

基于组合模型的 MAG 焊工艺参数多目标优化

吕小青^{1,2}, 王旭¹, 徐连勇^{1,2}, 荆洪阳^{1,2}, 韩永典^{1,2}

(1. 天津大学, 天津, 300072; 2. 天津市现代连接技术重点实验室, 天津, 300072)

摘要: 以 MAG 焊焊接电压、焊接速度、送丝速度为可调工艺参数, 开展了三因素三水平全因子平板对接焊和堆焊试验。基于试验数据建立了误差反向传播神经网络、径向基神经网络和克里金模型来预测焊缝余高、接头抗拉强度和冲击吸收能量。模型预测结果显示, 所建立模型均能较好的预测焊缝性能, 但是没有一个模型能同时最佳预测三种焊缝性能且各模型预测波动较大。为了进一步提升预测精度和稳定性, 将误差反向传播神经网络、径向基神经网络和克里金模型以线性加权法组合。结果表明, 组合模型能提升预测的精度和稳定性。基于组合模型, 采用 NSGA-II 算法实现多目标优化, 得到并验证了焊缝余高、接头冲击吸收能量和抗拉强度三者间的非劣解。验证结果表明焊接工艺多目标优化对实现焊缝综合性能整体最优以及焊接精细化应用具有较大的指导意义。

关键词: 多目标优化; 焊接工艺; 组合模型; 神经网络; 克里金模型

中图分类号: TG444 文献标识码: A doi: 10.12073/j.hjxb.20190629001

0 序言

熔化极活性混合气体保护焊 (metal active gas arc welding, 简称 MAG 焊) 是一种高效、低成本的焊接技术, 被广泛应用于汽车、航天、造船和建筑等领域^[1-2]。随着科技的发展, 工业对焊接质量的要求越来越高^[3]。本质上, 主要体现在两个方面, 其一, 调节焊接工艺, 使得焊缝综合性能 (如抗拉强度、冲击强度等) 最优; 其二, 针对不同的应用场合, 调节工艺使得焊缝整体合格的基础上, 某种物理性能 (如冲击强度等) 最优, 即更加精细化的应用。前者, 实际就是一个多目标优化的问题, 即焊缝多个物理特性整体上达到最优; 后者, 在多目标优化过程中, 可以通过选择不同的非劣解来达到应用要求。故焊接工艺的多目标优化具有较大的实际应用价值和发展前景。

文中把焊接电压、送丝速度和焊接速度作为主要工艺调整参数, 以焊缝余高、接头抗拉强度和冲击吸收能量作为目标优化参量, 来探索相关的普适性规律。显然, 掌握焊缝物理参量同焊接工艺参数内在联系是研究多目标优化必备基础。目前, 为了节约人力和物力, 在探究焊缝物理参量同焊接工艺参数的联系时往往采用数学建模的方法。常用的方法有建

立焊缝物理参量同工艺参数的多项式方程、神经网络、克里金插值模型等等^[4-7]。但是每种方法各有特点, 不同的焊缝物理参量所对应的方法往往不同。故而, 提出采用一种组合模型方式, 把建立物理参量同焊接工艺参数内在联系的各种方法有效结合到一起, 进而提高预测的精确性和稳定性。

1 试验方法

1.1 试验材料

试验选用 Q235 作为母材, 钢板尺寸为 200 mm × 100 mm × 10 mm。根据母材成分和等强匹配原则, 选择焊丝型号为 ER50-6 的 φ1.2 mm 实芯焊丝, 保护气体成分为 82%Ar + 18%CO₂。

1.2 试验设备

试验中, 焊接机器人选用 FANUC Robot M-10iA, 焊机为 Fronius CMT Advanced 4000。喷嘴到平板距离固定为 15 mm, 保护气送气速度固定为 15 L/min。采用体式显微镜测量焊缝余高。采用 DDL300 拉伸试验机测量平板对接接头抗拉强度。采用型号为 JBS0300B 冲击试验机采集接头冲击吸收能量数据。依据国标 GB/T 2651 和 GB/T 2650 设计拉伸试样和冲击试样尺寸。由于冲击试样尺寸固定, 因此文中采用冲击吸收能量代表冲击强度。MAG 焊焊接过程和试样示意图见图 1。

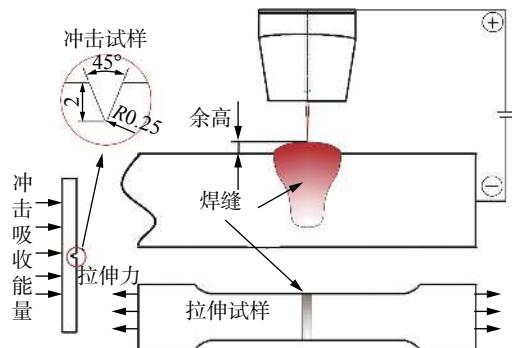


图 1 MAG 焊焊接过程示意图

Fig. 1 Schematic of MAG welding procedure

1.3 试验设计

试验中可调焊接工艺参数为焊接电压(U)、焊接速度(v)和送丝速度(v_s)，其余MAG焊接工艺参数恒定。焊接电压、焊接速度和送丝速度调整范围

采用试错法确定，范围如下： $25 \leq U \leq 32$ V； $5 \text{ mm/s} \leq v \leq 11 \text{ mm/s}$ ； $7 \text{ m/min} \leq v_s \leq 11 \text{ m/min}$ 。在该范围内，焊接工艺参数组合不存在明显焊接缺陷。设计三因素三水平全因子试验，工艺参数水平如表1所示。此外，在参数范围内，随机增设3组参数组合。30组试验数据见表2。

表 1 MAG 焊参数范围

Table 1 MAG welding parameter range

水平	焊接速度 $v/(\text{mm}\cdot\text{s}^{-1})$	焊接电压 U/V	送丝速度 $v_s/(\text{m}\cdot\text{min}^{-1})$
水平1	5	25	7
水平2	8	28.5	9
水平3	11	32	11

表 2 试验设计矩阵及结果

Table 2 Test design matrix and results

序号	工艺参数			试验结果			序号	工艺参数			试验结果		
	焊接速度 $v/(\text{mm}\cdot\text{s}^{-1})$	焊接电压 U/V	送丝速度 $v_s/(\text{m}\cdot\text{min}^{-1})$	冲击吸收 能量 A_{kV}/J	抗拉强度 R_m/MPa	焊缝余高 H/mm		焊接速度 $v/(\text{mm}\cdot\text{s}^{-1})$	焊接电压 U/V	送丝速度 $v_s/(\text{m}\cdot\text{min}^{-1})$	冲击吸收 能量 A_{kV}/J	抗拉强度 R_m/MPa	焊缝余高 H/mm
1	5	25.0	7	88.66	431.49	3.55	16	11	25.0	9	86.11	452.28	2.75
2	5	28.5	9	74.08	429.91	3.63	17	11	28.5	9	98.97	459.31	2.93
3	5	32.0	11	42.89	376.20	3.28	18	11	32.0	7	85.68	458.53	2.13
4	8	25.0	9	71.47	471.88	2.92	19	8	25.0	11	85.63	470.46	3.95
5	8	28.5	11	60.10	462.44	3.56	20	8	32.0	11	56.83	453.20	3.35
6	8	32.0	7	91.82	436.26	2.45	21	6	30.0	7	77.08	447.95	2.94
7	11	25.0	11	78.74	458.08	3.64	22	9	27.0	10	79.86	452.80	2.92
8	11	28.5	7	86.03	463.42	2.42	23	5	28.5	7	78.73	398.31	3.02
9	11	32.0	9	90.18	463.78	2.70	24	11	28.5	11	87.56	443.06	3.23
10	5	28.5	11	77.07	444.48	3.65	25	11	32.0	11	80.78	460.70	2.84
11	5	32.0	7	73.53	451.00	2.93	26	10	29.0	11	73.35	453.66	3.19
12	5	32.0	9	41.05	390.48	3.18	27	5	25.0	9	76.14	394.26	4.02
13	11	25.0	7	102.43	451.30	2.64	28	8	25.0	7	82.06	470.95	2.74
14	8	32.0	9	65.07	433.15	3.12	29	8	28.5	7	95.11	469.41	2.84
15	5	25.0	11	61.67	456.63	4.17	30	8	28.5	9	64.02	468.25	3.09

2 预测模型建立

2.1 独立模型建立

误差反向传播神经网络(BP神经网络)是一种前馈神经网络，在网络中有效信息向前传递，而输出与期望之间的误差则反向传递。因其良好的拟合近似能力，BP神经网络被大量地应用于建立焊接

工艺与焊缝质量间的联系^[8]。网络结构包含输入层、隐含层和输出层，如图2所示。径向基神经网络(RBF神经网络)与BP神经网络相比，是一种结构更简单、收敛速度更快、能够逼近任意非线性函数的网络。因此近年也有学者开始应用其来建立焊接工艺参数与焊接结果之间的非线性关系^[9]。克里金插值法是一种空间插值法，其通过对预测点周围

的测量值进行加权以得出预测值, 权重则取决于测量点与预测点之间的距离和预测位置周围的测量值之间的空间关系。克里金法最初用于辅助地质学家估算矿含量, 但是由于其出色的拟合近似能力, 最近也开始被逐渐应用在焊接领域^[10]。

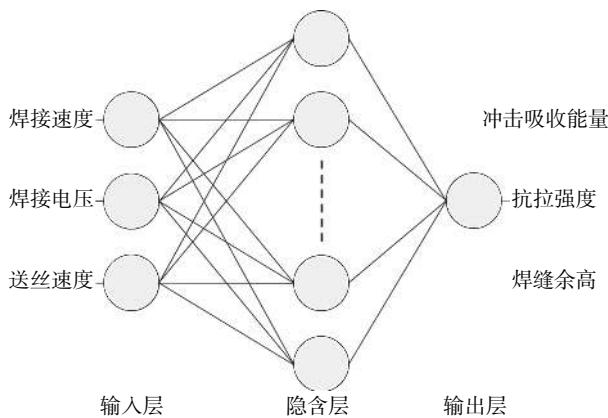


图 2 BP 神经网络结构
Fig. 2 Structure of BP neural network

将前 25 组试验数据作为训练数据, 建立 BP 神经网络、RBF 神经网络和克里金模型。经验公式计算 BP 神经网络隐含层节点数范围为 1~12, 然后采用数值试验测量不同隐含层神经元数量下 100 次建模的平均预测误差, 确定预测接头抗拉强度、冲击吸收能量和焊缝余高隐含层节点数分别为 1, 2 和 1。采用数值试验确定 RBF 神经网络预测冲击吸收能量、抗拉强度和余高的扩散速率分别为

1.55, 0.9 和 1.55。

2.2 组合模型建立

将表 2 中后 5 组数据作为测试数据, 测试模型预测能力。BP 神经网络、RBF 神经网络和克里金模型预测接头抗拉强度、冲击吸收能量和焊缝余高的相对误差如表 3 所示。可以观察到, 3 个独立模型对抗拉强度、冲击吸收能量和余高的平均预测误差均小于 10.1, 因此 3 个独立模型设置合适的建模参数后均可实现较好的预测。但是在 3 个独立模型中, 没有一个模型可以同时最优预测三种焊接结果。例如, RBF 神经网络对冲击吸收能量和余高的平均预测误差最小(分别为 8.6% 和 4.3%), 但其对抗拉强度的平均预测误差为 5.04%, 大于克里金模型对抗拉强度的平均预测误差, 因此 RBF 神经网络并不是预测抗拉强度最好的模型。同时, 克里金模型虽然对抗拉强度的预测效果最好, 平均预测误差为 4.4%, 但是其对冲击吸收能量和余高的预测效果却并不理想(分别为 10.1% 和 7.6%)。此外, 每个模型的预测效果并不能一直保持稳定。例如, BP 神经网络对冲击吸收能量的预测, 最大相对误差达到 21.2%, 5 组测试试验相对误差的标准差为 6.86。这种预测效果的波动将导致预测值与试验值存在较大的偏差。因此, 提出建立基于 3 个独立模型的组合模型, 利用各模型的优点来提高对焊缝质量预测的精度和稳定性。组合模型建立过程如下。

表 3 各模型预测结果
Table 3 Predicted results of each model

序号	BP 神经网络误差 δ_1 (%)			RBF 神经网络误差 δ_2 (%)			克里金模型误差 δ_3 (%)			组合模型误差 δ_4 (%)		
	冲击吸收能量	抗拉强度	余高	冲击吸收能量	抗拉强度	余高	冲击吸收能量	抗拉强度	余高	冲击吸收能量	抗拉强度	余高
26	3.3	1.3	3.1	8.9	0.1	2.0	14.1	1.2	7.3	7.7	1.1	1.05
27	3.7	14.5	7.1	1.3	14.8	13.0	2.0	11.9	12.7	1.34	11.0	9.53
28	13.3	2.5	10.2	1.7	3.7	3.6	13.7	1.8	10.1	2.1	1.9	7.51
29	6.1	4.7	2.7	12.6	3.5	1.3	18.8	4.1	1.1	10.8	4.2	1.07
30	21.2	2.2	1.6	18.5	3.2	1.8	2.2	3.2	6.8	12.3	3.2	1.71
最大误差	21.2	14.5	10.2	18.5	14.8	13.0	18.8	11.9	12.7	12.3	11.0	9.53
平均误差	9.5	5.0	4.9	8.6	5.0	4.3	10.1	4.4	7.6	6.9	4.3	4.17
标准差	6.86	4.83	3.22	6.54	5.03	4.39	6.84	3.86	3.89	4.44	3.52	3.61

(1) 加权组合各模型。为了利用 3 个模型各自的优点来提升预测精度和稳定性, 可以采用设置权值将 3 个独立模型组合起来的方式, 即

$$\hat{f}_{EM}(x) = \sum_{i=1}^3 \omega_i \hat{f}_i(x), \quad (1)$$

式中: \hat{f}_{EM} 代表组合模型; $\hat{f}_i(i=1, 2, 3)$ 分别代表 BP

神经网络、RBF 神经网络和克里金模型; $\omega_i (i=1, 2, 3)$ 分别代表 3 个独立模型对应的权值。

(2) 求解各模型的权值。为保证组合模型预测值稳定, 独立模型的权值之和应为 1, 并应使组合模型的预测误差最小, 预测误差通过均方误差表示。权值求解问题如下

$$\begin{cases} \text{Find } \omega_i \\ \text{Min } \text{MSE} = \sum_{j=1}^m (\hat{f}_{EM,j}(x_j) - \hat{f}(x_j))^2 / m \\ \text{S.T. } \sum_{i=1}^3 \omega_i = 1 \end{cases} \quad (2)$$

式中: MSE 是预测值和试验值的均方误差; $\hat{f}_{EM,j}(x_j)$ 是组合模型对第 j 个焊接结果的预测值; $\hat{f}(x_j)$ 是第 j 个焊接结果的试验值; m 为测试试验组数。由于独立模型中存在神经网络等映射模型, 因此采用遗传算法求解各模型的权值, 各独立模型权值如表 4 所示。

表 4 独立预测模型权值

Table 4 Weights of stand-alone prediction model

优化目标	BP网络	RBF网络	克里金模型
冲击吸收能量	0.588	0	0.412
抗拉强度	0.071	0	0.929
余高	0.582	0.407	0.012

2.3 模型分析与验证

组合模型预测结果如表 3 所示。显然, 组合模型与 3 个常用模型相比, 对冲击吸收能量、抗拉强度和余高预测的最大相对误差从 21.2%, 18.8%

和 13.0% 显著降低至 12.3%, 11.0% 和 9.53%。组合模型对冲击吸收能量、抗拉强度和余高的平均相对误差分别为 6.9%、4.3% 和 4.17%, 明显优于三种独立模型中的最小平均相对误差(分别为 8.6%、4.4% 和 4.3%)。同时, 组合模型预测冲击功和抗拉强度的标准差为 4.44 和 3.52, 低于三种独立模型中的最小值 6.54 和 3.86。组合模型预测余高的标准差为 3.61, 仅次于最好的 BP 神经网络(3.22)。因此, 组合模型与常用的独立模型相比, 不仅能通过设置最优的权值来提升预测精度, 而且可以利用不同模型的优点, 使对每次试验的预测效果更加稳定, 降低预测效果大幅度波动的可能。

3 多目标优化

3.1 多目标优化模型建立

实现冲击吸收能量和抗拉强度最大、余高最小的焊接工艺优化是一个典型的多目标任务。在此采用的 NSGA-II 算法是多目标遗传算法中的一种。相比于传统的多目标算法, 如加权求合法、约束法和最大-最小法, NSGA-II 不需要将多个目标转化为一个目标问题。通过 NSGA-II 来实现 MAG 焊工艺参数多目标优化, 可以得到 3 个优化目标间的折中解, 这些解也称为非劣解, 即不存在 3 个目标上都优于这些解的其它解。由非劣解组成的曲面称为帕累托最优曲面。NSGA-II 的相关参数设置如表 5 所示。冲击吸收能量、抗拉强度和余高的适应度函数由组合模型充当。

表 5 NSGA-II 相关参数

Table 5 Related parameters of NSGA-II

种群规模	最大迭代次数	非劣解显示比例	函数容差	交叉比例	精英数
100	200	0.6	10×10^{-6}	0.8	2

3.2 多目标优化结果分析及验证

图 3 为 60 个非劣解所形成的帕累托最优曲面。由图可知, 帕累托最优曲面是倾斜的, 因为不存在使 3 个目标同时都达到最优的非劣解。如冲击吸收能量最大值为 97.81 J, 但该点对应的抗拉强度和余高分别为 452.99 MPa 和 2.68 mm, 明显劣于最优的抗拉强度和余高(471.7 MPa 和 2.22 mm)。

而当抗拉强度达到最大值(471.7 MPa)时, 该非劣解对应的冲击吸收能量和余高分别为 81.32 J 和 3.46 mm。因此, 冲击吸收能量的最优是以抗拉强度和余高的劣化为代价的, 而抗拉强度的最优同样以另外两个指标降低为代价。在此, 可以在非劣解中选择合适的焊接工艺参数来满足不同工程应用的需要。例如对于有低温脆性的承重

接头, 可以选择冲击吸收能量和抗拉强度较高而余高略大的焊接工艺参数. 而对焊接结构变形和残余应力要求较高的场合, 可以选择焊缝余高偏小的工艺参数.

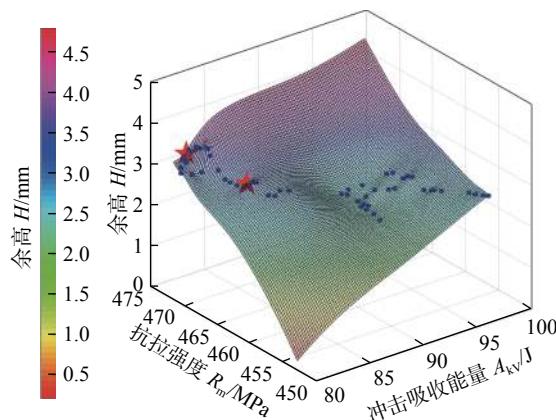


图 3 帕累托最优曲面
Fig. 3 Pareto optimal surface

选择帕累托最优曲面上的两个非劣解(图 3 中红色五角星)来验证优化方法及组合模型的有效性, 验证参数如表 6 所示, 结果如表 7 所示. RBF 网络金模型的平均相对误差分别为 7.0% 和

7.9%, 而 BP 网络和组合模型分别为 4.1% 和 4.1%, 因此 BP 网络和组合模型的预测精度更高. 虽然 BP 网络的平均相对误差与组合模型相近, 但组合模型预测的标准差为 1.66, 远小于 BP 网络的标准差 (5.68), 因此组合模型具有更好的预测稳定性. 同时可以观察到, 尽管在第一组验证试验中, BP 网络具有良好的预测精度(对冲击吸收能量、抗拉强度和余高的相对误差分别为 0.3%, 0.8% 和 0.9%), 与表 3 中第 26 组测试试验相似(对冲击吸收能量、抗拉强度和余高的相对误差分别是 3.3%, 1.3% 和 3.1%). 但是, 在第 2 组验证试验中最大的预测相对误差高达 14.5%, 这揭示了 BP 网络预测效果的不稳定性. 以上分析进一步证明, 组合模型可以提高预测结果的准确性和稳定性.

表 6 验证工艺参数

Table 6 Verification of process parameters

序号	焊接速度 $v/(mm \cdot s^{-1})$	焊接电压 U/V	送丝速度 $v_s/(m \cdot min^{-1})$
1	8.1	25.05	9.73
2	8.97	25.22	8.61

表 7 验证试验结果
Table 7 Validation test

序号	焊接结果	试验值	BP神经网络	误差	RBF网络	误差	克里金模型	误差	组合模型	误差
1	冲击吸收能量 A_{kV}/J	84.96	84.72	0.3%	75.46	11.2%	76.34	10.2%	81.25	4.4%
	抗拉强度 R_m/MPa	456.11	459.68	0.8%	468.69	2.8%	472.93	3.7%	471.69	3.4%
	余高 H/mm	3.52	3.55	0.9%	3.32	5.7%	3.29	6.5%	3.45	2.0%
2	冲击吸收能量 A_{kV}/J	78.66	90.06	14.5%	76.37	2.9%	74.33	5.5%	83.55	6.2%
	抗拉强度 R_m/MPa	453.85	459.68	1.3%	459.91	1.3%	467.04	2.9%	466.22	2.7%
	余高 H/mm	3.35	3.11	7.2%	2.74	18.2%	2.73	18.5%	3.16	5.7%
平均误差		—	—	4.1%	—	7.0%	—	7.9%	—	4.1%
标准差		—	—	5.68	—	6.48	—	5.79	—	1.66

4 结论

(1) 建立 BP 神经网络、RBF 神经网络和克里金模型, 实现接头冲击吸收能量、抗拉强度和焊缝余高的预测. 通过设置合适的建模参数, 3 个独立预测模型平均预测误差最大为 10.1%.

(2) 通过线性加权方式建立基于 3 个独立模型的组合模型. 组合模型与独立模型相比, 提升了预测的精度和稳定性.

(3) NSGA-II 算法可以实现焊接工艺参数的多目标优化并得到非劣解, 从这些非劣解中选择合适的参数可以满足工程实际需要.

参考文献

- [1] 范成磊,姚庆泰,谢伟峰,等.超声-MAG复合焊接的熔滴过渡行为[J].*焊接学报*,2017,38(11):11–15.
Fan Chenglei, Yao Qingtai, Xie Weifeng, et al. Characteristics of droplet transfer during ultrasound-MAG hybrid welding[J]. Transactions of the China Welding Institution, 2017, 38(11): 11–15.
- [2] Kamble A G, Rao R V. Experimental investigation on the effects of process parameters of GMAW and transient thermal analysis of AISI321 steel[J]. *Advances in Manufacturing*, 2013, 1(4): 362–377.
- [3] Eusebio J M, Jose A E, Valentin M, et al. Optimization of geometric parameters in a welded joint through response surface methodology[J]. *Construction and Building Materials*, 2017, 154: 105–114.
- [4] Choudhary A, Kumar M, Unune D R. Parametric modeling and optimization of novel water-cooled advanced submerged arc welding process[J]. *The International Journal of Advanced Manufacturing Technology*, 2018, 97: 927–938.
- [5] 赵大伟,康与云,易荣涛,等.基于试验设计与统计分析的双相钢激光焊工艺优化[J].*焊接学报*,2018,39(1):65–69.
Zhao Dawei, Kang Yuyun, Yi Rongtao, et al. Research on process parameters optimization of laser welding for dual phase steel DP600[J]. Transactions of the China Welding Institution, 2018, 39(1): 65–69.
- [6] 杨亚超,全惠敏,邓林峰,等.基于神经网络的焊机参数预测方法[J].*焊接学报*,2018,39(1):32–36.
Yang Yachao, Quan Huimin, Deng Linfeng, et al. Prediction method of welding machine parameters based on neural network[J]. Transactions of the China Welding Institution, 2018, 39(1): 32–36.
- [7] Vimal K E K, Vinodh S, Raja A. Optimization of process parameters of SMAW process using NN-FGRA from the sustainability view point[J]. *Journal of Intelligent Manufacturing*, 2017, 28(6): 1459–1480.
- [8] Palanivel R, Dinaharan I, Laubscher R F. Application of an artificial neural network model to predict the ultimate tensile strength of friction-welded titanium tubes[J]. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 2019, 41: 111.
- [9] Ahmed A N, Noor C W M, Allawi M F, et al. RBFNN-based model for prediction of weld bead geometry in shielded metal arc welding (SMAW)[J]. *Neural Computing and Applications*, 2018, 29(3): 889–899.
- [10] Bayo E, Gracia J. Stiffness modelling of 2D welded joints using metamodels based on mode shapes[J]. *Journal of Constructional Steel Research*, 2019, 156: 242–251.

第一作者简介:吕小青,1978年出生,博士,副教授;主要从事焊接电弧机理、弧焊混沌理论、焊接电信号分析、逆变电源、焊接过程自动化科研和教学工作;发表论文20余篇;Email:xiaoqinglv@tju.edu.cn.

通信作者简介:徐连勇,博士,教授,博士研究生导师. Email:xulianyong@tju.edu.cn.

(编辑: 杨婉春)