

引文格式: 朱卫华, 王宗园, 周金华, 等. 面向残余应力控制的高温合金铣削刀具几何参数优化方法[J]. 航空制造技术, 2021, 64(14): 79-86.

ZHU Weihua, WANG Zongyuan, ZHOU Jinhua, et al. Optimization of high-temperature alloy milling tool geometry for residual stress control[J]. Aeronautical Manufacturing Technology, 2021, 64(14): 79-86.

面向残余应力控制的高温合金铣削刀具几何参数优化方法*

朱卫华^{1,2}, 王宗园¹, 周金华¹, 路超凡¹

(1. 西北工业大学, 西安 710072;

2. 海装驻西安地区第五军事代表室, 西安 712101)

[摘要] 针对 GH4169 铣削过程, 采用正交试验获得了不同刀具结构参数下的表面残余应力。利用遗传算法(GA)优化了 BP 神经网络的初始权值和阈值, 提高了模型的收敛速度和预测精度, 并提出应用 GA-BP 模型预测铣削残余应力的方法。研究了基于萤火虫算法(FA)进行工艺参数优化的方法, 结合 GA-BP 预测模型, 建立了铣削残余应力的 GA-BP-FA 参数优化模型, 并以同时获得最小残余拉应力/最大残余压应力为目标, 进行刀具几何参数的多目标优化。结果表明, 采用优化后的刀具几何参数, 可以获得 X 方向的最小残余拉应力、Y 方向的最大残余压应力。

关键词: 铣削; 高温合金; 残余应力; 刀具结构; 优化方法

Optimization of High-Temperature Alloy Milling Tool Geometry for Residual Stress Control

ZHU Weihua^{1,2}, WANG Zongyuan¹, ZHOU Jinhua¹, LU Chaofan¹

(1. Northwestern Polytechnical University, Xi'an 710072, China;

2. Office of Fifth Military Representative of the Navy in Xi'an, Xi'an 712101, China)

[ABSTRACT] With regard to the milling process of GH4169, the surface residual stresses under different tool structural parameters were obtained based on orthogonal experimental method. The initial weights and thresholds of the BP neural network were optimized using a genetic algorithm (GA) to improve the convergence speed and prediction accuracy of the model, and a method for applying the GA-BP model to predict the milling residual stress was proposed. The firefly algorithm (FA)-based method for process parameter optimization was investigated, and the GA-BP-FA parameter optimization model for milling residual stresses was established in combination with the GA-BP prediction model for multi-objective optimization of tool geometry parameters with the goal of simultaneously obtaining the minimum residual tensile stress/maximum residual compressive stress. The results show that the minimum residual tensile stress in the X-direction and the maximum residual compressive stress in the Y-direction can be obtained using the optimized tool geometry parameters.

Keywords: Milling; High-temperature alloy; Residual stress; Tool geometric parameters; Optimization methods

DOI: 10.16080/j.issn1671-833x.2021.14.079

GH4169 是一种极难加工的金属材料, 在切削过程中切削力大、温度高, 容易发生塑性变形, 且已加工表面残余应力常为拉伸应力^[1]。上述问题会影响构件的残余应力分布状态, 造成构件局部应力集中, 导致表面裂

纹的萌生与扩展, 进而影响构件的使用性能^[2]。

在高温合金切削加工过程中, 残余应力的分布状态与刀具性能有着密切的联系, 而可供选择的刀具材料主要为硬质合金, 因此研究刀具结构对高温合金铣削加工

* 基金项目: 国家自然科学基金(51775444, 52075451); 航空科学基金(2019ZE053008); 中国博士后科学基金(2020M683551)。

性能以及残余应力分布的影响是十分必要的。Yen 等^[3]通过有限元分析结合正交试验的方法,初步研究了刀尖形状对残余应力、应变、切削力、切削温度的影响。Lo^[4]利用有限元法研究了刀具前角对残余应力、切屑的形成以及工件最后的表面粗糙度的影响。Zong 等^[5]采用有限元方法研究了刀具后角对残余应力的影响,并对刀具几何参数进行优化,发现当后角取为 6° 时,残余拉应力达到最小,而当后角取为 9° 时,残余压应力最小。任军学等^[6]针对硬质合金球头刀铣削 TC17 钛合金,通过研究刀具参数对残余应力、表面粗糙度、形貌的影响,得到了一组较好的刀具参数。Liu 等^[7]研究了刀尖圆角对 CBN 刀具车削残余应力的影响,结果表明,刀尖圆角增加及刀具磨损都会使表面残余应力由压应力变为拉应力。Capello 等^[8]试验研究了外圆车削 C45 和 39NiCrMo3 钢的残余应力,认为刀尖圆角与进给量对表面残余应力有主要的影响,切削速度与主前角的影响很小。Jiang 等^[9]研究了刀具直径对铣削残余应力的影响,发现采用大直径的铣刀加工可以明显地减小残余拉应力。

本文针对球头多轴铣削过程,使用遗传算法优化的 BP 神经网络建立了刀具几何参数对高温合金铣削残余应力影响的预测模型,并利用萤火虫算法对刀具几何参数进行优化,为高温合金航空结构铣削加工提供刀具选择的依据和方法。

1 试验过程

1.1 试件材料

高温合金按基体元素可以分为铁基高温合金、镍基高温合金、镍铁基高温合金和钴基高温合金四大类。GH4169 为以体心立方 γ'' 和面心立方 γ' 相沉淀强化的镍基高温合金,其化学成分及力学性能如表 1 和表 2 所示。

1.2 试验方案

试验机床采用 FVP-800A 三坐标精密立式加工中心,铣削方式为逆铣,冷却方式为乳化液冷却。采用 17 种 $\Phi 8$ 硬质合金球头刀进行试验,为了减小刀具磨损对铣削残余应力的影响,每次试验均采用一把全新的刀

具。球头铣刀的具体材料与参数为: K44 硬质合金,四齿,直径为 8mm,总长为 110mm,刃长为 12mm,铣削试验时的刀具悬长设置为 76mm。根据刀具参数的不同,采用 3 因素 4 水平正交试验的方法进行高温合金 GH4169 铣削试验,如表 3 所示。

每个试件规划 6 个加工区域,斜面与水平面的夹角 Φ 均为 85°,每个区域为 37.5mm × 20mm 的矩形,以保证每组试验加工区域的条件相同,如图 1 所示。指定进给方向为 x 轴, y 轴位于加工表面内并垂直于 x 轴。试验前,对试件进行去应力退火热处理,并且铣掉加工区域距表面 0.5mm 深度的硬化表层,分两次进行,铣削深度分别 0.3mm 和 0.2mm,具体试验铣削参数如表 4 所示。铣削试验现场如图 2 所示。

表 2 GH4169 力学性能(20°C)
Table 2 Mechanical properties of GH4169 (20°C)

抗拉强度 / MPa	屈服强度 / MPa	延伸率 / %	收缩率 / %	硬度 (HV)
1310	1110	20	46	468

表 3 试验因素及其相应水平
Table 3 Experimental factors and their corresponding levels

水平	因素		
	前角 $\gamma_0 / (^\circ)$	后角 $\alpha_0 / (^\circ)$	螺旋角 $\beta_0 / (^\circ)$
1	3	5	30
2	8	10	38
3	13	15	46
4	18	20	54

表 1 GH4169 的主要化学成分(质量分数)

Table 1 Main chemical composition of GH4169 (mass fraction) %

C	Si	Mn	P	S	Cr	Ni
0.042	0.21	0.03	0.005	0.001	17.00	51.75
Ti	Nb	Mo	B	Mg	Cu	Fe
1.04	5.11	2.93	0.006	0.004	<0.07	剩余




图 1 试件实物尺寸

Fig.1 Physical size of specimen

表 4 铣削参数
Table 4 Milling parameters

转速 $n/$ ($r \cdot \min^{-1}$)	进给 $F/$ ($\text{mm} \cdot \min^{-1}$)	切宽 $a_d/$ mm	切深 $a_p/$ mm	切削速度 $v_d/$ ($\text{mm} \cdot \text{z}^{-1}$)	每齿进 给量 $f_z/$ ($\text{mm} \cdot \text{z}^{-1}$)
1592	384	0.35	0.25	40	0.06




图 2 铣削试验现场
Fig.2 Milling experiment site

1.3 残余应力测试及结果

残余应力测试采用 PROTO LXR D-MG2000 残余应力测试分析系统。测试采用 Mn 靶 K Alpha 波段, 靶电压 25kV, 靶电流 20mA, 布拉格角 152° , 曝光时间 2s, 曝光次数 10 次, 焦斑大小 2mm。残余应力测试过程如图 3 所示, 测试结果如表 5 所示。




图 3 PROTO LXR D-MG2000 残余应力测试系统
Fig.3 Residual stress test system of PROTO LXR D-MG2000

表 5 正交试验残余应力测试结果
Table 5 Results of orthogonal experimental residual stress tests

试验编号	前角 $\gamma_0/$ ($^\circ$)	后角 $\alpha_0/$ ($^\circ$)	螺旋角 $\beta_0/$ ($^\circ$)	表面残余应力 /MPa	
				σ_x	σ_y
1	3	5	30	161.9	73.3
2	3	10	38	61.7	-127.7
3	3	15	46	50.8	-95.8
4	3	20	54	87.2	-113.7
5	8	5	38	35.3	-5.9
6	8	10	30	182.3	13.9
7	8	15	54	-0.8	-234.5
8	8	20	46	93	-80
9	13	5	46	74.8	-40.8
10	13	10	54	68.3	-201.7
11	13	15	30	47	-75.5
12	13	20	38	120	-68.3
13	18	5	54	65.3	31.4
14	18	10	46	6.2	-74.2
15	18	15	38	10.4	-121.3
16	18	20	30	92.2	-22.6
17	10	12	40	94.7	4.8

2 遗传算法优化 BP 神经网络

神经网络算法通过模拟大量神经元的信息传导方式,将其互联起来组成网络模型。虽然 BP 算法有寻优精确的特点,但学习速度慢且为局部搜索的优化方法,可能陷入局部极值,使训练失败。遗传算法具有良好的全局搜索能力,求解时使用特定问题的信息少且具有极强的容错能力,同时选择、交叉和变异都为随机操作,无须确定的精确规则。因此,利用遗传算法优化传统 BP 神经网络,既可以减小遗传算法的搜索空间,提高搜索效率,又可以较易地搜索最优解。通过 GA 算法优化 BP 网络的初始阈值和权值,使网络结构更加科学规范,从而实现更好的预测效果。优化要素主要包括以下内容。

(1) 种群初始化。

设初始化的种群 $C=\{C_1, C_2, \dots, C_N\}$,第 n 个个体 C^n 包含 BP 神经网络输入层到隐含层的权值矩阵 $W1^n$ 、隐含层到输出层的权值矩阵 $W2^n$ 、隐含层神经元的阈值向量 $B1^n$ 、输出层神经元的阈值向量 $B2^n$ 。

$$\begin{aligned}
 W1^n &= \begin{bmatrix} \omega_{11}^n & \omega_{12}^n & \dots & \omega_{1I}^n \\ \omega_{21}^n & \omega_{22}^n & \dots & \omega_{2I}^n \\ \vdots & \vdots & \ddots & \vdots \\ \omega_{M1}^n & \omega_{M2}^n & \dots & \omega_{MI}^n \end{bmatrix} \\
 W2^n &= \begin{bmatrix} \omega_{21}^n & \omega_{22}^n & \dots & \omega_{2J}^n \\ \omega_{21}^n & \omega_{22}^n & \dots & \omega_{2J}^n \\ \vdots & \vdots & \ddots & \vdots \\ \omega_{21}^n & \omega_{22}^n & \dots & \omega_{2J}^n \end{bmatrix} \\
 B1^n &= [b1_1^n \quad b1_2^n \quad \dots \quad b1_I^n] \\
 B2^n &= [b2_1^n \quad b2_2^n \quad \dots \quad b2_J^n]
 \end{aligned} \tag{1}$$

式中, N 为种群规模; M 为输入层神经元的个数; I 为隐含层的神经元个数; J 为输出层的神经元个数; ω_{ij}^n 表示输入层的第 m 个神经元到隐含层的第 i 个神经元的初始权值; ω_{ij}^n 表示隐含层的第 i 个神经元到输出层的第 j 个神经元的初始权值; $b1_i^n$ 表示隐含层第 i 个神经元的阈值; $b2_j^n$ 表示输出层第 j 个神经元的阈值。将 $W1^n$ 、 $W2^n$ 、 $B1^n$ 、 $B2^n$ 中的所有元素随机赋予某区间上的值。

(2) 适应度函数。

神经网络模型确定后,通过训练样本对网络进行训练,系统可预测输出结果,将预测结果与期望的输出结果作差,即误差,将个体适应度值 F 设置为误差绝对值和:

$$F = k \left(\sum_{i=1}^n \text{abs}(y_i - o_i) \right) \tag{2}$$

式中, n 表示网络的输出节点数目; y_i 表示网络的第 i 个节点期望的输出结果; o_i 表示第 i 个节点的预测结果; k 为系数。

(3) 选择操作。

轮盘赌法作为遗传算法的选择操作,该选择策略实际是依据适应度比例,每个染色体 i 的选择概率 p_i 可以表示为:

$$f_i = k/F_i \tag{3}$$

$$p_i = \frac{f_i}{\sum_{j=1}^{N_1} f_j} \tag{4}$$

式中, F_i 是染色体 i 的适应度; k 为系数; f_i 为个体适应度值, N_1 为种群染色体数目。

根据选择概率 p_i ($i=1,2,\dots,n$) 把一个圆盘分成 n 份。在进行选择时,可转动圆盘,若某点落到第 i 个扇形内,则选择个体 i 。

(4) 交叉操作。

由于染色体采用实数编码,因此交叉操作采用实数交叉的方法,第 k 个染色体 a_k 和第 l 个染色体 a_l 在 j 位置的交叉方法可以表示为:

$$\begin{cases} a_{kj} = a_{lj}(1-b) + a_{kj}b \\ a_{lj} = a_{kj}(1-b) + a_{lj}b \end{cases} \tag{5}$$

式中, b 为随机数,范围是 $[0,1]$ 。

(5) 变异操作。

选取第 i 个染色体的第 j 位基因 a 进行变异操作,可表示为:

$$a_{ij} = \begin{cases} a_{ij} + (a_{\max} - a_{ij}) \cdot f(g) & r > 0.5 \\ a_{ij} + (a_{\min} - a_{ij}) \cdot f(g) & r \leq 0.5 \end{cases} \tag{6}$$

式中, a_{\max} 为基因 a_{ij} 的上界; a_{\min} 为基因 a_{ij} 的下界; $f(g) = r_2(1-g/G_{\max})^2$; g 为当前迭代次数; G_{\max} 是最大进化次数; r, r_2 都为随机数,范围是 $[0,1]$ 。

确定神经网络的合适结构之后,GA 对网络权值和阈值进行初始化,会随机分配权值、阈值向量 ω 、 b 值给不同的神经元,输入向量 x ,经过 S 型函数变换后,作为下一层的输入量,最终经过输出层线性函数变化,得到网络模型输出结果 σ_x, σ_y ,其与测量值之间存在误差 e , e 是 ω 、 b 的函数,把 16 组训练数据的绝对误差和 $\sum_{i=1}^{16} |e|$ 作为适应度函数。将刀具几何参数范围设为约束条件:前角 $\gamma_0=[3^\circ, 18^\circ]$,后角 $\alpha_0=[5^\circ, 20^\circ]$,螺旋角 $\beta=[30^\circ, 54^\circ]$ 。

由于过度训练是 BP 网络训练面对的主要问题之一,每个依赖其学习能力的神经网络应当避免过度训练^[10]。

目前通过反复调试程序的方法,不断尝试改变 GA 终止进化代数、初始种群规模、交叉概率、变异概率,可以获得合适的神经网络权值阈值,即得到使得 16 组训练数据误差和 $\sum_{i=1}^{16} |e_i|$ 最小的权值 ω 和阈值 b 。最终采用的遗传算法主要参数如表 6 所示。基于 GA 优化的 BP 神经网络建模流程如图 4 所示。

3 工艺参数优化方法

3.1 萤火虫算法

萤火虫算法 (FA) 是受自然界中的萤火虫通过荧光进行信息交流这种群体行为的启发演变而来的一种新颖的仿生群智能优化算法。萤火虫彼此吸引的原因取决于两个因素,即自身亮度和吸引度。其中,萤火虫发出荧光的亮度取决于自身所在位置的目标值,位置越好目标值越佳。萤火虫的吸引度与亮度,与它们的距离成反比关系^[11]。

在萤火虫算法中,萤火虫由于“亮度”不同,受到的“吸引力”也不同,从而产生“位移”,算法的 3 个要素:亮度、吸引度和位移^[12],具体定义为:

3.1.1 萤火虫的亮度

(1) 相对荧光亮度。

假定在解空间中的位置向量 x_i 和位置向量 x_j 上存在两个萤火虫个体 i 和 j , 它们的相对荧光亮度可以表示为:

$$I(r_{ij}) = I_0 e^{-\gamma r_{ij}} \quad (7)$$

式中, I_0 表示最大荧光亮度,也就是自身光源 ($r=0$) 处的亮度,与目标函数(适应度函数)关系密切,目标函数越好萤火虫会越亮; γ 表示光强吸收系数,设置 γ 是为了体现荧光随距离增加和传播媒介吸收逐渐减弱的特性,可设为常数; r_{ij} 为萤火虫 i 与 j 之间的空间距离,由笛卡尔距离公式给出:

$$r_{ij} = \|x_i - x_j\| = \sqrt{\sum_{m=1}^D (x_{i,m} - x_{j,m})^2} \quad (8)$$

表 6 遗传算法主要参数
Table 6 Main parameters of genetic algorithm

GA 优化的网络类型	终止进化代数 T	种群规模	交叉概率 P_c	变异概率 P_m
σ_x 网络	2000	100	0.6	0.05
σ_y 网络	2000	100	0.5	0.09

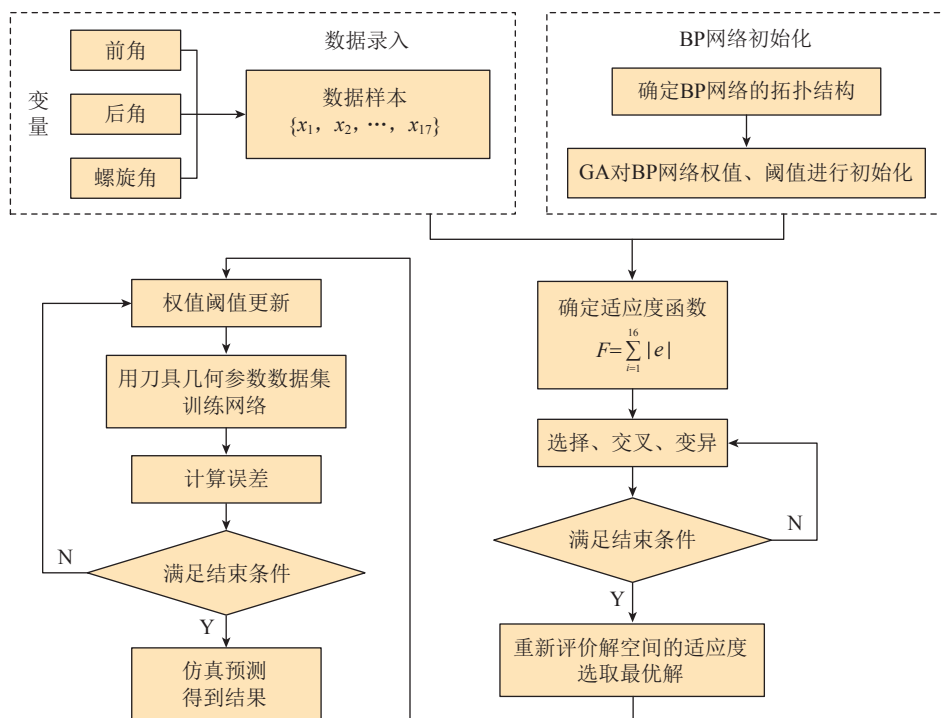


图 4 GA 优化 BP 神经网络流程图
Fig.4 Flowchart of GA-optimized BP neural network

式中, D 是空间维数; $\mathbf{x}_{i,m}$ 表示萤火虫 i 在 D 维空间中的第 m 个分量。

(2) 绝对荧光亮度。

目标函数决定了萤火虫的绝对亮度, 因此绝对亮度的取值大小反映了该萤火虫表示的潜在解的好坏, 萤火虫的绝对亮度越大, 则它代表的潜在解越好。

在具体优化问题中, 在位置 \mathbf{x} 处的萤火虫绝对荧光亮度 $I(\mathbf{x}) \propto F(\mathbf{x})$, $F(\mathbf{x})$ 为目标函数。将萤火虫 i 与萤火虫 j 绝对亮度分别表示为 $I_i(\mathbf{x})$ 、 $I_j(\mathbf{x})$ 。若 $I_i(\mathbf{x}) > I_j(\mathbf{x})$, 则萤火虫 i 吸引萤火虫 j 向其移动; 相反, 萤火虫 j 吸引萤火虫 i 向其移动。

3.1.2 萤火虫吸引度

萤火虫吸引度可以表示为:

$$\beta(r_{ij}) = \beta_0 e^{-\gamma r_{ij}^2} \quad (9)$$

式中, β_0 表示萤火虫吸引度的最大值, 也就是自身光源 ($r=0$) 的吸引度; γ 表示光强吸收系数, 可设为常数; r_{ij} 表示不同的萤火虫 i 与 j 之间的空间距离。

3.1.3 位置更新

假设 $I_i < I_j$, 即萤火虫 j 吸引萤火虫 i 向其移动, 萤火虫 i 位置更新由式(4)决定:

$$\mathbf{x}_i^{\text{new}} = \mathbf{x}_i^{\text{old}} + \beta(r_{ij})(\mathbf{x}_j - \mathbf{x}_i^{\text{old}}) + \alpha \left(\text{rand} - \frac{1}{2} \right) \quad (10)$$

式中, $\mathbf{x}_i^{\text{old}}$ 和 $\mathbf{x}_i^{\text{new}}$ 分别为萤火虫 i 更新前后的位置向量; α 为步长因子, 是 $[0, 1]$ 上的常数; rand 为 $[0, 1]$ 上服从均匀分布的随机因子。显然, 位置更新公式的第 2 项取决于吸引度, 第 3 项是带有特定系数的随机项。

3.2 目标优化函数

3.2.1 约束条件

建立 BP 神经网络模型时, 刀具前角、后角、螺旋角是在一定范围内变化的, 模型在该范围内才能较为准确地进行预估计算, 因此刀具几何参数优化的约束条件为: 前角 $\gamma_0 = [3^\circ, 18^\circ]$, 后角 $\alpha_0 = [5^\circ, 20^\circ]$, 螺旋角 $\beta = [30^\circ, 54^\circ]$ 。对于既定的铣削试验, 铣削参数被认为是确定的, 即进给 F 、切宽 a_e 、切深 a_p 、切削速度 V_c 、每齿进给量 f_z 。

3.2.2 目标函数

目标函数 $F(x)$ 为铣削残余应力的预测模型 $\sigma_x(\gamma_0, \alpha_0, \beta)$, $\sigma_y(\gamma_0, \alpha_0, \beta)$ 。最终的最佳适应度即最小拉应力/最大压应力, 平均适应度为所有萤火虫个体适应度的算术平均值, 则总体优化目标函数可表示为:

$$F(\gamma_0, \alpha_0, \beta) = 0.5\sigma_x(\gamma_0, \alpha_0, \beta) + 0.5\sigma_y(\gamma_0, \alpha_0, \beta) \quad (11)$$

3.2.3 优化模型

由于萤火虫算法是搜寻亮度最强的萤火虫的位置, 而本文的目标是寻找使残余拉应力最小/残余压应力最大的刀具几何参数。把萤火虫的位置向量用刀具几

何参数表示:

$$\mathbf{x} = (\gamma_0, \alpha_0, \beta) \quad (12)$$

则萤火虫的亮度函数可以定义为:

$$I(\mathbf{x}) = -F(\gamma_0, \alpha_0, \beta) \quad (13)$$

将式(12)代入式(9)和式(10), 即可得到萤火虫的吸引度和位置更新函数。具体刀具几何参数优化流程如图 5 所示。

4 结果与讨论

4.1 残余应力预测结果

经过遗传算法优化后, BP 神经网络的初始权值、阈值已经达到较佳的状态, 然后用训练数据集对 BP 神经网络的初始权值、阈值进行学习。当达到网络训练要求后, 停止训练。最终得到的两个表面残余应力分量模型为 $\sigma_x(\gamma_0, \alpha_0, \beta)$, $\sigma_y(\gamma_0, \alpha_0, \beta)$, 将刀具几何参数作为铣削残余应力模型的输入值, 经过计算得到预测输出值。图 6 为训练 σ_x 和 σ_y 的 BP 网络时, GA 的收敛情况。

将 σ_x 和 σ_y 的 BP 网络模型的预测值与相应的试验真实值进行对比, 结果如图 7 所示, 其中前 16 组分别为两种 BP 网络的训练数据预测结果, 第 17 组为测试数据的预测结果。表 7 给出了两种网络模型的最终误差

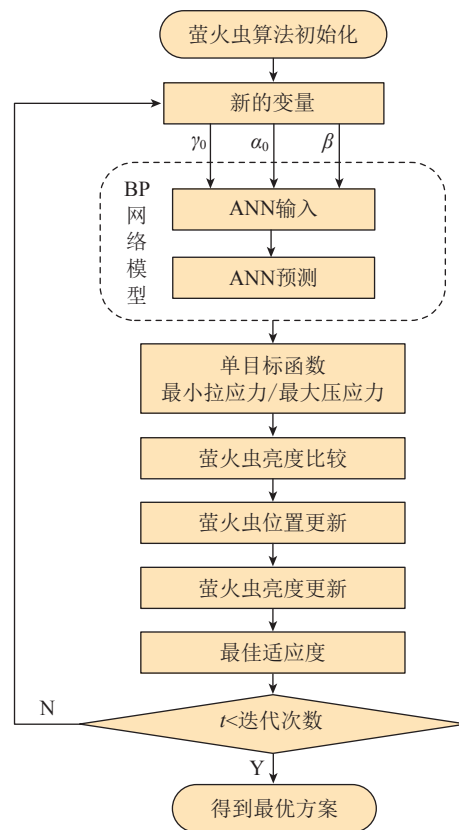


图 5 刀具几何参数优化流程图
Fig.5 Flowchart of tool geometry optimization

统计情况。

可以看出,模型的预测值和真实值非常接近,训练数据和测试数据的误差很小,网络已被很好地训练。这得益于之前大量调试程序获取的合理的 GA 终止进化代数、初始种群规模、交叉概率、变异概率,因此优化的 BP 网络初始权值阈值更能满足网络需求。

4.2 刀具几何参数优化结果

经过大量程序测试,萤火虫算法的主要参数最终选定:种群规模为 100;迭代次数为 1000;步长因子为 0.2;光强吸收系数为 1;初始吸引度为 1。采用萤火虫算法对刀具几何参数进行多目标优化,适应度收敛曲线如图 8 所示。优化结果如表 8 所示。应用萤火虫算法对刀具几何参数进行多目标优化,即考虑 x 方向最小残余应力、 y 方向最大残余应力。由于刀具在制作过程中存在

偏差,同时为了便于工人磨制刀具,因此刀具角度取为优化结果的相近值:前角 $\gamma_0=6.5^\circ$ 、后角 $\alpha_0=8.5^\circ$ 、螺旋角 $\beta=48.5^\circ$ 。

4.3 试验验证

为了证明优化结果的可行性,需要通过实际加工试验对优化结果进行验证。由于刀具在制作过程中存

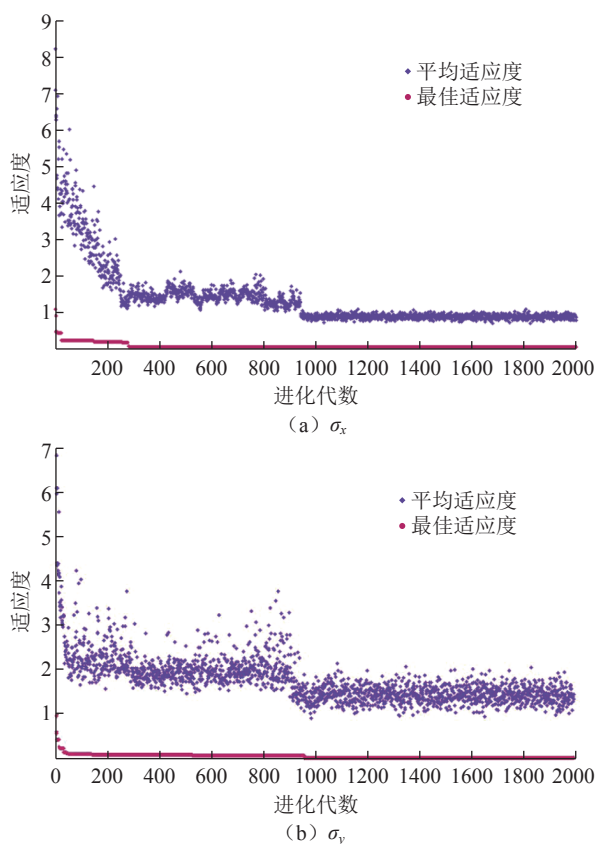


图 6 GA 优化 σ_x 和 σ_y 网络的适应度收敛图

Fig.6 Convergence plot of adaptation for GA optimized σ_x and σ_y network

表 7 σ_x 和 σ_y 的网络模型误差统计

Table 7 Network model error statistics for σ_x and σ_y

网络类型	训练平均绝对误差 (MAE)	训练平均绝对误差率 /%	预测绝对误差率 /%
σ_x 网络	4.62	18	20
σ_y 网络	5.68	21	24




图 7 σ_x 和 σ_y 的 BP 网络预测结果

Fig.7 BP network prediction results for σ_x and σ_y




图 8 萤火虫算法多目标优化的适应度

Fig.8 Adaptation of firefly algorithm for multi-objective optimization

在偏差,同时为了便于工人磨制刀具,因此刀具角度取为优化结果的相近值:前角 $\gamma_0=6.5^\circ$,后角 $\alpha_0=8.5^\circ$,螺旋角 $\beta=48.5^\circ$,刀具其他参数及铣削参数与 1.2 节中试验方案相同,加工完后对表面残余应力值进行检测,测量值如表 9 所示。可知, σ_x 和 σ_y 的测量结果和优化结果误差较小,说明使用本文优化的刀具几何参数,可以获得较为满意的表面残余应力 σ_x 和 σ_y 。

表 8 萤火虫算法多目标优化结果

Table 8 Multi-objective optimization results of firefly algorithm

前角 $\gamma_0/$ ($^\circ$)	后角 $\alpha_0/$ ($^\circ$)	螺旋角 $\beta/$ ($^\circ$)	最大萤火虫 亮度 I_{max}	σ_x 预测值 / MPa	σ_y 预测值 / MPa
6.57	8.31	48.62	0.6692	-0.86	-338.56

表 9 刀具参数优化方案验证结果

Table 9 Validation results of tool parameter optimization

试验与优化	$\sigma_x/$ MPa	$\sigma_y/$ MPa
试验结果	2.30	-322.90
优化预测结果	0.86	-338.56

5 结论

(1) 运用遗传算法优化神经网络的初始阈值和权重,可以使神经网络能更高效准确地对数据样本进行训练,能够提高网络模型的精准度。

(2) 基于残余应力的 GA-BP 预测模型,应用萤火虫算法对刀具几何参数进行多目标优化。最终综合考虑 x 方向、 y 方向残余应力,优选的刀具几何参数为:前角 $\gamma_0=6.5^\circ$ 、后角 $\alpha_0=8.5^\circ$ 、螺旋角 $\beta=48.5^\circ$,验证试验结果表明,优化方法与结果可行。

参考文献

[1] WALL D J, EVANS A G, MARSHALL D B, et al. Residual stresses in machined ceramic surfaces[J]. Journal of American Ceramic Society, 1986, 69(1): 44-47.

[2] WYATT J E, BERRY J T. A new technique for the determination of superficial residual stresses associated with machining and other manufacturing processes[J]. Journal of Materials Processing Technology, 2006, 171(1): 132-140.

[3] YEN Y C, JAIN A R, ALTAN T. A finite element analysis of orthogonal machining using different tool edge geometries[J]. Journal of Materials Processing Technology, 2004, 146(1): 72-81.

[4] LO S P. An analysis of cutting under different rake angles using the finite element method[J]. Journal of Materials Processing Technology, 2000, 105(1-2): 143-151.

[5] ZONG W J, SUN T, LI D, et al. FEM optimization of tool

geometry based on the machined near surface's residual stresses generated in diamond turning[J]. Journal of Materials Processing Technology, 2006, 180(1-3): 271-278.

[6] 任军学,姚倡锋,田卫军,等.球头铣刀结构参数对钛合金铣削表面完整性的影响[J].航空制造技术,2010,53(1):81-84.

REN Junxue, YAO Changfeng, TIAN Weijun, et al. Effect of ball-end milling structural parameters on surface integrity for titanium alloy milling[J]. Aeronautical Manufacturing Technology, 2010, 53(1): 81-84.

[7] LIU M, TAKAGI J, TSUKUDA A. Effect of tool nose radius and tool wear on residual stress distribution in hard turning of bearing steel[J]. Journal of Materials Processing Technology, 2004, 150(3): 234-241.

[8] CAPELLO E, DAVOLI P, BASSANINI G, et al. Residual stresses and surface roughness in turning[J]. Journal of Engineering Materials Technology, 1999, 121(3): 346-351.

[9] JIANG X H, LI B, YANG J G, et al. Effects of tool diameters on the residual stress and distortion induced by milling of thin-walled part[J]. International Journal of Advanced Manufacturing Technology, 2013, 68(1-4): 175-186.

[10] ZUPERL U, CUS F, MURSEC B, et al. A generalized neural network model of ball-end milling force system[J]. Journal of Materials Processing Technology, 2006, 175(1-3): 98-108.

[11] 刘长平,叶春明.一种新颖的仿生群智能优化算法:萤火虫算法[J].计算机应用研究,2011,28(9):3295-3297.

LIU Changping, YE Chunming. Novel bioinspired swarm intelligence optimization algorithm: firefly algorithm[J]. Application Research of Computers, 2011, 28(9): 3295-3297.

[12] VERMA O P, AGGARWAL D, PATODI T. Opposition and dimensional based modified firefly algorithm[J]. Expert Systems with Applications, 2016, 44: 168-176.

通讯作者:王宗园,助理研究员、硕士,研究方向为航空发动机精密加工变形控制。

(责编 七七)

(上接第 78 页)

ZHUANG Cunbo, LIU Jianhua, XIONG Hui, et al. Connotation, architecture and trends of product digital twin[J]. Computer Integrated Manufacturing Systems, 2017, 23(4): 753-768.

[9] ROSEN R, VON WICHERT G, LO G, et al. About the importance of autonomy and digital twins for the future of manufacturing[J]. IFAC-PapersOnLine, 2015, 48(3): 567-572.

[10] QI Q L, TAO F. Digital twin and big data towards smart manufacturing and industry 4.0: 360 degree comparison[J]. IEEE Access, 2018, 6: 3585-3593.

通讯作者:吕瑞强,高级工程师,研究方向包括数字化制造、智能制造系统规划等。

(责编 七七)