

引文格式: 李超, 王仲奇, 常正平, 等. 基于BP神经网络和多目标粒子群算法的自动钻铆工艺参数优化方法[J]. 航空制造技术, 2021, 64(23/24): 94-102.

LI Chao, WANG Zhongqi, CHANG Zhengping, et al. Automatic drilling and riveting process parameter optimization method based on BP neural network and multi-objective particle swarm optimization algorithm[J]. Aeronautical Manufacturing Technology, 2021, 64(23/24): 94-102.

基于BP神经网络和多目标粒子群算法的自动钻铆工艺参数优化方法*

李超, 王仲奇, 常正平, 马健智

(西北工业大学, 西安 710072)

[摘要] 飞机壁板自动钻铆大量采用干涉连接, 干涉量的均匀程度与壁板变形程度的协同控制是目前亟须解决的问题, 为此提出一种基于BP神经网络(BP neural network, BPNN)的优化方法。以压铆力、压铆过程时间、压铆停留时间和夹紧力为变量, 以仿真数据为样本, 采用BP神经网络, 建立干涉量均匀程度和壁板变形程度的预测模型, 利用多目标粒子群算法(Multi-objective particle swarm optimization, MOPSO)进行多目标优化。仿真及试验结果表明, 优化后的参数能够显著提升干涉量的均匀程度并有效降低板件的变形程度。

关键词: 自动钻铆; 数值模拟; 工艺参数优化; BP神经网络(BPNN); 多目标粒子群算法(MOPSO)

Automatic Drilling and Riveting Process Parameter Optimization Method Based on BP Neural Network and Multi-Objective Particle Swarm Optimization Algorithm

LI Chao, WANG Zhongqi, CHANG Zhengping, MA Jianzhi

(Northwestern Polytechnical University, Xi'an 710072, China)

[ABSTRACT] Interference connection is widely used in automatic drilling and riveting of aircraft panel. The coordinated control of the degree of uniformity of interference and panel deformation is an urgent problem to be solved. In this paper, an optimization method based on BP neural network (BPNN) is proposed. Taking the riveting force, riveting process time, riveting retention time and clamping force as variables, and taking the simulation data as samples, the prediction model of interference uniformity and wall deformation was established by using BP neural network. Multi-objective particle swarm optimization (MOPSO) algorithm was used for multi-objective optimization. The simulation and experimental results show that the optimized parameters can significantly improve the uniformity of interference and effectively reduce the deformation degree of plate.

Keywords: Automatic drilling and riveting; Numerical simulation; Process parameter optimization; BP neural network (BPNN); Multi-objective particle swarm optimization (MOPSO) algorithm

DOI: 10.16080/j.issn1671-833x.2021.23/24.094

飞机壁板装配常采用铆接的方式, 其中自动钻铆大量采用干涉连接, 而干涉连接会使孔周围的应力场发生

变化, 干涉量不均匀会造成被连接件的扭曲和弯曲变形, 而飞机装配过程中壁板的外形精度对飞机的飞行性

* 基金项目: 陕西省自然科学基金基础研究计划(2019JQ-032); 航空基金(ASFC-201916053001); 国家自然科学基金(51905443); 博士后面上基金(2020M673325); 民用飞机专项科研(MJ-2017-G-68); 陕西省重点研发计划(2020ZDLGY01-04)。

下表面,同时将上板件上端面完全约束,实现夹紧作用。为简化模型,限制铆钉沉头端的所有自由度,代替顶铁。

1.2 有限元模型验证

工程中常用镦头尺寸(镦头高度、镦头直径)和干涉量作为评定铆接质量的指标^[15]。因此,为检验有限元模型的模拟效果,进行自动钻铆试验,仿真结果如图4所示。分别测量仿真和试验的镦头尺寸和干涉量值进行对比分析,对比结果如表2所示,其中平均干涉量误差为0.019%;镦头直径误差为0.025mm;镦头高度误差为0.039mm。其中,干涉量值为图5所示5个位置的平均值。

从表2可以看出,镦头尺寸和干涉量这两个评价指标的仿真结果与试验结果的误差不超过5%,均在可接受范围内,故该有限元模型可以模拟实际的铆接效果,该模型可以作为后续优化研究的基础模型。

2 BP神经网络预测模型

BP神经网络属于前向反馈网络,结构如图6所示。BP的神经元有 n 个输入,每个输入都通过1个权值 w_i ($i=1,2, \dots, n$)连接到神经元上。输出函数为 $y=f(\alpha, \theta)$, $\alpha=\sum w_i x_i$ 为输入的加权和, θ 是神经元的阈值。神经元模型的输出向量可表示为:

$$y=f(W \cdot X + \theta) = f\left(\sum_{i=1}^n w_i x_i + \theta\right) \quad (1)$$

其中, $W=(w_1, w_2, \dots, w_n)$; $X=(x_1, x_2, \dots, x_n)^T$, x_i 为第 i 个神经元的数值, w_i 为第 i 个神经元的权值。

2.1 样本

输入量的取值范围参考经验取值并进行适当扩展,取值范围见表3。




图4 仿真结果

Fig.4 Simulation results

表2 仿真与试验数据

Table 2 Simulation and test data

检验指标	平均干涉量 /%	镦头直径 /mm	镦头高度 /mm
试验数据	2.803	5.398	1.476
仿真数据	2.784	5.423	1.437




图2 网格划分
Fig.2 Mesh division




图3 载荷及边界条件
Fig.3 Loading and boundary conditions




图5 数据测量位置示意图

Fig.5 Schematic diagram of data measurement position




图6 BP神经网络模型流程图

Fig.6 Flow chart of neural network model

在上述参数范围内,利用 Matlab 中的 rand() 函数随机生成 20 组参数进行仿真,仿真测量关键点见图 7。

表 3 输入参数取值范围
Table 3 Input parameter value range

取值范围	压铆力 A/ N	夹紧力 B/ MPa	压铆过程时间 C/ s	压铆停留时间 D/ s
最小值	12000	3.17	0.075	0.025
最大值	14500	5.18	0.15	0.1




图 7 测量节点位置示意图
Fig.7 Measurement node site

仿真结果见表 4。

2.2 神经网络的建立与验证

将前文 20 组输入、输出数据分别导入 Matlab 中,调用 Randperm 函数将其随机打乱,将打乱后的前 15 组数据作为训练集,后 5 组数据作为测试集。为了缩短其收敛时间,提高训练效率,分别将训练集的输入输出和测试集的输入进行归一化处理至 [0,1] 区间,归一化公式如下:

$$Z = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

输入层与隐含层的激活函数选择 tansig,即 $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ 。隐含层与输出层的激活函数选择 logsig 函数,

即 $F(x) = \frac{1}{1 + e^{-x}}$,隐含层神经元个数设为 3,调用 newff 函数创建网络,调用 train 函数训练网络,训练过程如图 8 所示。

表 4 样本数据
Table 4 Sample data

编号	压铆力 A/N	夹紧力 B/MPa	压铆过程时间 C/s	压铆停留时间 D/s	干涉量的均匀程度 CV	壁板的变形程度 M
1	14037	4.799	0.087	0.033	0.7438	0.030318
2	14265	4.358	0.135	0.097	0.6598	0.035
3	12317	3.874	0.098	0.025	0.695	0.02916
4	14284	4.150	0.115	0.083	0.655	0.03109
5	13581	3.938	0.087	0.086	0.6568	0.03081
6	12243	3.315	0.120	0.090	0.7218	0.03093
7	12696	3.628	0.095	0.0310	0.6989	0.02867
8	13367	3.406	0.124	0.055	0.6965	0.0317
9	14394	3.521	0.127	0.045	0.6647	0.03427
10	14413	3.628	0.131	0.085	0.6699	0.03824
11	12394	3.967	0.109	0.057	0.7157	0.03072
12	14427	3.265	0.081	0.093	0.6351	0.031189
13	14393	4.894	0.092	0.039	0.64998	0.0306
14	13213	4.975	0.144	0.045	0.6878	0.03258
15	14001	4.108	0.086	0.036	0.6541	0.03011
16	12354	4.105	0.137	0.035	0.7001	0.03128
17	13054	3.815	0.115	0.090	0.6432	0.03255
18	14290	4.889	0.150	0.069	0.6534	0.03619
19	13981	3.875	0.081	0.066	0.6416	0.030056
20	14399	3.382	0.108	0.036	0.65199	0.031367

用建立的 net 网络对输入的测试集进行计算,并对其结果进行反归一化,将反归一化的结果与测试集真实的输出值进行误差分析,其结果如图 9 所示,由于测试集测量值与预测结果对比 $R^2=0.97135$,接近于 1,故训练的结果较好。

3 优化

基于仿真得到的样本数据建立 BP 神经网络,通过 Isight 软件集成 Matlab,并利用多目标粒子群优化算法 (Multi-objective particle swarm optimization, MOPSO) 进行优化。优化流程见图 10。

3.1 DOE 试验

进行 DOE (Design of experiment) 试验的目的在于得到更有影响的因素、其影响的大小,以及因素间可能存在的相互关系。为了更好地了解工艺参数对输出变量的影响关系,利用 Isight 软件进行主因素分析和方差分析,结果如图 11 所示,其中蓝色柱形表示该参数值越大则输出量也相应地越大,红色柱形则相反。不难发现,输出变量不单纯依赖某个输入参数(将压铆力、夹紧力、压铆过程时间、压铆停留时间分别由 A 、 B 、 C 、 D 表示;将干涉量均匀程度和壁板的变形程度用 CV 和 $M^{[16]}$ 表示),而且受到 A 、 B 、 C 、 D 的交互影响。参数 D 、 C^2 对 CV 值呈负贡献度,对 M 则相反;参数 $A-D$ 、 A^2 、 B^2 、 $A-B$ 、 $A-C$ 对 CV 值呈负贡献度,对 M 值则相反。因此两个目标同时达到最优是不可能的,只能在它们之间进行折中处理,使两个目标尽可能达到最小。DOE 试验的分析研究为生产实际中优化响应变量提供了最优参数设计的指导性依据,避免了盲目探索的过程。

3.2 优化目标

将压铆力 A 、夹紧力 B 、压铆过程时间 C 、压铆停留时间 D 作为输入量,将干涉量均匀程度 CV 和壁板的变形程度 M 作为输出响应。其中:

$$CV = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(X_i - \frac{1}{N} \sum_{i=1}^N X_i \right)^2} / \left(\frac{1}{N} \sum_{i=1}^N X_i \right) \quad (3)$$

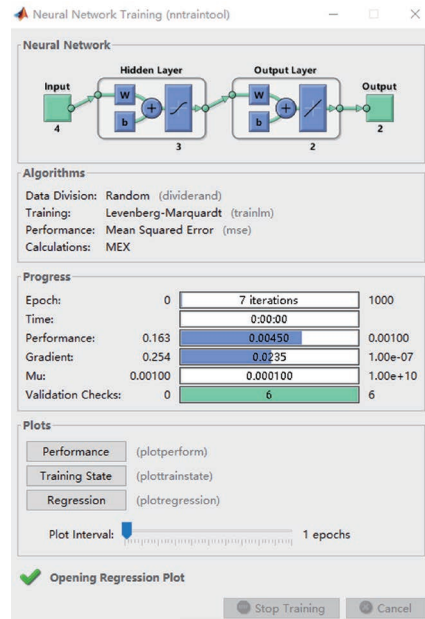
式中, X_i 表示铆钉第 i 个点的膨胀量; N 为铆钉上测量点的总数。 CV 值越小表示干涉量越均匀。

$$M = \sqrt{\sum_{i=1}^N Y_i^2} / N_1 \quad (4)$$

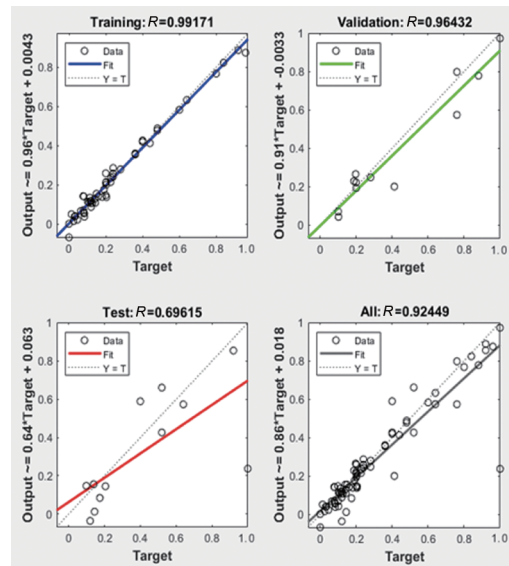
式中, Y_i 为板件第 i 个点的变形量; N_1 为板件上测量点的总数。 M 值越小表示板件的平滑度越好。因此,该优化过程可抽象为数学模型:

$$\text{Min } CV(A, B, C, D)$$

$$\text{Min } M(A, B, C, D)$$



(a) 网络训练过程



(b) 训练结果

图 8 网络训练过程和训练结果

Fig.8 Network training process and training results




图 9 输出值与预测值对比图

Fig.9 Comparison of output value and predicted value

$$\begin{cases} 12000 \leq A \leq 14500 \\ 3.17 \leq B \leq 5.08 \\ 0.075 \leq C \leq 0.15 \\ 0.025 \leq D \leq 0.1 \end{cases} \quad (5)$$

3.3 多目标粒子群优化

多目标粒子群优化算法属于进化算法的一种,具有容易实现、精度高、收敛快等优点,因此本研究利用该算法进行优化求解,算法参数设置为:迭代次数 300;粒子数 20;全局增量 0.9;粒子增量 0.9;惯性因子 0.9;最大速度 0.1;最大失败迭代次数 5;罚函数 0.001;目标终止迭代条件 0.0001。寻优过程如图 12 所示。

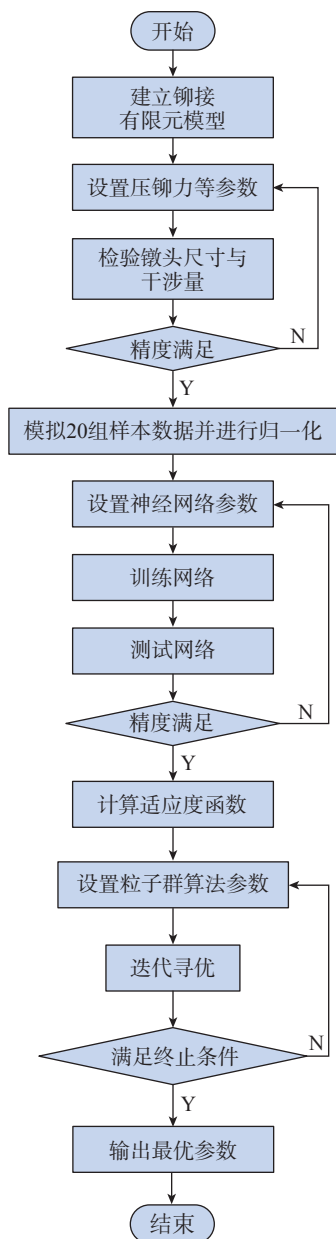




图 10 神经网络-粒子群优化流程

Fig.10 Neural network-particle swarm optimization process




(a) 钉孔膨胀量




(b) 板件变形值

图 11 输入参数对响应变量的影响

Fig.11 Influence of input parameters on response variables



(a) CV寻优过程



(b) M寻优过程

图 12 寻优过程

Fig.12 Optimization process

4 试验验证

基于 GEMCOR G86 型自动钻铆设备,分别选取优化前的与优化后的参数进行试验,为减小误差,每组参数下进行 5 次压铆试验。铆钉选用沉头式铆钉,试件尺寸参数为:铆钉直径 3.5mm;铆钉长度 7mm;铆接孔直径 3.6mm;上板厚度 1.5mm;下板厚度 1.2mm;沉头高度 1mm;沉头角度 100°。图 13 和 14 分别为试验所用的铆钉和线切割设备,试验结果如图 15 所示。

采用手持式三维激光扫描仪进行铆接变形的测量,测量工具与靶点如图 16 所示。分别对铆接前和铆接后的被连接件进行扫描,借助 Geomagic 软件对

两次扫描的点云数据进行降噪、过滤处理并封装生成曲面,将两个曲面配准并进行偏差分析从而得到变形量。

基准模型与优化后的结果对比见表 5,测量数据见表 6 和 7。结果表明,优化参数下的 CV 和 M 值均比基准模型小,即该优化方法得到的参数组合其铆接的干涉量均匀程度和壁板的变形程度均有所改善,优化结果有效。

5 结论

(1)建立了一套“仿真样本-预测模型-算法优化”的多目标优化方法,为自动钻铆工艺参数优化提供了一





图 13 沉头式铆钉
Fig.13 Countersunk head rivet



图 14 线切割设备
Fig.14 Wire cutting equipment




(a) 铆接结果 (b) 测量过程



(c) 切割后的试件

图 15 试验结果
Fig.15 Experimental results



(a) 测量工具 (b) 靶点位置示意图

图 16 测量工具与靶点
Fig.16 Measuring tools and targets

表 5 基准模型与优化结果对比

Table 5 Comparison of baseline model and optimization results

模型对比	压铆力 A/N	夹紧力 B/MPa	压铆过程时间 C/s	压铆停留时间 D/s	干涉量的均匀程度 CV	壁板的变形程度 M
基准模型	14037	4.799	0.087	0.033	0.7438	0.03032
优化模型	14463	4.746	0.143	0.026	0.6584	0.02576

表 6 基准模型测量数据
Table 6 Measured data of benchmark model

基准模型	第 1 组	第 2 组	第 3 组	第 4 组	第 5 组
X_1	0.01	0.02	0.01	0.01	0.01
X_2	0.02	0.03	0.02	0.02	0.02
X_3	0.07	0.08	0.13	0.09	0.14
X_4	0.11	0.17	0.19	0.16	0.17
X_5	0.15	0.19	0.22	0.18	0.23
CV	0.732	0.717	0.754	0.757	0.754
Y_1	0.471	0.0458	0.0445	0.0497	0.0461
Y_2	0.288	0.0294	0.0291	0.0305	0.0294
Y_3	0.282	0.0232	0.0333	0.0234	0.0213
Y_4	0.234	0.0231	0.0237	0.0193	0.0235
Y_5	0.171	0.0194	0.0192	0.0182	0.0196
M	0.0306	0.0297	0.0312	0.0305	0.0296

表 7 优化模型测量数据
Table 7 Measurement data of optimization model

优化模型	第 1 组	第 2 组	第 3 组	第 4 组	第 5 组
X_1	0.01	0.01	0.01	0.02	0.02
X_2	0.07	0.06	0.08	0.09	0.07
X_3	0.10	0.09	0.12	0.09	0.08
X_4	0.12	0.16	0.13	0.16	0.20
X_5	0.23	0.19	0.25	0.25	0.22
CV	0.682	0.643	0.664	0.638	0.665
Y_1	0.387	0.0373	0.0455	0.0472	0.0439
Y_2	0.311	0.0288	0.0293	0.0276	0.0299
Y_3	0.164	0.0177	0.0171	0.0178	0.0167
Y_4	0.145	0.0140	0.0146	0.0146	0.0148
Y_5	0.115	0.0112	0.0122	0.0122	0.0117
M	0.0248	0.0239	0.0267	0.0271	0.0263

种新思路。

(2) 基于铆接仿真模型得到的样本数据构建并验证了 BP 神经网络预测模型, 预测值与真实值的误差为 0.97135, 说明了神经网络预测模型的有效性。

(3) 采用多目标粒子群算法对干涉量均匀程度和壁板的变形程度进行了优化, 并通过试验验证了优化结果的有效性。

参考文献

[1] 王仲奇, 张津铭, 常正平, 等. 壁板铆接变形分析及铆接顺序规划研究 [J]. 航空制造技术, 2017, 60(22): 16–23.

WANG Zhongqi, ZHANG Jinming, CHANG Zhengping, et al. Research on deformation analysis and sequence planning of aircraft panel in riveting process[J]. Aeronautical Manufacturing Technology, 2017, 60(22): 16–23.

[2] 张开富, 杨殿国, 李原, 等. 壁板自动钻铆行为及变形分析技术综述 [J]. 航空制造技术, 2010, 53(23): 67–72.

ZHANG Kaifu, YANG Dianguo, LI Yuan, et al. Deformation analysis and application of automatic riveting for wing panel[J]. Aeronautical Manufacturing Technology, 2010, 53(23): 67–72.

[3] HOSSEIN C S, KRISHNAN K, BAJRACHARYA B. Effect of variations in the riveting process on the quality of riveted joints[J]. The International Journal of Advanced Manufacturing Technology, 2008, 39(11–12): 1156–1156.

[4] 张洪双. 铆接工艺参数分析 [J]. 机械设计与制造, 2011(6): 241–243.

ZHANG Hongshuang. Analysis on riveting process parameters[J]. Machinery Design & Manufacture, 2011(6): 241–243.

[5] AMAN F, CHERAGHI S H, KRISHNAN K K, et al. Study of the impact of riveting sequence, rivet pitch, and gap between sheets on the quality of riveted lap joints using finite element method[J]. The International Journal of Advanced Manufacturing Technology, 2013, 67(1): 545–562.

[6] 刘连喜, 李西宁, 王仲奇, 等. 无头铆钉自动钻铆工艺试验研究 [J]. 西北工业大学学报, 2013, 31(1): 77–82.

LIU Lianxi, LI Xining, WANG Zhongqi, et al. Semi-empirical research on automatic drilling and riveting process of headless rivet[J]. Journal of Northwestern Polytechnical University, 2013, 31(1): 77–82.

[7] 王端义. 响应曲面法优化钢铝异种材料自冲铆接工艺参数的研究 [J]. 锻压技术, 2019, 44(12): 65–69, 76.

WANG Duanyi. Research on optimization of process parameters for self-piercing riveting of steel-aluminium dissimilar materials based on response surface method[J]. Forging & Stamping Technology, 2019, 44(12): 65–69, 76.

[8] 张兆元, 石柏军, 钟佳彬. 铝合金汽车车身半空心自冲铆接接头参数匹配优化研究 [J]. 机械设计与制造工程, 2019, 48(3): 64–68.

ZHANG Zhaoyuan, SHI Baijun, ZHONG Jiabin. The parameter matching optimization of self-pierce riveted joints for aluminum alloy

automobile body[J]. Machine Design and Manufacturing Engineering, 2019, 48(3): 64–68.

[9] 陈建英, 张建仁. 神经网络与响应面法相结合分析 [J]. 长沙理工大学学报 (自然科学版), 2004, 1(3): 13–17, 22.

CHEN Jianying, ZHANG Jianren. The reliability assessment of existing bridge based on neural network and response surface method[J]. Journal of Changsha University of Science and Technology (Natural Science), 2004, 1(3): 13–17, 22.

[10] 鲁墨武, 殷思羽, 姜春英, 等. 飞机蒙皮锤铆参数优化方法研究 [J]. 机械工程与自动化, 2020(2): 19–21.

LU Mowu, YIN Siyu, JIANG Chunying, et al. Parameters optimization method research on aircraft skin hammer riveting[J]. Mechanical Engineering & Automation, 2020(2): 19–21.

[11] 于立明, 李启明. 基于最小二乘法的飞机蒙皮波纹度处理方法研究 [J]. 科技信息, 2012(28): 424–427.

YU Liming, LI Qiming. Research on the treatment method of aircraft skin waviness based on least square method[J]. Science & Technology Information, 2012(28): 424–427.

[12] 张铁纯, 田璐, 邓云飞, 等. 2A12 铝合金薄板抗叶片形弹体撞击的数值仿真研究 [J]. 机械强度, 2019, 41(3): 734–738.

ZHANG Tiechun, TIAN Lu, DENG Yunfei, et al. Numerical simulation study on the impact resistance of aluminum alloy sheet against vane shaped projectile[J]. Journal of Mechanical Strength, 2019, 41(3): 734–738.

[13] 李艳, 于克杰, 李小雷. 铆钉材料对铆接变形影响的有限元分析 [J]. 机床与液压, 2013, 41(4): 50–52.

LI Yan, YU Kejie, LI Xiaolei. Finite element analysis for the influence of rivet materials on rivet deformation[J]. Machine Tool & Hydraulics, 2013, 41(4): 50–52.

[14] 常正平, 王仲奇, 李诚, 等. 飞机薄壁件铆接过程变形分析与数值模拟 [J]. 航空制造技术, 2016, 59(7): 82–86, 90.

CHANG Zhengping, WANG Zhongqi, LI Cheng, et al. Deformation analysis and numerical simulation of riveting process for aircraft thin-walled parts[J]. Aeronautical Manufacturing Technology, 2016, 59(7): 82–86, 90.

[15] RIJCK M D, HOMAN J J, SCHIJVE J, et al. The driven rivet head dimensions as an indication of the fatigue performance of aircraft lap joints[J]. International Journal of Fatigue, 2007, 29(12): 2208–2218.

[16] 常正平. 壁板铆接变形分析及铆接顺序规划研究 [D]. 西安: 西北工业大学, 2018.

CHANG Zhengping. Research on deformation analysis and sequence planning of aircraft panel in riveting process[D]. Xi'an: Northwestern Polytechnical University, 2018.

通讯作者: 王仲奇, 教授, 研究方向为飞机数字化装配工艺技术与装备、智能制造技术、树脂基碳纤维增强复合材料增强增韧及自愈技术。

(责编 七七)