

文章编号: 1000-3851(2005)05-0134-07

# 基于神经网络响应面的复合材料结构优化设计

李 烁, 徐元铭\*, 张俊

(北京航空航天大学 航空科学与工程学院, 北京 100083)

**摘要:** 用正交试验设计的方法选择样本点构建神经网络响应面, 将神经网络响应面作为优化的目标函数或约束条件, 加上其它常规约束条件建立优化模型, 应用遗传算法(GA)进行优化, 形成一套适用于复杂结构设计的高效优化方法。以复合材料帽型加筋板的重量优化问题为例, 建立了加筋板模型的重量响应面目标函数、强度和稳定性响应面约束条件; 并用PATRAN/NASTRAN进行有限元计算, 获取用于响应面训练的样本点数值。算例表明: 该方法能以很少的有限元分析次数, 取得高精度的响应面近似模型, 并且使优化效率大大提高。

**关键词:** 复合材料; 结构优化; 神经网络; 遗传算法; 响应面

中图分类号: TB 330.1; O 316 文献标识码: A

## COMPOSITE STRUCTURAL OPTIMIZATION DESIGN BASED ON NEURAL NETWORK RESPONSE SURFACES

LI Shuo, XU Yuan ming\*, ZHANG Jun

(School of Aeronautic Science and Engineering Technology,  
Beijing University of Aeronautics and Astronautics, Beijing 100083, China)

**Abstract :** To construct neural-net work response surfaces for composite structural optimal design, the Orthotropic Experimental Method (OEM) was used to select the most appropriate structural analysis sample points. The constructed response surfaces were used as the objective function or constraint conditions. Together with other conventional constraints, they form an optimization design model which can be solved by using genetic algorithm (GA). This approach is highly applicable for complex composite structural design. Taking a hat-stiffened composite plate as example, the weight response surface was developed as the objective function, and strength and stability response surfaces as constraints; all these neural net works were trained by PATRAN/NASTRAN computation. The optimization results illustrate that it can significantly reduce the cycles of FEM analysis and achieve highly accurate response approximation results. And eventually, the approach can greatly raise the efficiency of the optimization process.

**Keywords :** composites; structural optimization; neural net work; genetic algorithm (GA); response surface

复合材料结构优化设计充分挖掘和发挥复合材料的设计潜力, 来实现预期的设计目标。利用先进的结构分析技术、优化技术和计算机技术, 实现诸如重量、强度、稳定性、振动等多种因素在复合材料结构设计上的最佳综合。但是, 工程上, 大型复合材料结构的优化方法的研究和应用, 仍然存在不少障碍<sup>[1]</sup>。主要表现为: (1) 优化效率较低, 需要进行大量耗时的有限元计算; (2) 常规优化方法需要知道具体的函数表达式, 需要求得一阶或二阶导数, 有时难以得到; (3) 很难保证得到全局最优

解, 容易陷入局部最优; (4) 难以处理含有离散变量的优化问题; (5) 优化中靠经验调整的参数较多, 掌握困难。

响应面方法<sup>[2]</sup>源于统计学的一项综合实验技术, 用于处理复杂系统的输入与输出的转换关系问题。通过采用一个适当的修匀函数近似地表示一个未知函数的显示关系。近年来, 人们开始研究将函数响应面方法运用到机械结构的优化过程中, 通过响应面近似模型来代替有限元计算, 以图解决优化效率低的问题<sup>[3, 4]</sup>。神经网络具有建立输入和输出的非

线性映射功能, 而且非线性越强, 网络的结构映射性能就越优。这对于表述复杂结构分析中设计参数与结构响应之间的高度非线性关系更为贴切<sup>[5]</sup>。因此, 运用神经网络响应面比传统的函数响应面对大型复杂结构分析和优化设计更具有精确性。

遗传算法是一种不需要具体函数形式的非数值进化优化算法, 可以寻得全局最优解, 适合于离散变量的优化问题。但是遗传算法在结构优化过程中往往需要大量的有限元计算, 利用神经网络响应面近似模型则可以大大减少有限元的计算次数。因此, 将两者相结合, 可以很好地解决复合材料结构优化中所遇到的困难。

## 1 结构分析神经网络响应面近似模型

### 1.1 理论基础

复合材料结构的有限元分析就是求出结构的应力、应变和位移等量与该结构的设计变量、外加载荷以及边界条件的映射关系。这种由单元刚度合成的映射关系往往是复杂的, 甚至带有高度的非线性。通常优化过程中的结构近似分析是利用一些设计点处的结构应力、位移以及应力和位移对设计变量的梯度, 进而求出一些新的设计点处的应力和位移。由于这种近似分析方法不仅需要已知设计点应力和位移的一阶梯度信息, 增加了一定的计算量, 而且是一种局部性的结构近似分析方法。随着设计变量的增多、区域的增大, 其近似分析的精度会急剧下降<sup>[6]</sup>。

Hecht-Nelsen 曾证明假定 BP 网络中隐单元可以根据需要自由设定, 那么一个三层网络可以实现任意精度近似任何连续函数<sup>[7]</sup>。因此可以利用一个三层的BP 神经网络响应面来创建结构的应力、位移等量与设计变量之间的全局映射模型。将结构设计点的变量作为神经网络响应面模型的输入, 结构位移、应力等参量则可以作为响应面输出的近似值, 以此来代替优化过程中的结构有限元计算。而神经网络响应面模型对这种结构分析映射关系的近似程度则将决定对结构设计点的近似分析的精度。

### 1.2 神经网络响应面近似模型的建立

传统的函数响应面采用二次多项式<sup>[8]</sup>

$$y^* = C_0 + \sum_{i=1}^p C_i x_i + \sum_{i=1}^{p-1} \sum_{j=i+1}^p C_{ij} x_i x_j \quad (1)$$

式中:  $y^*$  为响应面的近似函数;  $x_i$  表示不同的设计变量;  $C_i$  与  $C_{ij}$  表示多项式中各个未知系数,  $i$  和  $j$

的取值范围是  $0 \leq i, j \leq p$ ,  $p$  个设计变量的多项式中共有  $n = (p+1)(p+2)/2$  项, 所以未知系数个数即有  $n$  项。通过实验值求出系数  $C_i$  与  $C_{ij}$ , 从而可以求出  $y(x_i)$  的近似函数  $y^*(x_i)$ , 并利用均方误差 (RMSE) 进行检测。而神经网络响应面则是通过样本训练来表达近似值  $y^*$ 。把一组样本的输入、输出映射变成一个非线性优化问题, 使用梯度下降法迭代求解连接权值( $w$ ) 和阀值( $\theta$ ), 利用反馈学习算法<sup>[7]</sup> 进行网络参数训练和调整。改变隐层节点数还可以得到更为精确的解。整个网络相当于从样本输入空间  $R_m$  到样本输出空间  $R_n$  的映射, 即

$$F: R_m \rightarrow R_n \quad Y^* = F(X) \quad (2)$$

图1 示出了典型BP 神经网络响应面的结构。

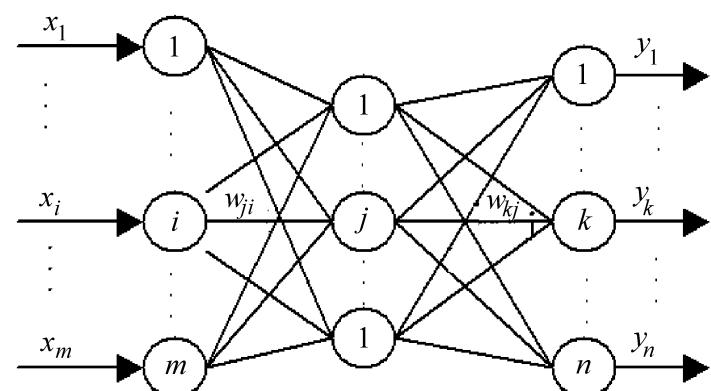


图1 典型 BP 神经网络响应面结构

Fig. 1 A typical structure of BP neural network response surface

### 1.3 改进的 BP 算法

神经网络响应面的好坏取决于其泛化性能。通常需要样本学习集和测试集来评价训练效果, 并以此来调整网络结构及相关参数, 以获得较高精度的响应面输出。

为了加快训练速度, 避免陷入局部极小值, 本文中在原有算法的基础上做了如下改进。

(1) 在权值  $w$ 、阀值  $\theta$  计算中增加附加动量项, 即

$$w_{ji}(t+1) = w_{ji}(t) + \eta o_{ki} + [w_{ji}(t) - w_{ji}(t-1)] \quad (3)$$

$$\eta(t+1) = \eta(t) + \eta + [\eta(t) - \eta(t-1)] \quad (4)$$

式中:  $\eta$  为学习速率;  $\eta$  为动量因子, 一般取 0.9 左右;  $\eta$  为误差函数;  $o_{ki}$  为第  $k$  个神经元的输出。

(2) 改进误差函数, 即取  $\eta_k = (f(n) + 0.1)/(t_k - o_k)$ , 当  $|n|$  变大时, 仍能保持  $\eta_k$  有一定的大小, 从而避免了饱和现象的发生。其中:  $f(n)$  为激发函数;  $t_k$  为期望输出。

(3) 分段选取学习速率。学习速率的选取范围在 0.01 ~ 0.9 之间。一般可以在训练初期选择较大

的学习效率，后期选择较小的学习效率。

通过大量的实际训练和检测比较发现，采用多输入、单输出、单隐含层的三层网络结构建立响应面近似模型，其训练、检测精度均远远大于多个输出的情况。这里取激发函数为S型函数： $f(x) = 1/(1 + e^{-x})$ 。

改进后的BP神经网络算法步骤如下：

(1) 确定网络的拓扑结构，如隐层神经单元数等。

(2) 设置权值和阀值的初始数值： $w_{ij}(0)$ 、 $b_j(0)$  为小的随机数字。

(3) 提供训练样本：输入矢量  $X_k$  和期望输出  $t_k$ ,  $k=1, 2, \dots, P$ ；对每个输入样本执行下面步骤(4)到步骤(6)的迭代。

(4) 计算网络实际输出及隐层单元的状态

$$o_{kj} = f_j(\sum_i w_{ji} o_{ki} + b_j)$$

(5) 计算训练误差

$$e_{kj} = (o_{kj}(1 - o_{kj}) + 0.1)(t_{kj} - o_{kj}) \quad (\text{输出层})$$

$$e_{kj} = (o_{kj}(1 - o_{kj}) + 0.1) \sum_m w_{mj} \quad (\text{隐含层})$$

(6) 通过式(3)和式(4)修正权值和阀值。

(7) 当 k 每经历 1 到 P 后，判断期望输出和实际输出的均方根误差 E 是否满足精度要求：E。其中 E 为精度。

#### 1.4 基于正交设计的样本处理和选择

由于设计变量的量级可能会不同，使各个参数对误差处于同等水平，需要对输入变量进行归一化处理，公式为  $x_i = (x_i - x_{\min}) / (x_{\max} - x_{\min})$ 。其中  $x_i$  为归一后的值； $x_i$  为原始值； $x_{\max}$ 、 $x_{\min}$  分别为 x 输入变量原始值中最大值和最小值。由于激活函数的取值范围是  $[0, 1]$ ，因此需要对输出值进行处理，使训练样本和检测样本的输出值均为  $[0, 1]$  中的值，然后通过逆运算得到实际的近似分析值。

正交试验法<sup>[9]</sup>是根据数理统计学的原理，从大量的试验点中挑选适量的具有代表性的试验点，应用一种标准化的“正交表”来合理安排多因素试验的一种科学方法。使用正交试验法训练神经网络响应面时，需要针对问题明确试验目的，确定试验指标；确定需要考察的因素，选取适当的水平；然后选用合适的正交表，安排试验。

神经网络响应面的训练样本太少或样本不具有代表性，网络便不可能学习到一般的映射规律。若样本太多，则会存在网络“过学习”的问题，使网

络结构过于复杂，记忆过多的细节，而无法建立正确的映射模型。正交试验法具有均衡分散性和整齐可比性，同时可以尽可能少地取典型样本数据，避免所需样本过剩，从而提高建模的效率。

## 2 遗传算法优化设计

### 2.1 优化模型

复合材料结构优化设计问题可表示为如下的一个数学形式：

$$\begin{aligned} & \min f(x) \\ & \text{s.t. } g_j(x) \leq 0 \quad (j = 1, 2, \dots, m) \\ & \quad x_{i\min} \leq x_i \leq x_{i\max} \quad (i = 1, 2, \dots, n) \end{aligned} \quad (4)$$

其中： $f(x)$  为目标函数；n 为设计变量个数；m 为约束函数  $g_j(x)$  个数； $x_{i\min}$  和  $x_{i\max}$  分别为设计变量  $x_i$  的上界和下界。在结构优化中，目标和约束函数是结构的重量和应力、位移、频率、屈曲荷载等性态函数，通常用有限元等数值方法计算。由于本文中采用神经网络响应面来代替有限元，则优化模型可进一步表示为

$$\begin{aligned} & \min f(x) \text{ 或 } F: R_m \rightarrow R_n \quad Y^* = f(x) \\ & \text{s.t. } g_j(x) \leq 0 \quad (j = 1, 2, \dots, k) \\ & G: R_m \rightarrow R_{m-k} \quad \{y^* = g_j(x)\} \leq 0 \\ & \quad x_{i\min} \leq x_i \leq x_{i\max} \quad (i = 1, 2, \dots, n) \end{aligned} \quad (5)$$

式中： $Y^*$  的含义见式(2)； $y^*$  含义与  $Y^*$  相同，这里为了区别目标函数与约束条件采用不同符号。前 k 个约束为常规约束（即不需要有限元计算），后  $m - k$  个约束为神经网络响应面约束；同理目标函数也可以是响应面近似函数  $Y^*$ 。

### 2.2 遗传算法、适应度与罚函数

遗传算法(GA)是一种可用于求解上述优化模型的有效优化算法，具有很好的搜索性。其计算过程是将实际的优化问题的解编码成符号串（也称为染色体），则目标函数用染色体的适应度表示。在最初随机产生一群染色体的基础上，根据各染色体的适应度进行繁殖、交叉和变异的遗传操作，产生下一代染色体。适应度的大小决定了该染色体被繁殖的机率，从而反映了适者生存的原则。交叉和变异操作，是通过随机地和结构化地交换染色体之间的信息而产生更加优秀的染色体。随着遗传代数的增加，将会产生一批适应度很高的染色体。将这批染色体解码还原就可以得到原问题的解。当染色体群体是足够大和遗传代数足够多时，遗传算法从理论上讲可以给出原问题的全局最优解。

GA 仅能直接处理无约束最大化问题，因此必

须先用适应度函数将最小化问题转化为最大化问题, 再通过罚函数法将属于约束优化问题变为无约束优化问题。

对于最小化问题的适应度函数可以被定义为:

$$C_{\max} - f(x) \quad (f(x) < C_{\max}, \text{常规情况})$$

$$F(X) = \begin{cases} C_{\max} - Y^* & (Y^* < C_{\max}, \text{响应面情况}) \\ 0 & (f(x) \geq C_{\max} \text{ 或 } Y^* \geq C_{\max}) \end{cases} \quad (6)$$

式中:  $C_{\max}$  为某一大正数。

罚函数法是把不满足约束条件的个体减少适应度来减少遗传到下一代的机会, 从而起到约束的效果。罚函数对适应度函数的调整可定义为:

$$F(X) = \begin{cases} F(X) & (X \text{ 满足约束}) \\ F(X) - P(X) & (X \text{ 不满足约束}) \end{cases} \quad (7)$$

$$P(X) = \sum_{j=1}^k \cdot \max\{0, g_j(x)\} + \sum_{j=k+1}^m \cdot \max\{0, y^*\}$$

式中:  $F(X)$  为原适应度;  $F(X)$  为考虑了罚函数之后的新适应度;  $P(X)$  为罚函数;  $j$  为确定罚函数作用强度的系数。

基于神经网络响应面的遗传算法结构优化的流程图如下:

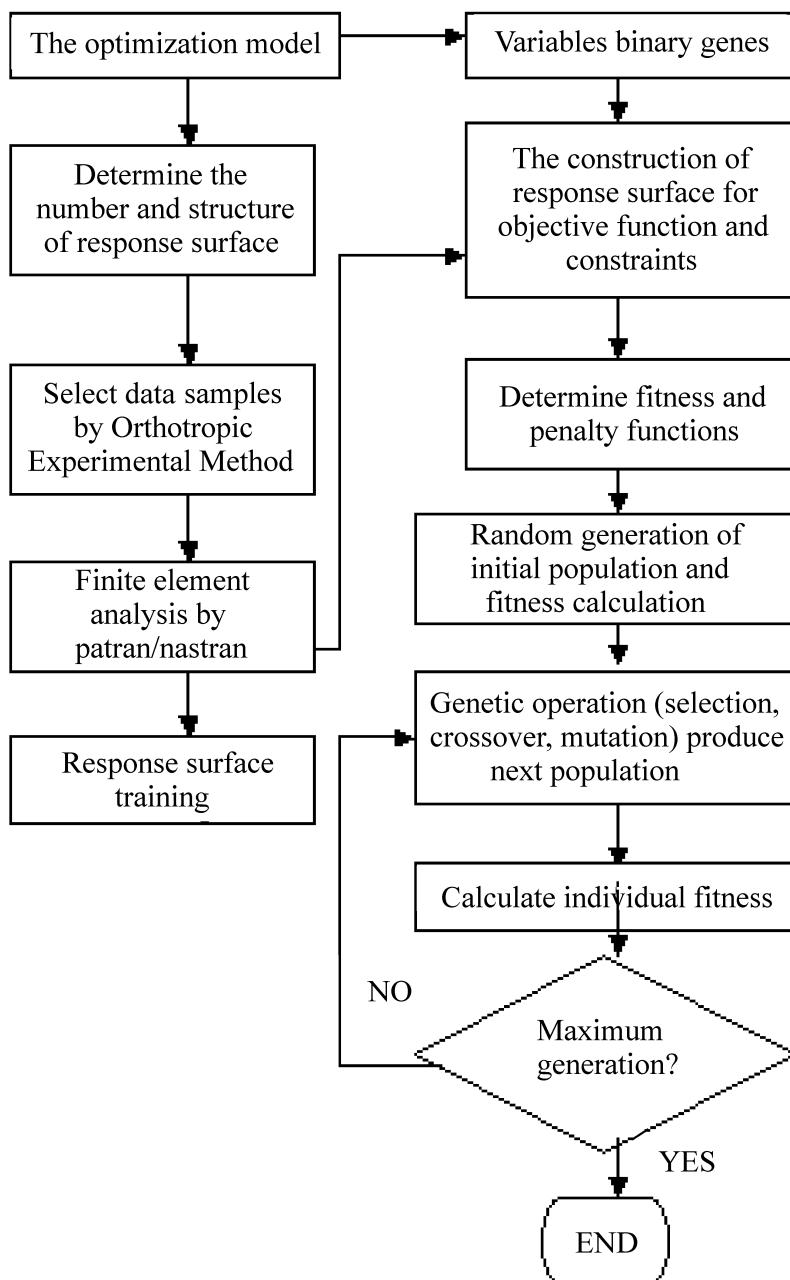


图2 神经网络响应面GA算法结构优化流程图

Fig 2 The chart of neural network response surface and GA for structural optimization

### 3 应用实例

本文中以大型翼身融合体(BWB)客机的乘客区加筋舱板结构设计<sup>[10]</sup>为例, 来验证该优化方法的有效性。这里取该加筋板结构的上盖板, 由于其采用环氧石墨复合材料帽型加筋件, 设计中要考虑强度和受压翘曲稳定性的影响。

#### 3.1 结构描述及优化模型

如图3所示。整个加筋盖板是由沿宽度y方向重复的帽型单元构成, 仅取其中一个单元进行研究。由于帽型单元沿长度x方向上的应力分布是不均匀的, 所以将帽型加筋沿x方向分成三段, 外端的两段相同, 如图4(a)所示, 中间段如图4(b)所示。

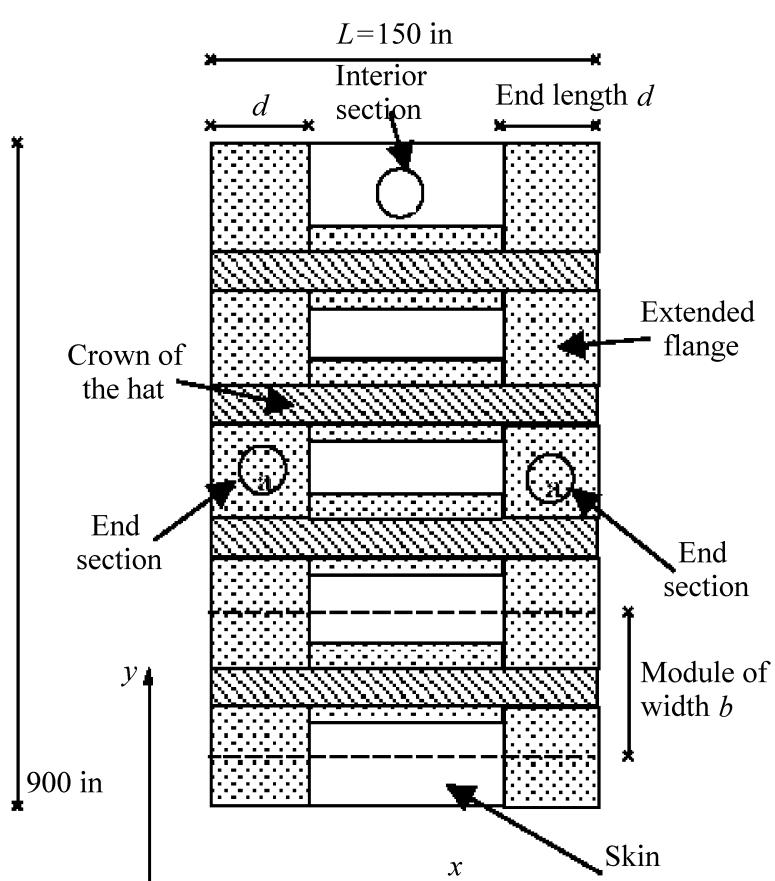


图3 翼身加筋板蒙皮图

Fig 3 A stiffened skin panel for wing-body

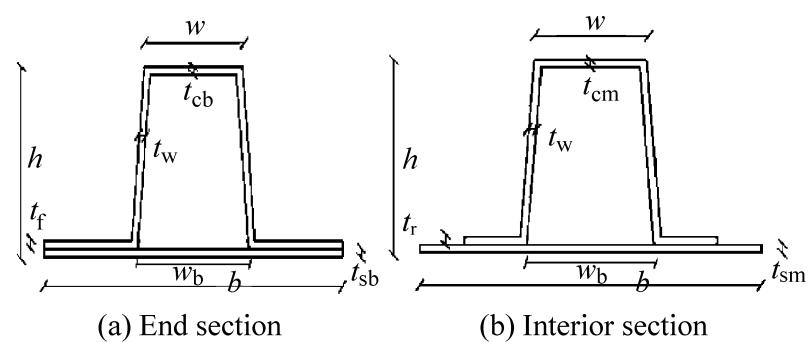


图4 加筋板截面设计参数

其中帽型单元板长L为3810 mm, 宽b为351.282 mm, 高h为165.1 mm, 帽顶宽w为109.22 mm, 帽边厚度t\_w为5.588 mm, 帽底厚度

Fig 4 Cross-sectional design variables for stiffened panel

$t_f$  为 2.794 mm, 均为固定值。

结构所受载荷为: 板沿长度  $x$  方向两端受 755.859 N/mm 的均匀分布的压力  $N_x$ , 受自上到下的 102.3218 kPa 的内压作用。

边界条件为: 板长度  $x$  方向的一端简支, 另一端要求各点沿长度  $x$  方向的位移相同。板沿宽度  $y$  方向的两侧限制高度方向的位移。

加筋板结构为一种复合材料, 整个材料是以 7 层为一个基本厚度单位进行铺设, 铺设顺序为 [45/-45/0/90/0/-45/45]; 7 层总厚度为 1.397 mm。由此, 厚度的设计变量是 1.397 的整数倍的离散变量。材料属性参数如表 1 所示。

表 1 材料属性

Table 1 Material property

Property	Value	Property	Value
$E_{11}/\text{GPa}$	63.779	$\nu_{11}$	0.0054
$E_{22}/\text{GPa}$	32.200	$\nu_{21}/\text{MPa}$	344.75
$G_{12}/\text{GPa}$	15.652	$\nu_{31}/\text{MPa}$	124.11
$t_{12}$	0.397	$/(\text{kg} \cdot \text{m}^{-3})$	157.775

设计变量 5 个:  $d$  外端段长度;  $t_{sb}$  外端段板蒙皮厚度;  $t_{sm}$  中间段板蒙皮厚度;  $t_{cb}$  外端段帽顶厚度;  $t_{cm}$  中间段帽顶厚度。

约束条件包括:  $t_{sb}$ 、 $t_{sm}$  和  $t_{cm}$ 、 $t_{cb}$ , 同时满足强度和稳定性安全。

目标函数取帽型加筋板单元重量  $W$  为最小。

### 3.2 样本设计及响应面训练误差分析

由材料的铺设方法可以确定设计点范围为如下表 2 所示。这样共产生  $4 \times 7^4$  个设计样本。

表 2 设计变量范围(单位: mm)

Table 2 Candidate points of design (Unit: mm)

Variables	Minimum	Step	Maximum
$d$	304.8	304.8	1219.2
$t_{sb}$	2.794	1.397	11.176
$t_{sm}$	2.794	1.397	11.176
$t_{cb}$	2.794	1.397	11.176
$t_{cm}$	2.794	1.397	11.176

通过正交试验法确定 80 个典型训练样本(即取 5 组 5 因素 4 水平正交表  $L_{16}(4^5)$ ), 用于训练重量目标函数  $W$  响应面, 强度  $FI$  响应面, 稳定性 响应面。另外通过随机的方法在设计区域内产生 50 个检测样本来进行响应面泛化能力的检测。

在进行有限元结构计算之前, 对压力  $N$  取 1.25 的安全系数, 所以最终的结构有限元计算取  $N_x = 944.823 \text{ N/mm}$ ,  $p = 127.902 \text{ kPa}$ 。用 PATRAN/NASTRAN 计算结构的稳定性系数, 由公式  $([K] - [K_g])\{\} = 0$  可得。其中:  $K$  为全局刚度矩阵;  $K_g$  为几何刚度矩阵;  $\{\}$  为位移。同时计算 Tsai-Hill 系数

$$FI = \frac{\frac{2}{X^2}}{\frac{2}{Y^2}} - \frac{\frac{1}{X^2}}{\frac{1}{S^2}} + \frac{\frac{2}{Z^2}}{\frac{12}{S^2}}$$

表 3 给出了通过正交设计及有限元分析后的一个正交表 16 个训练样本的结果。

表 4 是响应面训练的误差分析结果(神经网络隐层结点个数为 7 个)。

表 3 正交设计训练样本计算结果

Table 3 The calculated results of training data samples by Orthotropic Experiment selected

	$d$	$t_{sb}$	$t_{sm}$	$t_{cb}$	$t_{cm}$	$W$	$FI$
1	1219.2	2.794	2.794	2.794	2.794	2.1682	0.3606
2	1219.2	5.588	5.588	5.588	5.588	2.9455	1.5708
3	1219.2	8.382	8.382	8.382	8.382	3.7228	2.4182
4	1219.2	11.18	11.18	11.18	11.18	4.5000	3.0829
5	914.4	2.794	5.588	8.382	11.18	2.9164	0.6945
6	914.4	5.588	2.794	11.18	8.382	2.9474	0.4305
7	914.4	8.382	11.18	2.794	5.588	3.6467	1.5574
8	914.4	11.18	8.382	5.588	2.794	3.6778	0.8836
9	609.6	2.794	8.382	11.18	5.588	2.9460	0.7363
10	609.6	5.588	11.18	8.382	2.794	3.3111	0.8375
11	609.6	8.382	2.794	5.588	11.18	3.2089	0.4445
12	609.6	11.18	5.588	2.794	8.382	3.5741	1.8654
13	304.8	2.794	11.18	5.588	8.382	2.5702	0.7225
14	304.8	5.588	8.382	2.794	11.18	2.8186	1.3002
15	304.8	8.382	5.588	11.18	2.794	3.6273	0.8494
16	304.8	11.18	2.794	8.382	5.588	3.8756	0.4093

表4 响应面训练结果

Table 4 Results of training for response surface

	Training RMSE	Testing RMSE
Weight (W)	0.0007983	0.002867
Strength (FI)	0.027	0.0757
Buckling ( )	0.0475	0.119

为了更好地说明神经网络响应面比二次响应面对于高度非线性的映射近似更具优越性, 本文中就稳定性响应面近似进行了比较分析。从表5 可以很明显地看出, 通过正交设计选点训练的神经网络响应面比通过 D 优化准则进行的二次响应面, 总体精度更佳。神经网络仅需要 16 个训练样本的检测误差( 均方根误差 RMSE), 要小于二次响应面 23 个样本的情况。而且, 随着样本数目的增加, 神经网络响应面明显优于二次响应面( 如 80 个样本的误差仅为 0.119)。

表5 稳定性响应面训练效果比较

Table 5 Comparison of buckling training efficiency

Samples	Methods	Type of response surface	RMSE
11	D-optimal	2-order	0.61
23	D-optimal	2-order	0.54
33	D-optimal	2-order	0.25
16	OEM	Neural network	0.453
80	OEM	Neural network	0.119

### 3.3 GA 优化结果

算例结构的参考重量大概在 3 kg 左右。由此可以看出, 重量响应面的精度是非常高的( 检测误差仅有 0.0956 % 左右)。所以完全可以用重量响应面代替实际的重量计算作为优化的目标函数。强度约束方面, 理论上 Tsai-Hill 系数 FI 小于 1 是安全的。由于检测误差达到 0.0757, 所以在优化前取 FI 0.9。对于稳定性而言, 大于 1 是稳定的。为了消除检测误差 0.119 的影响, 取 1.1。然后再结合尺寸约束条件  $t_{sb} = t_{sm}$ ,  $t_{cm} = t_{cb}$  进行优化。

最终优化结果为:  $d = 304.8 \text{ mm}$ ,  $T_{sm} = 4.191 \text{ mm}$ ,  $T_{sb} = 5.588 \text{ mm}$ ,  $T_{cm} = 9.779 \text{ mm}$ ,  $T_{cb} = 6.985 \text{ mm}$ 。这里取种群数为 100, 交叉率为 0.6, 变异率为 0.001 进行 200 代优化计算。GA 收敛过程如图 5 所示。

将优化后的结构尺寸进行有限元精确计算, 结果满足约束条件。表6 给出了 GA 优化的 W、 和 FI 结果与有限元实际计算结果的比较。相对误差充分说明了用BP 神经网络来构造响应面近似模型具有很高的预测精度, 且计算代价很小。

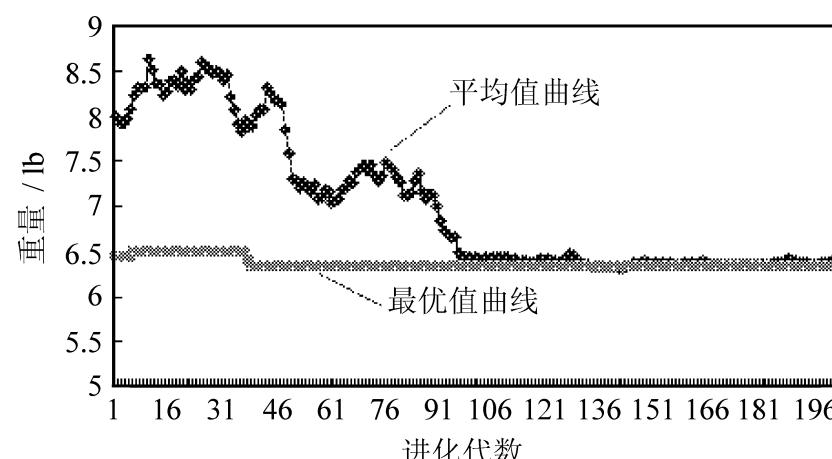


图5 GA 优化收敛过程

Fig. 5 Convergence of GA optimization

表6 优化最终结果

Table 6 The result of GA optimization

	W/kg	FI
Actual results	2.87049	1.70596
Response surface results	2.87602	1.67454
Relative error	0.193 %	1.84 %
	9.02 %	

## 4 结 论

通过上面的算例可以看出, 神经网络响应面近似模型可以很好地代替有限元计算, 从而大大减少优化过程中有限元分析的次数, 提高优化效率。对于大型复杂复合材料结构设计问题来说, 通过正交设计后的样本可以在不同机器上进行分布式并行计算, 极大地缩短了结构分析所需的时间。本文中所述的应用实例中, 响应面的构建仅需要进行 80 次正交样本的有限元计算, 而如果在优化中每次都采用有限元计算的话, 100 个种群进行 200 代演化则需要 20000 次有限元计算。可见, 应用响应面所带来的效率是非常明显的。GA 优化算法与神经网络响应面相结合很好地解决了复合材料结构优化中所遇到的各种困难, 为复合材料结构优化问题提供了一种切实可行的方法。

## 参 考 文 献:

- [1] 郭海丁, 路志峰. 基于 BP 神经网络和遗传算法的结构优化设计 [J]. 航空动力学报, 2003, 18(2): 216 - 220.
- [2] Myers R H, Montgomery D C. Response Surface Methodology [M]. New York: John Wiley and Sons, 2002.
- [3] 孟宪颐. 响应面法在可靠性优化设计中的应用 [J]. 北京建筑工程学院学报, 1999, 15(3): 31 - 36.
- [4] Tai J C, Mavris D N, Schrage D P. Application of a response surface method to the design of tip jet driven stopped rotor/

- wing concepts [ A] . 1st AIAA Aircraft Engineering Technology and Operations Congress [ C] . Los Angeles, California, 1995 . 1 - 13 .
- [ 5] 燕瑛, 刘兵山, 黄聪, 等. 缝合复合材料面内刚度和强度的神经网络预测 [ J] . 复合材料学报, 2004, 21(6) : 179 - 183 .
- [ 6] 李文勇, 李泉永. 利用神经网络进行近似分析的结构优化设计 [ J] . 广西科学, 2001, 8(2) : 86 - 89 .
- [ 7] 袁曾任. 人工神经元网络及其应用 [ M] . 北京: 清华大学出版社, 1999 . 66 - 130 .
- [ 8] 邢小楠, 徐元铭, 李烁. 神经网络响应面逼近优化在飞机总体设计中的应用 [ J] . 机械设计与研究, 2004, 20(1) : 68 - 71 .
- [ 9] 任露泉. 试验优化技术 [ M] . 北京: 机械工业出版社, 1987 . 7 - 15 .
- [ 10] Vitali R. Response surface methods for high dimensional structural design problems [ D] . USA: University of Florida, 2000 . 81 - 84 .

中国科技论文与引文数据库

CSTPCD 2003

## 中国科技论文统计源期刊

(中国科技核心期刊)

期刊检索证明

检索期刊: 复合材料学报

据中国科技论文与引文数据库 (CSTPCD) 统计, 贵刊 2003 年度文献计量学指标的统计结果与排名如下:

影响因子 : 0.566,

在 37 种“材料科学技术类”期刊中列第 5 位,

在 1576 种中国科技论文统计源期刊中列第 229 位。

总被引频次 : 569,

在 37 种“材料科学技术类”期刊中列第 8 位,

在 1576 种中国科技论文统计源期刊中列第 265 位。

详细内容请参见《2004 年版中国科技期刊引证报告》。



二〇〇四年十二月七日