

УДК 004.032.26:004.89



УПРОЩЕНИЕ СТРУКТУРЫ НЕЙРОСЕТЕЙ НА ОСНОВЕ ОСТРОВНОЙ МОДЕЛИ ЭВОЛЮЦИОННОГО ПОИСКА

А. А. Олейник¹, С. А. Субботин²¹ Запорожский национальный технический университет, г. Запорожье, Украина, olejnik@zntu.edu.ua;² Запорожский национальный технический университет, г. Запорожье, Украина, subbotin@zntu.edu.ua

Исследована проблема упрощения нейросетевых моделей. Разработан многокритериальный островной эволюционный метод, позволяющий организовать параллельный поиск по нескольким различным критериям. Проведены эксперименты по оптимизации нейромоделей режимов фрезерования нежестких деталей авиадвигателей.

НЕЙРОМОДЕЛЬ, ОПТИМИЗАЦИЯ, ЭВОЛЮЦИОННЫЙ ПОИСК

Введение

В настоящее время разработка автоматических систем распознавания образов, технической и биомедицинской диагностики, поддержки принятия решений остаётся достаточно сложной теоретической и технической проблемой, эффективность решения которой существенно зависит от качества классификации и идентификации исследуемых объектов, явлений, процессов, сигналов, что обуславливает необходимость разработки новых методов построения моделей зависимостей по конечным наборам данных, описывающих свойства и характеристики исследуемых объектов [1–2].

В качестве распознающих моделей эффективно могут использоваться искусственные нейронные сети прямого распространения [3–5], для построения которых необходимо предварительно определить структуру нейросети, учитывающую специфику решаемой задачи. Как правило, при синтезе нейромоделей структура сети задается пользователем, а сеть обучается путем оптимизационной настройки матрицы связей [6], вследствие чего эффективность данной нейромодели в значительной степени зависит от выбранной структуры.

Поскольку нейросети, имеющие небольшое количество нейронов из-за своих ограниченных аппроксимационных способностей не позволяют решать реальные практические задачи, число нейронов в сети выбирается с запасом, что приводит к увеличению времени вычисления значения целевого параметра по синтезированной нейромодели, увеличению объема памяти, необходимого для хранения значений весовых коэффициентов сети, снижению ее интерпретируемости, что вызвано избыточностью и неоптимальностью синтезированной нейромодели.

Поэтому целью настоящей работы является разработка метода оптимизации построенных нейромоделей, позволяющего сокращать количество нейроэлементов и связей между ними, синтезируя нейронные сети, обладающие приемлемыми аппроксимационными качествами.

1. Постановка задачи

Пусть задана обучающая выборка исходных данных в виде $\langle X, Y \rangle$, где $X = \{X_i\}$ – исходный набор значений признаков, характеризующих рассматриваемый объект или процесс; $Y = \{y_p\}$ – массив значений выходного параметра в выборке; $X_i = \{x_{ip}\}$ – i -ый признак в исходной выборке, $i = 1, 2, \dots, L$; L – общее количество признаков в исходном наборе; x_{ip} – значение i -го признака для p -го экземпляра выборки, $p = 1, 2, \dots, m$; y_p – значения прогнозируемого параметра для p -го экземпляра; m – количество экземпляров выборки.

Тогда задача оптимизации построенной нейросетевой модели вида $НС = НС(C, W, B, DF, TF)$ заключается в поиске таких новых значений $C' \subseteq C, W', B', DF', TF'$, при которых достигаются оптимальные значения заданных критериев оптимальности $\xi_1, \xi_2, \dots, \xi_K$, учитывающих основные характеристики нейромодели, где K – количество целевых критериев; C – матрица, определяющая наличие синаптических связей между элементами сети (рецепторами, нейронами); $W = W(C)$ – матрица весовых коэффициентов, соответствующих связям, присутствующим в сети $НС$; $B = B(C)$ – вектор смещений нейронов сети; $DF = DF(C)$ – вектор дискриминантных функций нейроэлементов; $TF = TF(C)$ – вектор функций активации нейронов сети; $\xi(НС, X, Y)$ – критерий, определяющий эффективность использования нейросетевой модели $НС$ для аппроксимации зависимости между набором входных параметров X и соответствующим ему вектором значений выходного параметра Y . Как правило, в качестве критерия оптимальности нейромодели используется среднеквадратическая ошибка [7].

В настоящее время существует два основных подхода к оптимизации структуры синтезированной нейросетевой модели [6]:

– методы удаления связей уменьшают количество элементов матрицы весов нейросети, упрощая таким образом ее структуру. При использовании таких методов удаляются связи, имеющие наименьшие значения синаптических весов или оказывающие наименьшее влияние на эффективность функционирования нейросетевой модели;

– методы удаления нейронов упрощают структуру нейромодели путем исключения из нее нейронов, удаление которых не приводит к значительному увеличению ошибки сети. Таким образом, при использовании методов удаления нейронов дополнительно необходимо оценивать их значимость путем вычисления ошибки упрощенной модели.

Однако существующие подходы упрощения нейромоделей, как правило, предполагают использование штрафных функций [6, 8], что во многих случаях не позволяет получать оптимальную структуру нейромодели, а иногда приводит к невозможности сходимости процесса упрощения нейромодели или к удалению значимых связей или нейронов.

Поэтому необходимо разработать новые методы упрощения нейросетевых моделей, способные выполнять поиск во всем пространстве возможных структур нейронных сетей прямого распространения.

Для оптимизации построенных нейромоделей эффективно могут использоваться методы эволюционного поиска [9–11], которые работают на каждой итерации с набором решений, что позволяет более детально исследовать пространство поиска, а также не накладывают ограничения на целевую функцию, в частности, не требуется дифференцируемость целевой функции, что позволяет производить поиск в пространстве нейронных сетей, содержащих нейроэлементы с недифференцируемыми функциями активации.

2. Оптимизация нейромоделей на основе эволюционного подхода

Известно [6, 12], что нейросетевые модели обладают различными характеристиками: качеством аппроксимации, точностью, интерпретабельностью, простотой аппаратной и программной реализации, вычислительной и пространственной сложностью и другими. Поэтому при оптимизации нейромодели целесообразным является использование набора критериев, наиболее полным образом её характеризующих.

При оценивании структурной сложности нейромодели целесообразно использовать количество синаптических соединений (весов) в сети N_w , количество нейронов N_n и количество слоев N_c в нейромодели. Предлагается использовать следующий критерий оценивания сложности структуры нейросети:

$$K_c = \left(1 + \frac{N_w}{N_n}\right) \left(1 + \frac{N_n}{N_c}\right) (1 + N_c), \quad N_n \geq 1, \quad N_c \geq 1.$$

Такой критерий учитывает количество слоев в нейросети, а также среднее количество нейронов в слое и среднее количество связей, приходящихся на один нейрон.

На вычислительную сложность сети существенное влияние оказывают функции активации нейроэлементов. Поэтому в качестве критерия оценивания вычислительной сложности предлагается использовать выра-

жение, учитывающее количество вычислительно сложных и вычислительно простых функций активации:

$$K_\theta = \left(\frac{1 + N_{сл.}}{1 + N_{пр.}}\right),$$

где $N_{сл.}$ – количество вычислительно сложных функций активации нейронов (логистическая сигмоидная, тангенциальная сигмоидная, радиальнобазисная и другие); $N_{пр.}$ – количество вычислительно простых функций активации (пороговая, линейная).

Для оценивания аппроксимационных качеств сети и сложности ее применения целесообразно использовать среднеквадратическую ошибку модели E и время расчета значения выходного параметра по синтезированной нейромодели t соответственно.

Предложенный набор критериев охватывает большинство характеристик нейросетей, что позволяет использовать его для многокритериальной оптимизации с целью получения достаточно простых и интерпретабельных нейромоделей, обеспечивающих высокую точность аппроксимации.

Поскольку оптимизация по нескольким критериям является эффективной при небольшом количестве целевых функций, предлагается для упрощения структуры нейромоделей использовать два критерия, интегрирующие основные характеристики нейросетей:

$$f_1 = E \cdot K_c = E \left(1 + \frac{N_w}{N_n}\right) \left(1 + \frac{N_n}{N_c}\right) (1 + N_c),$$

$$f_2 = t \cdot K_\theta = t \left(\frac{1 + N_{сл.}}{1 + N_{пр.}}\right).$$

Первый критерий f_1 характеризует качество аппроксимации нейромодели и ее структурную сложность. Критерий f_2 объединяет время вычисления выходного параметра по синтезированной сети и ее вычислительную сложность.

С целью решения задачи оптимизации нейромоделей по нескольким заданным целевым критериям предлагается использовать многокритериальный островной эволюционный метод, выполнение которого состоит из двух этапов. На первом этапе выполняется разбиение популяции на подпопуляции (острова) и однокритериальный поиск оптимумов каждой из целевых функций, на втором – многокритериальный поиск в объединенной популяции хромосом.

Разработанный многокритериальный островной эволюционный метод предлагается выполнять в следующей последовательности шагов.

Шаг 1. Установить счетчик итераций: $t = 0$. Выполнить инициализацию начальной популяции P_0 хромосомами, содержащими информацию о значениях весовых коэффициентов и смещений нейроэлементов, а также о виде функции активации каждого нейрона сети, подлежащей упрощению.

Решения (хромосомы) при оптимизации нейромоделей предлагается кодировать следующим образом

(рис. 1): в первой части хромосом хранить информацию о значениях весов нейронов входного слоя, во второй – значения весовых коэффициентов нейронов скрытых слоев, в третьей – значения смещений нейронов, в четвертой – функции активации каждого нейрона сети.

На рис. 1 используются следующие обозначения: iw_{vp} – значение весового коэффициента связи от v -го признака к ρ -му нейрону; lw_{vp} – значение весового коэффициента связи от v -го нейрона к ρ -му нейрону; b_ρ – значение смещения ρ -го нейрона; tf_ρ – функция активации ρ -го нейрона.

Шаг 2. Разбить популяцию P_t на K подпопуляций (островов) размером N/K каждая ($N/K \geq 2$), где K – количество целевых функций решаемой задачи.

Шаг 2.1. Для каждой хромосомы H_j рассчитать евклидово расстояние от нее до всех остальных хромосом в популяции. Евклидово расстояние d между хромосомами H_j и H_l вычисляется по формуле:

$$d(H_j; H_l) = \sqrt{\sum_{i=1}^L (h_{ij} - h_{il})^2},$$

где L – размер хромосом; h_{ij} и h_{il} – значения i -ых генов хромосом H_j и H_l , соответственно.

Шаг 2.2. Установить счетчик сформированных подпопуляций: $c = 1$. Сформировать множество не вошедших в подпопуляцию хромосом $A = P_t$.

Шаг 2.3. Инициализировать c -ую подпопуляцию: $V_c = \emptyset$.

Шаг 2.4. Выбрать из множества A две хромосомы H_j и H_l с максимальным расстоянием между ними.

Шаг 2.5. Включить выбранные хромосомы H_j и H_l в c -ую подпопуляцию: $V_c = V_c \cup \{H_j, H_l\}$. Исключить хромосомы H_j и H_l из A : $A = A \setminus \{H_j, H_l\}$.

Шаг 2.6. Если c -ая подпопуляция полностью сформирована ($|V_c| = N/K$), тогда перейти к шагу 2.9.

Шаг 2.7. Выбрать из множества A хромосому H_k , сумма расстояний от которой до хромосом из V_c является максимальной.

Шаг 2.8. Включить хромосому H_k в c -ую подпопуляцию: $V_c = V_c \cup \{H_k\}$. Исключить хромосому H_k из A : $A = A \setminus \{H_k\}$. Выполнить переход к шагу 2.6.

Шаг 2.9. Если сформированы все подпопуляции ($c = K$), тогда перейти к выполнению шага 3.

Шаг 2.10. Увеличить счетчик сформированных подпопуляций: $c = c + 1$. Выполнить переход к шагу 2.3.

Шаг 3. Увеличить счетчик итераций: $t = t + 1$.

Шаг 4. Выполнить основной цикл эволюционного поиска в каждой из K подпопуляций.

Шаг 4.1. Оценить приспособленность особей c -ой подпопуляции путем вычисления значений c -ой целевой функции $f_c(H_j)$, $j = 1, 2, \dots, N$.

Шаг 4.2. Выбрать часть хромосом для скрещивания и мутации.

Шаг 4.3. Выполнить оператор скрещивания, уменьшающий количество синаптических соединений в сети.

Для частей хромосом, содержащих информацию о значениях весовых коэффициентов нейронов входного и скрытых слоев, значение i -го гена потомков предлагается определять по формулам:

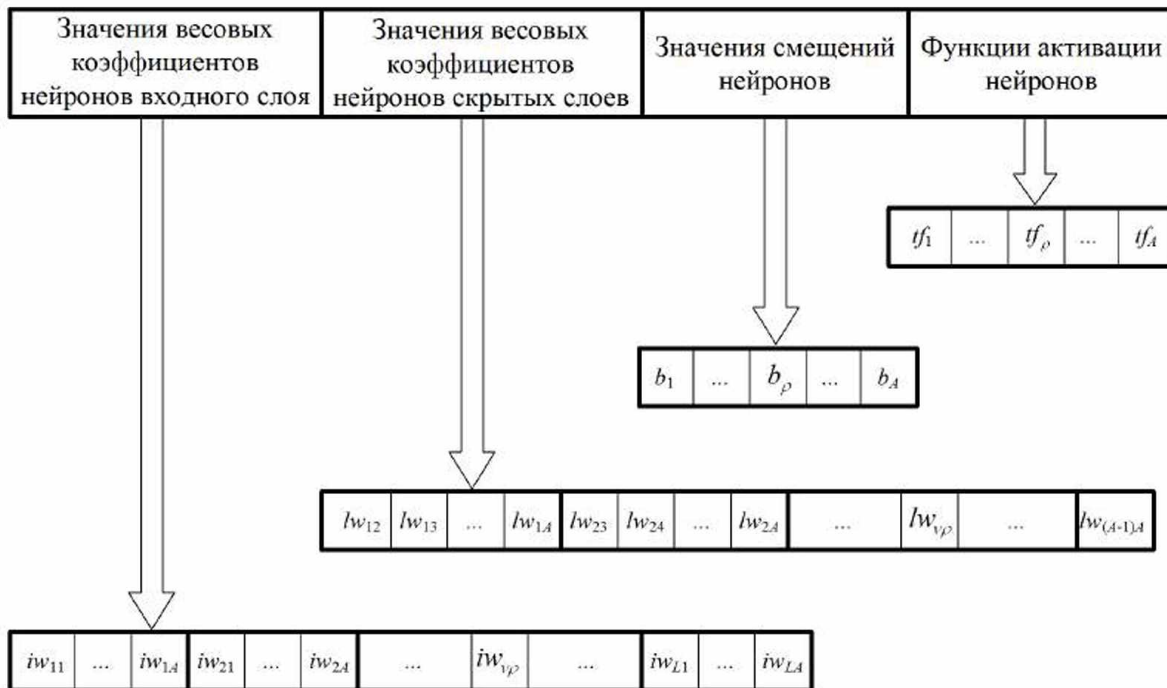


Рис. 1. Представление хромосомы при упрощении нейромоделей

$$h_{in1} = \begin{cases} 0, & \text{если } h_{i1} \cdot h_{i2} < 0; \\ kh_{i1} + (1-k)h_{i2}, & \text{в противном случае,} \end{cases}$$

$$h_{in2} = \begin{cases} 0, & \text{если } h_{i1} \cdot h_{i2} > 0; \\ (1-k)h_{i1} + kh_{i2}, & \text{в противном случае,} \end{cases}$$

где h_{in1} и h_{in2} – значения i -ых генов первого и второго потомков, соответственно; h_{i1} и h_{i2} – значения i -ых генов первого и второго родителей, соответственно; k – коэффициент, задаваемый пользователем, $k \in (0; 1)$.

Значения генов, соответствующих смещениям нейронов, определить по формулам:

$$h_{in1} = kh_{i1} + (1-k)h_{i2} \text{ и } h_{in2} = kh_{i2} + (1-k)h_{i1}.$$

Значения генов, определяющих функции активации нейрона, предлагается определять по правилам:

$$h_{in1} = \begin{cases} h_{i1}, & \text{если } h_{i1} = h_{i2} \text{ или } r > 0,5; \\ \text{rand[TF]}, & \text{в противном случае,} \end{cases}$$

$$h_{in2} = \begin{cases} h_{i2}, & \text{если } h_{i1} = h_{i2} \text{ или } r \leq 0,5; \\ \text{rand[TF]}, & \text{в противном случае,} \end{cases}$$

где r – случайно сгенерированное число в интервале $(0; 1)$; rand[TF] – случайно выбранный элемент множества TF, содержащего информацию о функции активации, используемой для построения нейросети.

Шаг 4.4. Выполнить оператор точечной мутации.

В случае, если для мутации выбран ген хромосомы, содержащий информацию о значениях весовых коэффициентов нейронов сети, тогда новое значение i -го гена предлагается вычислять по формуле:

$$h_{in} = \begin{cases} 0, & \text{если } |r| < 0,5h_i; \\ r, & \text{в противном случае,} \end{cases}$$

где h_i и h_{in} – значения i -го гена до и после мутации соответственно; $r = \text{rand}[-h_i; h_i]$ – случайно сгенерированное число в интервале $[-h_i; h_i]$.

Если для мутации выбран ген хромосомы, соответствующий смещению нейрона, тогда значение i -го гена после мутации h_{in} предлагается определять по формуле:

$$h_{in} = \text{rand}[h_{i,\min}; h_{i,\max}],$$

где $h_{i,\min}$ и $h_{i,\max}$ – минимальное и максимальное значения i -го гена в текущей популяции хромосом.

В случае выбора для мутации гена хромосомы, содержащего информацию о функции активации нейрона, новое значение гена предлагается определять по формуле:

$$h_{in} = \text{rand[TF]}.$$

Шаг 4.5. Создать новое поколение c -ой подпопуляции из полученных на предыдущем шаге хромосом-потомков и наиболее приспособленных хромосом текущего поколения.

Шаг 5. Если $(\text{rem}(t, t_m) = 0)$, где $\text{rem}(a, b)$ – остаток от целочисленного деления a на b ; t_m – заданный пользователем интервал смены этапов эволюционной оптимизации, тогда перейти к шагу 6. В противном случае выполнить переход к шагу 3.

Шаг 6. Увеличить счетчик итераций: $t = t + 1$. Объединить хромосомы подпопуляций в единую популяцию P_t :

$$P_t = \bigcup_{c=1}^K V_c.$$

Шаг 7. Выполнить основной цикл эволюционного поиска над хромосомами из объединенной популяции. При этом оценивание хромосомы H_j проводить с помощью вычисления обобщенного значения целевой функции $F(H_j) = F(f_1(H_j), f_2(H_j), \dots, f_K(H_j))$, определяемого по правилу:

$$F(H_j) = \sum_{k=1}^K \frac{B_k}{\Delta_k},$$

где $B_k = \begin{cases} f_k(H_j) - \min(f_k), & \text{если } f_k \rightarrow \min; \\ \max(f_k) - f_k(H_j), & \text{если } f_k \rightarrow \max; \end{cases}$

$\Delta_k = \max(f_k) - \min(f_k)$ – диапазон изменения значений k -ой целевой функции; $\max(f_k)$ и $\min(f_k)$ – соответственно максимальное и минимальное значения k -ой целевой функции на текущей итерации. Таким образом, $F(H_j) \in [0; K]$.

При необходимости оценивание хромосом обобщенной популяции можно проводить с помощью подхода Парето, используя сортировку или ранжирование по принципу недоминируемости.

С целью уменьшения количества синаптических соединений в сети в качестве эволюционных операторов предлагается использовать операторы скрещивания и мутации, используемые на шагах 4.3 и 4.4, соответственно.

Шаг 8. Если $(\text{rem}(t, t_m) = 0)$, тогда перейти к шагу 9. В противном случае выполнить переход к шагу 7.

Шаг 9. Выполнить проверку критериев окончания поиска (достижение максимально допустимого количества итераций, приемлемого значения целевой функции). Если критерии останова удовлетворены, тогда выполнить переход к шагу 10. В противном случае перейти к выполнению шага 2.

Шаг 10. Останов.

Разработанный многокритериальный островной эволюционный метод, в отличие от классической островной модели эволюционного поиска [10], позволяет организовать параллельный поиск по нескольким различным критериям, вследствие чего он может применяться для решения многокритериальных задач. Кроме того, предложенный эволюционный метод упрощения нейромоделей позволяет ускорить поиск за счет уменьшения количества вычислений значений всех целевых функций на первом этапе эволюционной оптимизации, а также за счет использования специальных эволюционных операторов, уменьшающих количество синаптических соединений в сети, позволяет синтезировать нейронные сети, имеющие наиболее значимые нейроны и связи между нейроэлементами.

3. Эксперименты и результаты по синтезу моделей режимов фрезерования деталей авиадвигателей

С целью проверки эффективности применения разработанного многокритериального островного эволюционного метода проводились эксперименты по решению задачи синтеза моделей режимов фрезерования деталей авиадвигателей [13, 14].

При обработке нежестких деталей авиадвигателей применяют методы высокоскоростного фрезерования, которые, однако, сопровождаются вибрациями обрабатываемых деталей. Такие вибрации значительно повышают вероятность разрушения детали в процессе обработки. С целью уменьшения амплитуды вибраций предлагается синтезировать модели зависимости режимов высокоскоростного фрезерования от параметров вибраций. Затем на основе построенных моделей необходимо выбрать оптимальные параметры, обеспечивающие минимальный уровень вибраций.

Исходная выборка [13] характеризовалась значениями шести режимов фрезерования (y_1 – скорость резания, м/мин; y_2 – частота оборотов фрезы, об./мин; y_3 – подача на зуб, мм/зуб; y_4 – S – минутная подача, мм/мин; y_5 – глубина резания, мм; y_6 – вид фрезерования (попутное или встречное), а также получаемыми в результате обработки спектрами, которые численно представлены в виде отсчетов сигналов.

С целью сокращения описания исходных сигналов и представления их в форме, удобной для анализа зависимости режимов фрезерования от полученного сигнала, выполнялось преобразование Фурье [14] для каждого из полученных сигналов. В результате такого преобразования были получены 100 комплексных коэффициентов для каждого сигнала. Выделение наиболее информативной комбинации признаков выполнялось с помощью эволюционного метода с фиксацией части пространства поиска [15], в результате чего получили, что для синтеза математической модели y_1 было отобрано 11 признаков, y_2 – 14 признаков, y_3 – 13 признаков, y_4 – 12 признаков, y_5 – 12 признаков,

y_6 – 14 признаков.

На основе полученных входных данных выполнялся структурно-параметрический синтез нейромоделей [15, 16] зависимостей y_1 – y_6 .

Упрощение построенных нейромоделей выполнялось с помощью предложенного многокритериального островного эволюционного метода. Начальные значения параметров эволюционных методов устанавливались следующими: оператор отбора – отбор с использованием рулетки, оператор скрещивания – одноточечный, оператор мутации – гауссова мутация, количество особей в популяции $N = 100$ (для многокритериальных методов используются две подпопуляции по 50 особей каждая), вероятность скрещивания $p_{скр} = 0,8$, вероятность мутации $p_m = 0,05$, количество элитных особей $N_e = 2$. Критерии останова: максимально допустимое количество итераций $T = 100$, достижение приемлемого значения ЦФ $f_n = 0,01$.

Сравнивались такие методы эволюционной оптимизации, как однокритериальный эволюционный поиск, использующий в качестве фитнес-функции f_1 , однокритериальный эволюционный поиск, использующий в качестве фитнес-функции f_2 , векторной генетический метод (Vector Evaluated Genetic Algorithm, VEGA), генетический метод с сортировкой по принципу недоминируемости (Nondominated Sorting Genetic Algorithm, NSGA), эволюционный метод с архивированием недоминируемых хромосом (Strength Pareto Evolutionary Algorithm, SPEA) [17] и многокритериальный островной эволюционный метод.

Результаты экспериментов по упрощению нейросетевой модели y_1 приведены в табл. 1, где t – время в секундах, затраченное на эволюционную оптимизацию; $E_{обуч}$ – ошибка модели по данным обучающей выборки; $E_{тест}$ – ошибка модели по тестовой выборке.

При упрощении моделей зависимостей других режимов фрезерования (y_2 – y_6) получены аналогичные результаты. Сравнение результатов, полученных с помощью применения однокритериального эволюцион-

Таблица 1

Результаты экспериментов по отбору признаков с помощью различных методов эволюционного поиска

Метод	τ	N_n	N_w	f_1	f_2	$E_{обуч}$	$E_{тест}$
Однокритериальный эволюционный поиск, использующий в качестве фитнес-функции f_1	218,2	8	39	0,78	0,097	0,0099	0,381
Однокритериальный эволюционный поиск, использующий в качестве фитнес-функции f_2	162,9	9	48	14,02	0,079	0,1108	0,1630
VEGA (лучшая модель, полученная для критерия f_1)	210,3	8	40	0,83	0,099	0,0098	0,2089
VEGA (лучшая модель, полученная для критерия f_2)	210,3	7	49	13,77	0,0087	0,0683	0,0936
Генетический метод с сортировкой по принципу недоминируемости	247,9	7	42	0,82	0,092	0,0099	0,2519
Эволюционный метод с архивированием недоминируемых хромосом	231,6	8	38	0,79	0,094	0,0098	0,2632
Многокритериальный островной эволюционный метод	182,7	7	37	0,78	0,095	0,0098	0,1931

ного поиска, VEGA, NSGA, SPEA и предложенного метода, показывает, что разработанный многокритериальный островной эволюционный метод позволяет более эффективно упрощать нейромодели по нескольким заданным критериям, а также сокращает время эволюционной оптимизации за счет меньшего количества вычислений значений всех целевых функций.

Выводы

С целью повышения интерпретируемости построенных нейросетевых моделей в работе решена задача упрощения их структуры на основе эволюционного подхода.

Научная новизна работы заключается в том, что разработан многокритериальный островной эволюционный метод, в отличие от классической островной модели эволюционного поиска, позволяет организовать параллельный поиск по нескольким различным критериям, вследствие чего он может применяться для решения многокритериальных задач. Кроме того, предложенный эволюционный метод упрощения нейромоделей позволяет ускорить поиск за счет уменьшения количества вычислений значений всех целевых функций на первом этапе эволюционной оптимизации, а также за счет использования специальных эволюционных операторов, уменьшающих количество синаптических соединений в сети, позволяет синтезировать нейронные сети, имеющие наиболее значимые нейроны и связи между нейроэлементами.

Практическая ценность результатов работы состоит в том, что решена задача упрощения нейромоделей режимов фрезерования жестких деталей авиадвигателей.

Список литературы: 1. Интеллектуальные средства диагностики и прогнозирования надежности авиадвигателей: Монография / В. И. Дубровин, С. А. Субботин, А. В. Богуслаев, В. К. Яценко. – Запорожье: ОАО «Мотор-Сич», 2003. – 279 с. 2. Патрик Э. Основы теории распознавания образов. – М.: Сов. радио, 1980. – 408 с. 3. Минаев Ю. Н., Филимонова О. Ю., Лиес Б. Методы и алгоритмы идентификации и прогнозирования в условиях неопределенности в нейросетевом логическом базисе. – М.: Горячая линия-Телеком, 2003. – 205 с. 4. Хайкин С. Нейронные сети: полный курс. – СПб: Издательский дом «Вильямс», 2005. – 1104 с. 5. Круглов В. В., Борисов В. В. Искусственные нейронные сети: Теория и практика. – М.: Горячая линия-Телеком, 2001. – 382 с. 6. Руденко О. Г., Бодянский Е. В. Штучні нейронні мережі. – Харків: Компанія СМІТ, 2006. – 404 с. 7. Дзи М. И. Нечеткая логика и искусственные нейронные сети. – М.: Физматлит, 2001. – 225 с. 8. Нейросетевые системы управления / В. А. Терехов, Д. В. Ефимов, И. Ю. Тюкин, В. Н. Антонов. – СПб.: Изд-во С.-Петербургского ун-та, 1999. – 265 с. 9. Эволюционные методы компьютерного моделирования: Монография / А. Ф. Верлань, В. Д. Дмитриенко, Н. И. Корсунов, В. А. Шорох. – К.: Наукова думка, 1992. – 256 с. 10. Cantu-Paz E. Efficient and Accurate Parallel Genetic Algorithms. – Massachusetts: Kluwer Academic Publishers, 2001. – 162 p. 11. Haupt R., Haupt S. Practical Genetic Algorithms. – New Jersey: John Wiley & Sons, 2004. – 261 p. 12. Yao X. Evolving Artificial Neural Network // Proceedings of

the IEEE. – 1999. – № 9(87). – P. 1423–1447. 13. Качан А. Я., Внуков Ю. Н., Павленко Д. В. и др. Особенности колебаний деталей при высокоскоростном строчном фрезеровании // Вісник двигунобудування. – 2007. – № 1. – С. 69–76. 14. Олейник А. А., Павленко Д. В., Субботин С. А. Определение влияния режимов высокоскоростного фрезерования на параметры жестких деталей на основе эволюционного подхода // Вісник двигунобудування. – 2008. – № 1. – С. 84–90. 15. Субботин С. О., Олейник А. О. Структурный синтез нейромоделей на основе полимодального эволюционного поиска // Радіоелектроніка. Інформатика. Управління. – 2008. – № 1. – С. 111–117. 16. Олейник А. А. Эволюционный метод обучения нейромоделей // Интеллектуальный анализ информации: Сборник трудов восьмой международной конференции ИАИ-2008 (14–17 мая 2008 г.). – К.: Просвіта, 2008. – С. 351–361. 17. Coello C. A Short Tutorial on Evolutionary Multiobjective Optimization // Evolutionary Multi-Criterion Optimization: Proceeding of the International Conference EMO2001 (7–9 March 2001). – Zurich: Springer-Verlag, 2001. – P. 21–40.

Поступила в редколлегию 12.03.2009

УДК 004.032.26:004.89

Спрощення структури нейромереж на основі островної моделі еволюційного пошуку / А. О. Олейник, С. О. Субботін // Біоніка інтелекту: наук.-техн. журнал. – 2009. – №1(70). – С. 107–112.

У статті досліджено проблему спрощення нейромережних моделей. Розроблено багатокритеріальний островний еволюційний метод, що дозволяє організувати паралельний пошук за декількома різними критеріями. Проведено експерименти з оптимізації нейромоделей режимів фрезерування нежорстких деталей авіадвигунів.

Табл.: 1. Лл.: 1. Бібліогр.: 17 найм.

UDC 004.032.26:004.89

Neural Network Structure Simplification Based on Island Model of Evolutionary Search / A.A. Oleynik, S.A. Subbotin // Bionics of Intelligence: Sci. Mag. – 2009. – №1(70). – P. 107–112.

The problem of neural network models simplification is investigated in the paper. The multiobjective island evolutionary method, allowing to organize a parallel search by several criteria is developed. The experiments on optimization of neural network models of airengine nonrigid details milling are conducted.

Tab.: 1. Fig.: 1. Ref.: 17 items.