasks of approximation and extrapolation has shown the efficiency of application of the evolutionary approach for finding the optimum quantity of neurons in the "latent" layers and a number of bonds between net neurons.

Введение

Практическое применение нейросетевых технологий связано с решением двух актуальных проблем – выбора топологии и настройки весовых коэффициентов связей искусственных нейронных сетей (ИНС), от которых зависит качество (адекватность) нейросетевой модели [1]. Выбор архитектуры ИНС обычно осуществляется экспертами методом проб и ошибок. Весьма продуктивной альтернативой для решения подобных задач перебора является эволюционный подход к проектированию оптимальной (или почти оптимальной) архитектуры нейронной сети. Один из возможных методов – формирование архитектуры с применением генетического алгоритма (ГА) [2, с. 1423–1447], который является наиболее популярной разновидностью эволюционных алгоритмов оптимизации [3], [4, с. 341–361], [5, с. 762–767], [6, с. 299–316].

Нейроэволюционный подход к проектированию нейронной сети

Проектирование оптимальной топологии нейронной сети может быть представлено в виде поиска такой архитектуры, которая обеспечивает наилучшее (относительно выбранного критерия) решение конкретной задачи. Такой подход предполагает перебор пространства архитектуры, составленного из всех возможных вариантов, и выбор точки этого пространства, наилучшей относительно заданного критерия оптимальности.

С учетом достоинств эволюционного проектирования архитектуры в последние годы было выполнено большое количество исследований, в которых основное внимание уделялось оптимизации структуры нейронной сети: выбору оптимального числа нейронов в «скрытых» слоях сети и топологии связей между ними [4, с. 341–361], [7]. В качестве критерия оптимальности рассматриваются два критерия: минимизация ошибки обучения на контрольной группе и минимизация сложности архитектуры нейронной сети [8, с. 1–37], [9].

Первый этап эволюционного проектирования архитектуры заключается в принятии решения относительно соответствующей формы ее описания. Полная информация об архитектуре может непосредственно кодироваться в виде двоичных последовательностей, т. е. каждая связь и каждый узел (нейрон) прямо специфицируется определенным количеством битов. Схема непосредственного кодирования архитектуры ИНС называется прямым кодированием (direct encoding). При данной схеме информация о структуре представляется в хромосоме в виде матрицы связей (матрицы смежности) [10] либо в виде списка связей.

Матрица $C = (c_{ij})$, размерностью $l \times l$, представляет связи нейронной сети, значение $c_{ij} = 1$ определяет наличие связи между i -м и j -м нейронами, а $c_{ij} = 0$ – отсутствие связи [4, 10].

Классический вариант непосредственного кодирования структуры ИНС имеет очевидный недостаток, заключающийся в стремительном увеличении длины хромосом при увеличении размеров нейронной сети. Внесение ограничений в данную схему кодирования позволяет значительно сократить длину хромосом, в частности:

- рассматриваются только однонаправленные связи, что позволяет учитывать только те элементы матрицы C , которые задают связи данного узла (нейрона) со следующим узлом;
- нейроны одного слоя сети не могут иметь связей друг с другом;
- в случае ИНС без обратных связей можно рассматривать только часть матрицы связей, расположенную справа от главной диагонали.



Пример прямого кодирования структуры ИНС с использованием матрицы связей для ИНС без обратных связей с учетом применения перечисленных выше ограничений представлен в табл. 1.

Таблица 1

**Пример прямого кодирования структуры ИНС
с использованием матрицы связей**

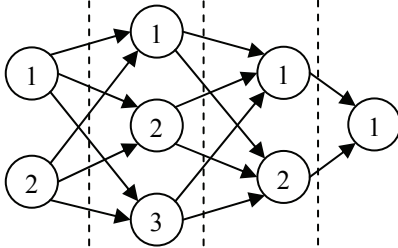
Нейронная сеть	Матрица связей	Хромосома
<p>Слой: 0 1 2</p>	$\begin{pmatrix} 0 & 0 & 1 & 1 & 1 & 0 \\ 0 & 0 & 1 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{pmatrix}$	<p>(11101110111)</p>

Использование НЭ подхода для нахождения оптимального количества нейронов в «скрытых» слоях нейронной сети предполагает описание ИНС в виде бинарной последовательности, в которой будут закодированы уже не связи сети, а количество нейронов на каждом из ее «скрытых» слоев.

Количество нейронов в каждом внутреннем слое сети непосредственно задается его двоичным представлением, при этом должно быть задано максимальное количество нейронов в каждом внутреннем слое, которое и будет определять длину двоичного представления количества нейронов в «скрытом» слое сети [10], [11, с. 397–404]. Под геном понимается количество нейронов в отдельном внутреннем слое сети, количество генов равно количеству «скрытых» слоев нейронной сети. Совокупность всех генов образует хромосому, представленную вектором \vec{C} размерностью $k \cdot s$, где k – количество «скрытых» слоев ИНС, а s – длина гена. Пример рассматриваемого способа кодирования для ИНС с двумя «скрытыми» слоями (с максимальным количеством нейронов во внутренних слоях равным 15) представлен в табл. 2.

Таблица 2

Пример кодирования количества нейронов в «скрытых» слоях ИНС

Нейронная сеть	Гены	Хромосома
 <p>Слой: 0 1 2 3</p>	<p>(0011) (0010)</p>	<p>(00110010)</p>

Второй этап, в соответствии с типовым циклом [2] эволюционного проектирования архитектуры нейронной сети, состоит из пяти шагов:

- 1) декодирование каждой особи текущей популяции для описания архитектуры ИНС;
- 2) обучение каждой нейронной сети с архитектурой, полученной на первом шаге;
- 3) оценивание приспособленности каждой особи (закодированной архитектуры) по достигнутым результатам обучения;
- 4) репродукция особей с вероятностью, соответствующей их приспособленности или рангу в зависимости от используемого метода селекции;
- 5) формирование нового поколения в результате применения таких генетических операторов, как скрещивание, мутация и инверсия.

Алгоритм, иллюстрирующий эволюцию архитектур нейронной сети, приведен на рис. 1.

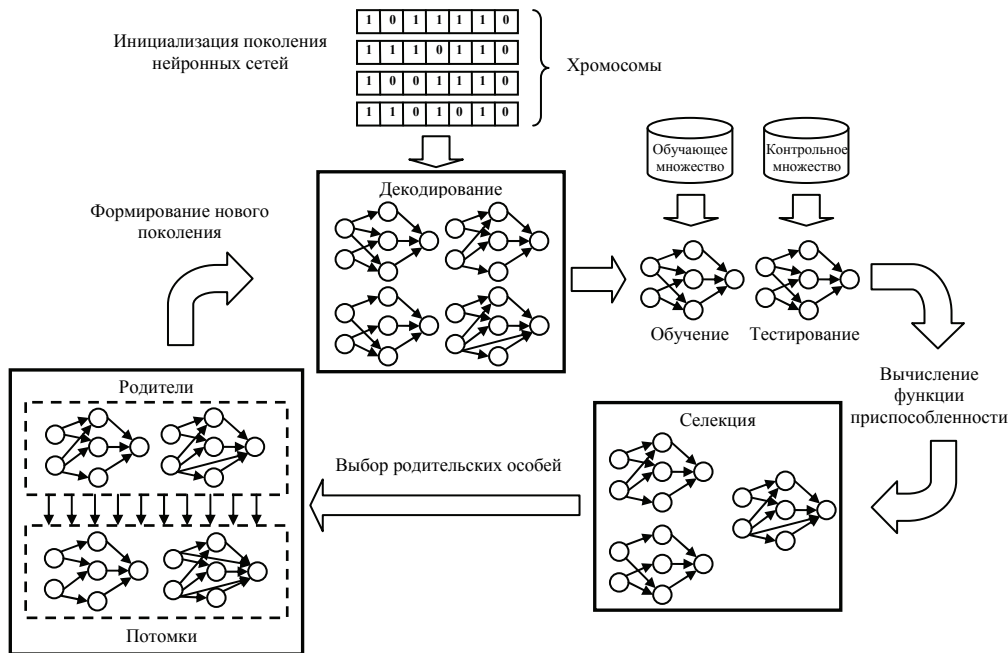


Рис. 1. Алгоритм поиска наилучшей архитектуры нейронной сети

Вид функции приспособленности выбирается в зависимости от того, с какими свойствами требуется получить нейронную сеть [9, с. 643–649]. В классическом виде приспособленность каждой особи оценивается по наименьшей среднеквадратичной погрешности обучения, зафиксированной на обучающем множестве данных после определенного количества эпох обучения. Среднеквадратическая погрешность рассчитывается по формуле:

$$E_w = \sqrt{\frac{1}{n} \sum_{q=1}^n (y_q - d_q)^2},$$

где y_q соответствует выходу при подаче на вход q -го образа; d_q – заданное значение выхода; n – объем обучающей выборки. Тогда функция приспособленности F_1 будет иметь следующий вид [1]:

$$F_1 = S - E_w.$$

Здесь S – некоторая постоянная, которая позволяет нейронным сетям с меньшей среднеквадратической погрешностью E_w поставить в соответствие большее значение функции приспособленности. Таким образом, после вычисления значений функции приспособленности для каждой особи популяции нейронная сеть с наилучшими свойствами (в данном случае с наименьшей среднеквадратической погрешностью



обучения) будет иметь наибольшее среди всех особей значение функции приспособленности.

Если при решении задачи наибольший интерес вызывает способность нейронной сети к обобщению, тогда для вычисления значений функции приспособленности в выражении (1) следует использовать среднеквадратическую погрешность на контрольном множестве [2].

Эволюционный подход позволяет не только уменьшить ошибку аппроксимации, но и упростить структуру нейронной сети. Сложность ИНС определяется количеством связей K в ней. В качестве точки отсчета примем сложность $K_{н.с.}$ – классической полносвязной сети при таком же количестве слоев и нейронов в слоях. Тогда функция приспособленности примет вид:

$$F_2 = \alpha(S - E_w) + \beta \left(1 - \frac{K}{K_{н.с.}} \right), \quad (1)$$

где α и β – коэффициенты функции приспособленности, которые подбираются исследователем и показывают степень влияния на функцию приспособленности ошибки обучения и количества связей в сети соответственно ($\alpha, \beta > 0; \alpha + \beta = 1$).

Функция приспособленности (2), вычисленная на контрольном множестве данных, позволяет получить нейронную сеть с высокой обобщающей способностью и логически более прозрачной архитектурой.

Адаптивная настройка шага обучения

Решающее влияние на скорость обучения и на получаемые конечные результаты при обучении нейронной сети методом обратного распространения ошибки оказывает коэффициент (шаг) обучения λ . Адаптивный подбор коэффициента λ позволяет контролировать погрешность обучения, в результате чего проводится увеличение или уменьшение его значения. В соответствии с этим методом стратегия изменения значения λ определяется путем сравнения суммарной погрешности ε на i -й итерации с ее предыдущим значением, причем ε рассчитывается по формуле [1]:

$$\varepsilon_i = \sqrt{\sum_{q=1}^n (y_q - d_q)^2},$$

где y_q соответствует выходу при подаче на вход q -го образа ($q = \overline{1, n}$).

Для ускорения процесса обучения предусматривается непрерывное возрастание коэффициента λ , если уровень фактической погрешности по сравнению с погрешностью предыдущей итерации находится в до-



пустимых пределах. Если обозначить ε_i и ε_{i-1} погрешности адаптации на i -м и $(i-1)$ -м шаге, а λ_i и λ_{i-1} – соответствующие им коэффициенты обучения, то в случае $\varepsilon_i > k_w \varepsilon_{i-1}$ (k_w – коэффициент допустимого прироста погрешности) производится уменьшение значения λ по формуле:

$$\lambda_{i+1} = \lambda_i \alpha_d,$$

где α_d является коэффициентом уменьшения значения λ . В противном случае, когда $\varepsilon_i < k_w \varepsilon_{i-1}$, значение этого коэффициента увеличивается по формуле:

$$\lambda_{i+1} = \lambda_i \alpha_k,$$

где α_k является коэффициентом увеличения значения λ [1].

Аппроксимация функции двух переменных

В качестве тестовой функции для решения задачи аппроксимации рассмотрим тестовую функцию Griewank [13]. Эта функция имеет достаточно сложную топологию и описывается выражением:

$$z(x, y) = \frac{1}{4000} x^2 + \frac{1}{4000} y^2 - \cos(x) \cos\left(\frac{1}{2} y \sqrt{2}\right) + 1.$$

Вид этой функции для $x, y \in [-5, 12]$ приведен на рис. 2. Данные для решения поставленной задачи в количестве 500 точек генерировались случайным образом. Для обучения и тестирования выборка была поделена на три части: 60 % составляла обучающая выборка (300 точек), контрольная выборка – 20 % (100 точек) и тестовая – 20 % (100 точек) от всей выборки.




Рис. 2. График тестовой функции

Решение задачи аппроксимации функции происходило с использованием ИНС с заданным количеством «скрытых» слоев. Для нахождения

ния количества нейронов на каждом «скрытом» слое применялся эволюционный алгоритм с прямым кодированием, представленным в табл. 2. В результате применения НЭ алгоритма было найдено оптимальное количество нейронов на 1-м и 2-м «скрытых» слоях (4 и 2 нейрона соответственно). В ходе решения поставленной задачи также было необходимо оптимизировать топологию связей сети, применив для этого НЭ подход к построению архитектуры нейронной сети.

Архитектура ИНС была закодирована согласно схеме прямого кодирования с применением матрицы связей сети.

Первый этап эволюции заключался в инициализации поколения из 10 особей (нейронных сетей). Далее в соответствии с типовым циклом эволюции происходила оптимизация топологии связей сети. Для обучения ИНС был использован алгоритм обратного распространения ошибки с адаптивной настройкой шага обучения. Исходные параметры нейронной сети и параметры обучения сети показаны в табл. 3.

Таблица 3

Параметры нейронной сети и параметры обучения

Параметр	Значение
Количество «скрытых» слоев ИНС k	2
Количество нейронов в 1-м «скрытом» слое N_1	4
Количество нейронов во 2-м «скрытом» слое N_2	2
Вид активационной функции f	Логистическая сигмоида
Коэффициент допустимого прироста погрешности k_w	1,005
Коэффициент увеличения скорости α_k	1,01
Коэффициент уменьшения скорости α_d	0,99
Максимальное системное время обучения T_{\max}	10000 мс

Эволюционный поиск оптимальной топологии связей нейронной сети осуществлялся при помощи ГА с параметрами, представленными в табл. 4. В качестве оператора селекции был выбран бинарный турнирный отбор, т. к. он на этапе тестирования ГА показал лучшие результаты по сравнению с методом рулетки.

Оценивание приспособленности особей (нейронных сетей) в популяции состояло в расчете функции приспособленности F по формуле:



$$F = \alpha(1 - E_w) + \beta \left(1 - \frac{K}{K_{nc}} \right), \quad (3)$$

где E_w – ошибка аппроксимации, рассчитанная по контрольной группе примеров; коэффициенты α и β подбирались таким образом, чтобы слагаемое, отражающее точность решения задачи аппроксимации, вносило больший вклад в значение функции приспособленности, чем слагаемое, отражающее сложность структуры ИНС. Классическая ИНС в данной задаче содержит $K_{nc} = 18$ связей. Остальные параметры обучения нейронной сети приведены в табл. 4.

Таблица 4

Параметры ГА

Показатель	Значение
Максимальное количество поколений P	12
Количество особей L	10
Вид селекции	Бинарный турнирный отбор
Оператор скрещивания	Двухточечный
Разрыв поколений	0,9
Вероятность скрещивания p_c	0,8
Вероятность мутации p_m	0,1
Коэффициент функции приспособленности α	0,6
Коэффициент функции приспособленности β	0,4

Обучение каждой нейронной сети, представляющей собой особь в популяции хромосом, происходило с помощью алгоритма обратного распространения ошибки на протяжении фиксированного временного интервала, равного параметру T_{max} (см. табл. 3). На каждом шаге обучения с целью предотвращения переобучения сети происходила кросс-валидационная проверка обученной сети на контрольной выборке.

Для уменьшения степени влияния случайных факторов на результаты работы НЭ алгоритма было проведено 10 независимых запусков этого алгоритма с параметрами, приведенными в табл. 3 и табл. 4.

Графики изменения максимального, минимального и среднего значений функций приспособленности на каждом поколении выполнения ГА, усредненные по 10 запускам, представлены на рис.3. Заметим, что функция приспособленности лучшей особи в поколении (особь с максимальной функцией приспособленности) является неубывающей функцией.

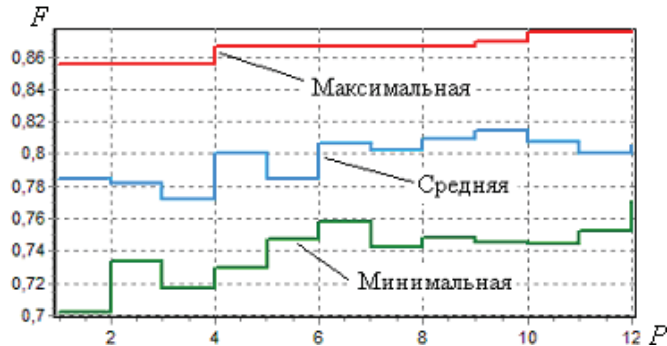


Рис. 3. График изменения значений функций приспособленности по поколениям

В каждом из запусков НЭ алгоритма в последнем поколении ГА были получены ИНС со структурами, отличающимися от классической полносвязной структуры меньшим количеством связей.

В табл. 5 представлены результаты 5 лучших результатов запуска НЭ алгоритма. Ошибка обучения E_w вычислялась на последнем шаге эволюции сети по данным, входящим в контрольную выборку.

Таблица 5

Результаты испытаний работы НЭ алгоритма при аппроксимации тестовой функции

Номер опыта	Ошибка E_w (%)	Лучшая хромосома
1	4,27	1111000101101011011001001011
2	3,98	1111000110100001011010011011
3	4,01	1111010111101101011001001011
4	4,07	1110000111010011011011010011
5	4,18	1101010111100011001011101011
Среднее	4,102	

Минимальное значение ошибки аппроксимации функции Griewank на контрольной выборке составила менее 4 % при втором запуске. Структура этой сети представлена на рис. 4.




Рис. 4. Структура оптимальной сети полученной с помощью ГА

Полученная сеть имеет 15 связей в отличие от 18 у полносвязной сети, что влияет на скорость процесса обучения. Для сравнения в табл.



6 приведены 5 лучших результатов испытаний, полученных при обучении нейронной сети с классической полносвязной структурой 2–4–2–1 с помощью алгоритма обратного распространения ошибки. Ошибка обучения E_w вычислялась по наблюдениям контрольной выборки.

Таблица 6

Результаты обучения полносвязной нейронной сети со структурой 2–4–2–1

Номер опыта	Ошибка E_w (%)
1	6,02
2	6,72
3	6,22
4	6,38
5	6,59
Среднее	6,386

Зависимости между реальными и модельными значениями аппроксимируемой функции показаны на рис. 5.




Рис. 5. Зависимости между реальными и модельными значениями функции для ИНС со структурой: а) полносвязной (обучающая выборка); б) полносвязной (тестовая выборка); в) полученной с помощью ГА (обучающая выборка); г) полученной с помощью ГА (тестовая выборка)

Результаты, представленные в табл. 5, 6 и рис. 5, свидетельствуют о преимуществе эволюционного подхода к обучению ИНС по сравнению с классическими методами.

Экстраполяция функции одной переменной

Задачу экстраполяции функции рассмотрим на примере функции одной переменной вида:

$$z(x) = \frac{1}{2}x \cos(x) + x + \sqrt{x} + 2.$$

Случайным образом генерировалась 201 точка на отрезке $x \in [0,80]$. Все данные были поделены на три части в зависимости от расположения их абсцисс на оси Ox в декартовой системе координат. Объем обучающей выборки составил 60 % от общего количества точек, контрольной – следующие 20 % и тестовой, соответственно, оставшиеся 20 %.

На первом этапе необходимо найти оптимальное количество нейронов на «скрытых» слоях сети и топологию связей для экстраполяции (прогнозирования) значений функции на дальнейший период. Эта задача решалась с использованием ИНС с одним «скрытым» слоем и ограничением на максимально возможное количество нейронов в слое равным 15. В связи с этим хромосома в ГА представляет собой бинарную строку, состоящую из 4 символов.

После проведения нескольких запусков работы НЭ алгоритма было определено оптимальное количество нейронов в «скрытом» слое сети. Наилучшая сеть выбиралась по минимальной среднеквадратической ошибке, вычисленной по данным контрольной выборки. В табл. 7 представлены четыре лучших результата работы НЭ алгоритма. Наибольшую способность к обобщению примеров из тестовой выборки показала ИНС с 10 нейронами в «скрытом» слое.

Таблица 7

Результаты оптимизации количества нейронов на «скрытом» слое сети

№ п/п	Лучшая хромосома	Количество нейронов по слоям	Ошибка экстраполяции
1	1010	2-10-1	3,509
2	1011	2-11-1	3,982
3	1001	2-9-1	4,154
4	1000	2-8-1	4,697

На следующем этапе решалась задача оптимизации топологии связей сети с целью получения ИНС с более простой структурой и лучшей способностью к обобщению. Исходные параметры нейронной сети и



параметры обучения приведены в табл. 8. Параметры ГА для нахождения оптимальной топологии связей сети представлены в табл. 9.

Таблица 8

Параметры нейронной сети и параметры обучения	
Показатель	Значение
Количество «скрытых» слоев ИНС k	1
Количество нейронов в 1-м «скрытом» слое N_1	10
Вид активационной функции f	Логистическая сигмоида
Коэффициент допустимого прироста погрешности k_w	1,005
Коэффициент увеличения скорости α_k	1,01
Коэффициент уменьшения скорости α_d	0,99
Шаг обучения	8
Максимальное системное время обучения T_{\max}	10000 мс

Таблица 9

Параметры ГА	
Параметр	Значение
Максимальное количество поколений P	10
Количество особей L	10
Вид селекции	Бинарный турнирный отбор
Оператор скрещивания	Двухточечный
Разрыв поколений	0,9
Вероятность скрещивания P_c	0,8
Вероятность мутации P_m	0,1
Коэффициент функции приспособленности α	0,8
Коэффициент функции приспособленности β	0,2

Оптимизация топологии ИНС с учетом функции приспособленности (3) осуществлялась тем же методом обучения и кросспроверки, который описан выше при решении задачи аппроксимации функции двух переменных. Результаты обучения усреднялись по 10 независимым запускам алгоритма.

Применение НЭ алгоритма позволило получить структуру ИНС, отличающуюся от классической полносвязной структуры меньшим количеством связей. Количество нейронов в «скрытых» слоях в сети не изменилось. Общее количество связей в оптимизированной с помощью ГА сети получилось равным 47, в то время как число связей для соот-

ветствующей сети с полносвязной структурой составляет 80 элементов.

На рис. 6 показаны графики функции $z(x)$ и графики функций, значения которой вычислялись ИНС с полносвязной структурой и со структурой, полученной с помощью ГА.

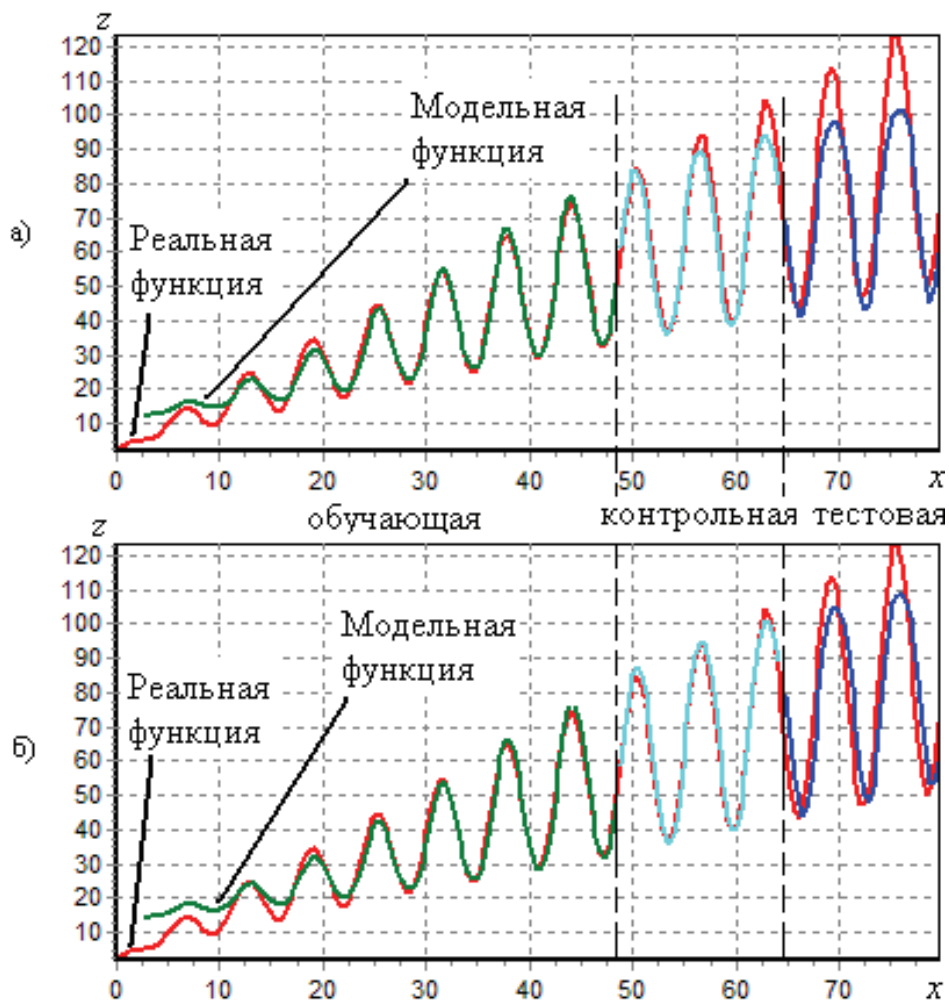


Рис. 6. Графики реальной и модельной функции для ИНС со структурой:
а) полносвязной; б) полученной с помощью ГА

Нейронная сеть со структурой, полученной с применением ГА, и соответствующая ей сеть с полносвязной структурой были обучены методом обратного распространения ошибки с переменным шагом за одинаковый промежуток времени, равный 10 с. Ошибки обучения и обобщения нейронных сетей, усреднены по 10 независимым запускам, представлены в табл. 10.



Таблица 10

Ошибки обучения нейронных сетей		
Группа	Ошибка E_w (%)	
	Полносвязная структура	Полученная с помощью ГА структура
Обучающая	2,045	1,985
Тестовая	8,658	5,728

Ошибки обучения для ИНС, полученной с помощью применения НЭ алгоритма, на обучающей и тестовой выборках меньше, чем для ИНС с полносвязной структурой, т. е. применение НЭ алгоритма позволяет заметно увеличить обобщающую способность нейронной сети.

Заключение

Эволюционный поиск нейросетевой архитектуры дает возможность автоматизировать процесс настройки и обучения ИНС. Решение тестовых задач аппроксимации и прогнозирования с применением предложенной схемы кодирования и модифицированной функцией приспособленности позволило получить нейронные сети, обладающие меньшей сложностью структуры и высокой обобщающей способностью. Как показали экспериментальные исследования, нейронные сети, обученные с помощью ГА, позволили в среднем в 1,5 раза уменьшить на тестовых выборках ошибку аппроксимации по сравнению с ошибками, показанными классическими полносвязными сетями.

Библиографические ссылки

1. *Осовский С.* Нейронные сети для обработки информации. М., 2002.
2. *Yao X.* Evolving artificial neural networks // Proceedings of the IEEE. 1999. №. 9(87).
3. *Рутковская Д.* Нейронные сети, генетические алгоритмы и нечеткие системы. М., 2006.
4. *Whitley D., Starkweather T., Bogart C.* Genetic Algorithms and Neural Networks: Optimization Connections and Connectivity // Parallel Computing. 1990. Vol. 14.
5. *Montana D. J., Davis L.* Training feedforward neural networks using genetic algorithms // Proceedings of 11th International Joint Conference on Artificial Intelligence. 1989.
6. *Korning P. G.* Training Neural Networks by Means of Genetic Algorithms Working on Very Long Chromosomes // International Journal of Neural Systems. 1995. Vol. 6. №. 3.
7. *Belew R. K., McInerney J., Schraudolph N. N.* Evolving networks: Using Genetic algorithms with connectionist learning. La Jolla, CA: University of California at San Diego, 1990.



8. *Schaffer J. D., Whitley L., Eshelman J.* Combinations of Genetic Algorithms and Neural Networks // Proceedings of the International Workshop on Combination of Genetic Algorithms and Neural Networks (COGANN-92). 1992.
9. *Mandisher M.* Representation and evolution of neural networks // Proceedings of the International Conference at Innsbruck. Austria. 1993.
10. *Koehn P.* Combining Genetic Algorithms and Neural Networks: The Encoding Problem // Master's Thesis, University of Tennessee. Knoxville. 1994.
11. *Koza J. R., Rice J. P.* Genetic generation of both the weight and architecture for a Neural Network // Proceedings of International Joint Conference on Neural Networks. 1991.
12. *Guo Z., Uhrig R. E.* Use of genetic algorithms to select inputs for neural networks // Proceedings of the International Workshop on Combination of Genetic Algorithms and Neural Networks (COGANN-92). 1992.
13. http://www-optima.amp.i.kyoto-u.ac.jp/member/student/hedar/Hedar_files/TestGO_files/Page1905.htm