

# 基于 PSO-SVM 的点焊接头拉剪强度分类分析

吴刚<sup>1,2</sup>, 陈天<sup>2</sup>, 余靓辉<sup>2</sup>, 柳志鹏<sup>2</sup>

(1. 三峡大学, 水电机械设备设计与维护湖北省重点实验室, 宜昌, 443002; 2. 三峡大学, 机械与动力学院, 宜昌, 443002)

**摘要:** 点焊是汽车零部件的主要连接方式之一, 点焊接头的拉剪强度是评价点焊质量的重要因素, 论文在制备大量点焊试样的基础上, 对各试样的焊点进行超声信号检测, 并运用信号处理获得时域、频域和小波包特征值, 随后对点焊试样在拉剪试验中的失效形式进行分析, 建立点焊接头拉剪强度的分级标准。根据试验数据设计了 BP(back-propagation) 神经网络和基于粒子群优化支持向量机 (particle swarm optimization support vector machine, PSO-SVM) 的神经网络分类器, 最后将试样的超声信号特征值作为输入参数, 比较两种神经网络模型对点焊试样拉剪强度分类的准确率。试验结果表明, 结合 9 个超声信号特征值的 PSO-SVM 神经网络具有最高的点焊强度分类准确率。

- 创新点:** (1) 构建点焊接头拉剪强度的分级标准。  
(2) 建立基于 PSO-SVM 的点焊接头拉剪强度分类模型。  
(3) 明确 PSO-SVM 能提高点焊强度分类的精度。

**关键词:** 点焊; 超声检测; 拉剪强度; BP 神经网络; PSO-SVM

中图分类号: TG 453.9 文献标识码: A doi: 10.12073/j.hjxb.20230820001

## Study on classification of tensile shear strength of spot welding joints based on PSO-SVM

WU Gang<sup>1,2</sup>, CHEN Tian<sup>2</sup>, YU Lianghui<sup>2</sup>, LIU Zhipeng<sup>2</sup>

(1. Hubei Key Laboratory of Hydroelectric Machinery Design & Maintenance, China Three Gorges University, Yichang, 443002, China; 2. College of Mechanical and Power Engineering, China Three Gorges University, Yichang, 443002, China)

**Abstract:** Spot welding is one of the main connection methods of automobile parts, and the tensile shear strength of spot welded joints is the most important factor to evaluate the quality of spot welding. In this paper, based on the preparation of a large number of spot welding samples, ultrasonic signal detection is carried out on the spot welding points of each sample, and the time-domain, frequency-domain and wavelet packet eigenvalues are obtained by using signal processing methods. Then, by analyzing the failure form of spot welding specimen in tension shear test, the grading standard of tensile shear strength of spot welding joint is established. BP neural network and neural network classifier based on PSO-SVM are designed according to the test data. Finally, the ultrasonic signal eigenvalue of the sample is used as the input parameter to compare the accuracy of the two neural network models for the classification of tensile shear strength of spot welding samples. The experimental results show that PSO-SVM neural network combined with 9 ultrasonic signal eigenvalues has the highest accuracy of spot welding strength classification.

- Highlights:** (1) A grading standard for the tensile shear strength of spot welded joints was established.  
(2) A classification model for tensile and shear strength of spot welded joints based on PSO-SVM was established.  
(3) It has been clarified that PSO-SVM can improve the accuracy of spot welding strength classification.

**Key words:** spot welding; ultrasonic testing; tensile shear strength; BP neural network; PSO-SVM

## 0 序言

点焊是一种高速、高效、低成本的薄板连接方法, 是汽车零部件的主要连接方式之一, 点焊质量直接影响汽车结构安全性能和使用寿命。目前, 传统的破坏性试验和抽样检验主要用于评价点焊的力学性能, 这些方法无法满足大批量车辆点焊质量快速准确检测的需要。

超声波信号检测可以有效检测固体中缺陷的类型和大小, 因此广泛应用于焊接件的性能检测, Abbas<sup>[1]</sup>认为, 可以通过超声波检测的衰减系数来估计点焊的显微硬度等焊接物理特性; Esmaeil<sup>[2]</sup>研究了汽车工业中不同点焊引起的缺陷对相似和不同板材性能的影响, 该试验通过超声波浸没法研究了产生缺陷波的反应强度和振幅, 及其对结果的影响; Dong 和 Fan 等人<sup>[3-4]</sup>使用基于小波包分解和重构技术的处理方法, 更准确地计算电阻点焊接头中气孔的大小和位置; Elangovan 等人<sup>[5]</sup>使用响应面法 (response surface methodology, RSM) 和遗传算法 (genetic algorithm, GA) 相结合确定最佳焊接条件, 提高焊接接头的强度; Yu 等人<sup>[6]</sup>研究了超声波技术在评估点焊件焊接性方面的适用性, 通过试验结果证实了平均衰减系数  $\alpha\text{-avg}$  行为与拉伸剪切强度行为的密切相关; Siljama 等人<sup>[7]</sup>开发了卷积神经网络并证明现代神经网络能够适应丰富的超声数据, 并显示出更准确的探伤性能; 张佳莹等人<sup>[8]</sup>提出一种基于幅度加权频率调制的超声检测方法, 能较好地判断焊缝内部缺陷类别; Wang 等人<sup>[9]</sup>使用 Krish 边缘检测算子进行边缘检测并计算点焊形状。上述研究证明, 基于超声信号检测的方法对点焊强度的无损检测提供较好的检测精度。

对于汽车零件点焊而言, 点焊接头拉伸剪切强度是评价点焊质量的最重要因素, 文中在制备大量点焊试样的基础上, 对各点焊试样接头进行超声信号检测, 运用信号处理获得时域、频域和小波包特征值, 通过对点焊试样进行拉剪试验, 建立点焊接头拉剪强度的分级标准, 随后根据试验数据设计了 BP 神经网络和 PSO-SVM 的神经网络分类器, 最后

将不同超声信号特征值作为输入参数, 比较了两种神经网络模型对点焊拉剪强度分类的准确率。

## 1 点焊试验与结果

### 1.1 试验方法

低碳钢具有低强度、低硬度、高耐磨性和良好焊接性等特点, 广泛应用于汽车零部件的工业生产制造, 试验选取碳含量约为 0.14%~0.22%、厚 1.6 mm 的低碳钢薄板作为点焊材料, 为方便后续点焊拉剪试验的装夹, 将金属薄板板材切割为 100 mm × 30 mm 的长方形试块, 两薄板搭接重叠部分的长度为 30 mm, 运用 JTF-600DN 交流点焊机进行焊接试验, 具体试样尺寸如图 1 所示, 通过改变电阻点焊的工艺参数 (焊接电流 6~12 kA; 焊接时间 0.2~0.4 s; 电极压力 2~5 kN), 共制备 100 组不同焊接质量的试样, 如图 2 所示。

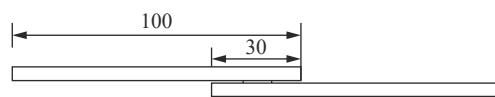


图 1 点焊试样示意图 (mm)  
Fig. 1 Schematic diagram of spot welding sample



图 2 点焊试验样本  
Fig. 2 Spot welding test samples

根据声场理论以及检测工艺, 采用中心频率为 15 MHz 带楔块的传感器探头对点焊试样进行测试, 如图 3 所示, 该探头晶片直径为 7.6 mm, 通过武汉中科创新公司生产的 HSD 多通道超声检测仪进行检测, 如图 4 所示。

在进行超声检测之前, 需要在点焊较为平整的一侧涂抹耦合剂, 由于机油粘度适合且不会腐蚀工件, 试验采用机油作为超声耦合剂, 把超声探头紧

贴于涂抹耦合剂的点焊处,为避免探头偏移或耦合效果不好,需要使用一定的压力按压超声探头,当超声检测仪显示良好波形图时,记录波形信号完成点焊的超声检测,按照该方法完成所有点焊试样的检测并保存其波形信号。

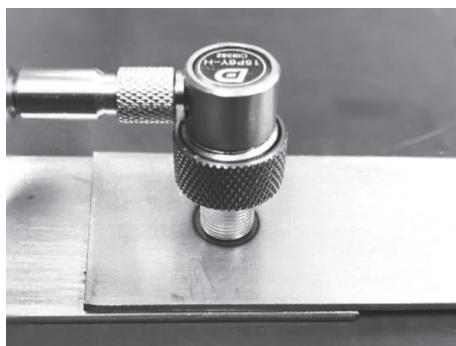


图 3 超声检测探头检测点焊试样

Fig. 3 Ultrasonic testing probe for spot welding sample



图 4 超声检测仪及检测软件

Fig. 4 Ultrasonic tester and testing software

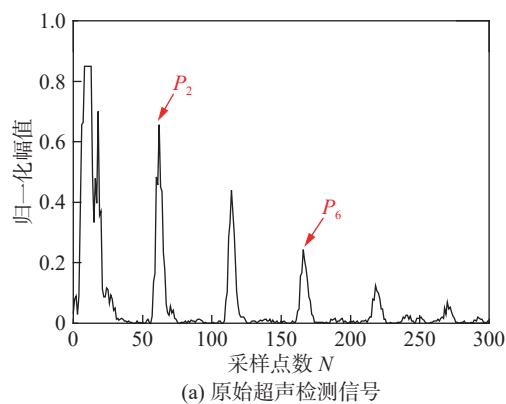
通过目视筛选出强度明显较低的 6 个点焊样本,随后运用 CMT 系列微机控制电子万能试验机对剩下的 94 个点焊试样进行拉剪试验,将点焊试样一端固定,另一端按照速度为 2 mm/min 进行拉伸,直到点焊试样破坏失效为止,在拉伸试验过程中试验机自动记录载荷-位移曲线,同时观察点焊试样的形变过程以及断裂程度。

## 1.2 超声信号特征提取

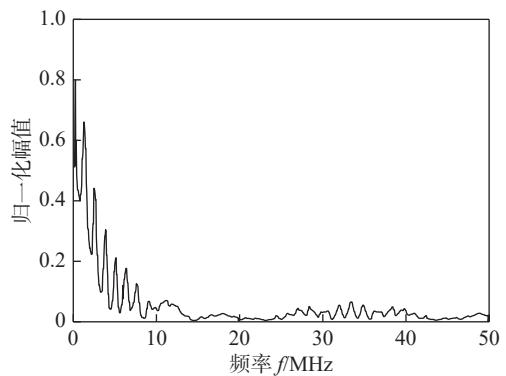
点焊形态会对超声时域波形产生不同程度的影响,但仍然无法直接判定点焊的具体内部缺陷尺寸和形态特征<sup>[10]</sup>,运用快速傅里叶变换处理超声时域信号能突出不同缺陷形态的频谱特征,所提取的超声频谱特征值能够一定程度上表征点焊内部不

同类型的缺陷信息,但对于多缺陷同时存在的情况或复杂不规则形态的焊点缺陷,所提取的频谱特征值还不能够完全反映全部的点焊内部结构和缺陷信息。小波包变换是小波变换的一种延伸方法,它不仅能突显信号低频信息,而且可以很好地保留高频细节信息。汽车点焊超声检测信号中,材料内部的缺陷形态特征和板材表面压痕信息,常常体现在信号高频部分,此外,超声信号高频容易被材料内部噪音和外部环境振动等因素影响而被淹没<sup>[11-12]</sup>。基于小波包变化超声信号特征提取,其原理就是通过小波包同时分解低频信号和高频信号,从分解的子带信号中提取隐藏在超声缺陷信号中的高频分量特征信息,将各个子带频段上的能量分布特点和各频带衰减系数作为材料内部缺陷形态的识别特征。

试验在获得点焊原始超声检测信号的基础上,如图 5 所示,对点焊超声检测信号分别进行频谱分析、小波分解与重构和小波包分析,如图 6 所示,实现点焊超声信号去噪和增益补偿,随后运用数学统



(a) 原始超声检测信号



(b) 超声检测信号频谱图

图 5 点焊超声检测信号

Fig. 5 Ultrasonic testing signal of spot welding. (a) original ultrasonic testing signal; (b) ultrasonic testing signal spectrum diagram

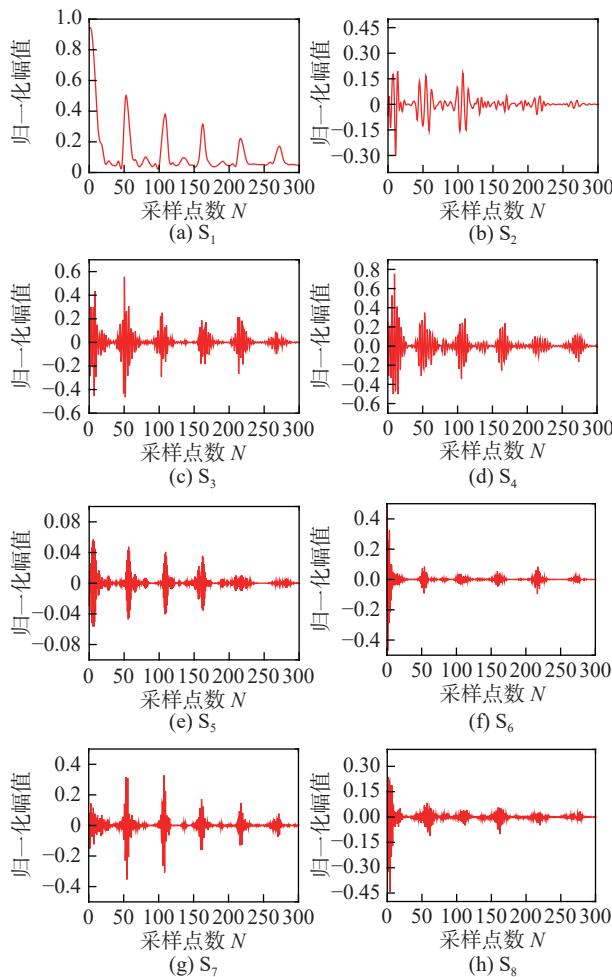


图6 点焊超声信号三层小波包变换子带信号

Fig. 6 Three layer wavelet packet transform subband signal of spot welding ultrasonic signal. (a) S<sub>1</sub>; (b) S<sub>2</sub>; (c) S<sub>3</sub>; (d) S<sub>4</sub>; (e) S<sub>5</sub>; (f) S<sub>6</sub>; (g) S<sub>7</sub>; (h) S<sub>8</sub>

计方法提取各点焊试样的超声时域信号特征值、频域信号特征值和小波包信号特征值,具体信号处理方法见参考文献[13]和[14].

### 1.3 点焊拉剪试验结果

#### 1.3.1 点焊拉剪失效模式分析

通过观察点焊拉剪试样的变形过程和最终断

裂形式,如图7所示,发现最终出现了3种不同的断裂类型,即母材撕裂、熔核拔出、分界面撕裂,其中,模式1是从热影响区靠近母材处断裂,最后沿着母材撕裂,这种模式发生在焊核质量比较好的情况,即熔核直径较大且焊核表面压痕较小,见图7(a);模式2是从热影响区靠近焊核处断裂,表现为焊核从母材中拔出,当熔核压痕过深时,便会出现这种现象,见图7(b);模式3为完全界面撕裂,一般发生在焊点熔核直径过小或熔核处的脆性过高,则结合面在不断加大的拉剪载荷作用下,导致焊核中间产生撕裂,即在两薄板连接面处发生完全界面撕裂,见图7(c).

#### 1.3.2 点焊拉剪强度结果与分类

选取3种典型断裂模式试样的载荷-位移曲线进行分析,如图8所示.曲线a为母材撕裂失效模式的点焊试样,最大拉剪强度约为18 kN,其变形位移量最大,超过了5.5 mm,说明破坏该点焊接头所消耗的能量最大,即该类型点焊接头的力学性能最佳;曲线b的失效模式为熔核拔出,该点焊试样的最大拉剪强度约为15 kN,变形位移量约4 mm,能满足焊接试样的最低强度要求;曲线c的失效模式为分界面撕裂,点焊接头最大拉剪强度约为10 kN,点焊接头变形量不足2 mm,说明该类型点焊接头强度弱,属于不合格焊点.文中根据各点焊试样拉剪断裂形式的不同,将点焊接头质量分为3种级别:良好焊点(A)、合格焊点(B)和不合格焊点(C),以各组点焊试样最大拉剪强度的最小值为标准,其中良好焊点的最大拉剪强度 $F_A > 16.4$  kN,合格焊点最大拉剪强度 $16.4 \text{ kN} \geq F_B \geq 14.8$  kN,不合格焊点的最大拉剪强度 $F_C < 14.8$  kN,按此标准分类对94组点焊试样进行分类,其拉剪强度分布结果如图9所示.

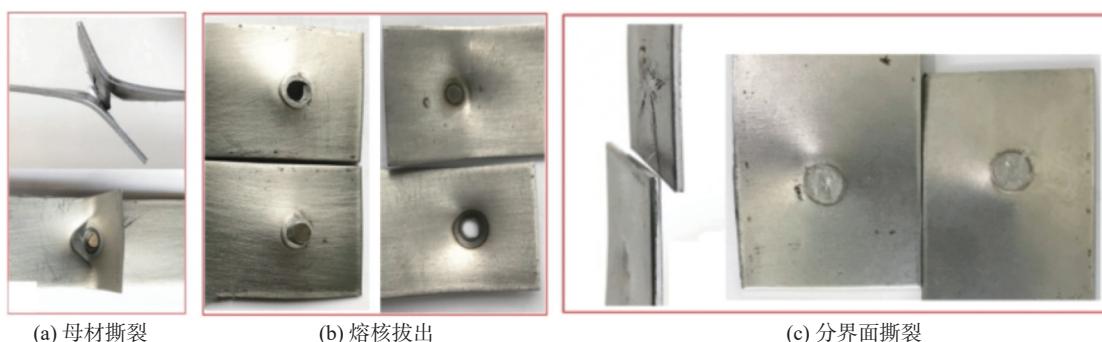


图7 点焊拉剪失效模式

Fig. 7 Failure mode of spot welding tensile shear. (a) base material tearing; (b) nugget extraction; (c) interfacial tearing

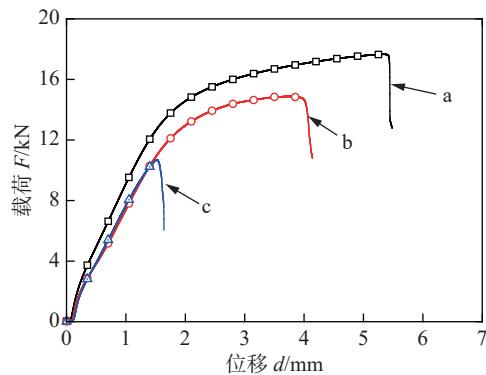


Fig. 8 Load-displacement curve

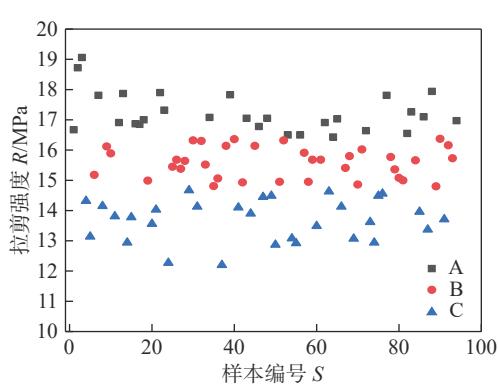


图 9 点焊试样拉剪强度分布

Fig. 9 Tensile-shear strength distribution of spot welding sample

## 2 神经网络模型构建

### 2.1 BP 神经网络

BP 神经网络是一种单向传播网络结构, 具有正向传递和反向传播的特点, 其中正向传递用于分析计算, 反向传播用于逐层反馈期望的输出值与实际输出结果之间的误差, 并修正权值和阀值参数, 在解决超声检测信号特征值识别的具体问题时, 需要进行多次训练和反复调整权值和阀值, 使误差函数向最小误差函数逼近。

### 2.2 基于粒子群优化算法的支持向量机神经网络

针对 BP 神经网络在处理样本较少的数据库时所出现的稳定性差, 误差大等问题, 采用一种基于粒子群优化算法的支持向量机 PSO-SVM 神经网络分类器, 该方法是通过将训练样本数据库映射到高纬度的输入空间中, 在高维度空间中建立一种最佳的分离超平面, 在该平面上可以实现最大程度区分不同类型的样本, 并且运用多种非线性函数提高样

本区分精度<sup>[15]</sup>, 假设输入的两类样本合集为

$$\mathbf{T} = \{(x_1, y_1), \dots, (x_i, y_i)\} \in (X \cdot Y)^l \quad (1)$$

式中:  $x_i \in R^n$  为第  $i$  个特征向量,  $y_i \in Y = \{1, 2, 3\}$  ( $i = 1, 2, \dots, l$ ) 为类别; 1、2、3 表示分类标识;  $l$  为输入样本数据的个数,  $n$  为输入样本的维数。SVM 神经网络采用最优超平面  $P: \omega \cdot x + b^* = 0$  对数据样本进行分类, 使得  $\mathbf{T}$  中的不同类型的样本被正确的区分开, 并且使分类面附近的样本空间距离最大化, 等价于  $\|\omega\|^2$  最小, 其中  $\omega$  表示最优分类面的法向量;  $b^*$  表示分类阈值, 非线性 SVM 分类器函数为<sup>[16]</sup>

$$\begin{cases} \min \varphi(\omega, \varepsilon) = \frac{1}{2} \|\omega\|^2 + c \sum_{i=1}^l \varepsilon_i \\ s.t. y_i (\omega \cdot x + b^*) \geq 1 - \varepsilon_i, \varepsilon_i \geq 0; i = 1, 2, \dots, l \end{cases} \quad (2)$$

式中:  $\varepsilon_i$  为松弛因子, 当训练数据库出现少量错误数据时, 该因子可以起修正作用;  $c$  为惩罚因子, 对错误数据样本, 该因子可规定其惩罚程度  $w$  表示最优分类面的法向量;  $b^*$  为分类阈值。选取合适的核函数  $K(x_i, x)$  和适当的参数  $c$ , 构造决策函数

$$f(x) = \text{sgn} \left[ \sum_{i=1}^l y_i \alpha_i^* K(x_i, x) + b^* \right] \quad (3)$$

式中:  $0 < \alpha_i^* < c$ , SVM 网络结构运用核函数径向基函数 (radial basis function, RBF) 将有限个样本数据转换为无穷维度空间可以线性区分的数据结构, 定义  $K(x_i, x) = \exp(-g \|x_i - x\|^2)$ , 其中  $g = \delta^{-2}$  就是核函数参数, 故定义决策函数为

$$f(x) = \text{sgn} \left( \sum_{i=1}^l y_i \alpha_i^* \exp(-g \|x_i - x\|^2) + b^* \right) \quad (4)$$

RBF 核函数中惩罚因子  $c$  和关键参数  $g$  对 SVM 神经网络的性能起到关键性作用, 为得到最适合样本数据库的神经网络修正参数, 采用粒子群优化算法 (PSO) 寻找最优参数  $c$  和  $g$ 。

### 2.3 基于 PSO-SVM 的点焊接头拉剪强度分类模型

基于 PSO-SVM 的点焊接头拉剪强度分类模型建立的算法流程, 如图 10 所示。

模型建立的具体步骤如下:

步骤 1: 根据点焊最大拉剪强度对点焊质量进行分类, 将点焊试样分为良好焊点、合格焊点、不合格焊点 3 种类别, 并分别用 1、2、3 标识。运用前述信号处理和数理统计方法, 将提取的特征值储存于数据库文件中, 每组数据为 10 维, 前 9 维为超声信

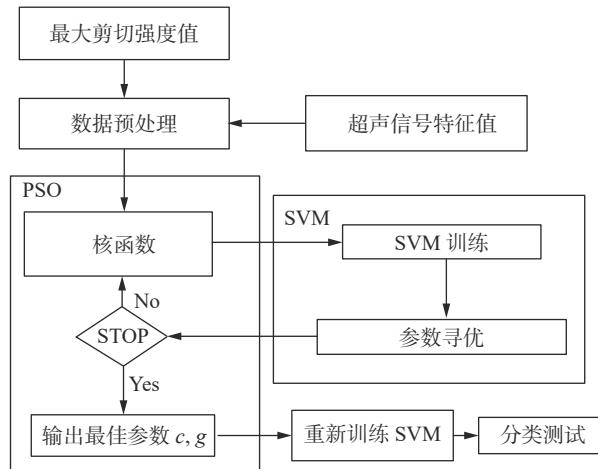


图10 基于PSO算法优化的SVM神经网络模型流程图  
Fig. 10 Chart of SVM neural network model optimized based on PSO algorithm

号特征值,最后1维为该试样的最大拉剪强度.按此方法共获得94组点焊试样的数据库,见表1.运用随机函数从表1中选取74组样本用来训练网络模型,剩余的20组则用于测试神经网络模型对试

样拉剪强度进行分类的准确率;

步骤2:对部分特征值参数( $K$ ,  $A_m$ ,  $Kurt$ ,  $\bar{E}$ ,  $S_{E^2}$ )进行量化处理,减小因为数据数值的差异性太大造成的预测误差影响,按下式将量化后的数据归一化到区间[0,1]

$$f: x \rightarrow y = \frac{x - x_{\min}}{\max(x) - \min(x)} \quad (5)$$

步骤3:设置PSO-SVM模型的初始参数,包括种群规模、迭代次数、学习因子、惯性权重、初始粒子位置和粒子初始速度等;

步骤4:依据SVM分类决策函数,评价每个粒子的适应度值,更新粒子群个体极值和全局极值;

步骤5:输出最优参数,若该参数是全局最优解,则寻优结束;反之,返回步骤3进行重新运算;

步骤6:将获得的最优 $c$ 和 $g$ 输入SVM模型中进行样本训练,得到全局最优的PSO-SVM模型,再运用该模型对剩余的20个试样拉剪强度进行分类预测.

表1 点焊超声检测时频特征值及最大拉剪强度

Table 1 Time domain and frequency domain characteristic value and maximum tensile shear strength of spot welding ultrasonic testing

序号	时域特征值			频域特征值			小波包特征值				拉剪强度 R/MPa
	底面回波峰 平均间隔 $\bar{s}/\text{mm}$	幅值系数 $K$	频谱 主频率 $f_m/\text{MHz}$	频谱幅值 极大值 $A_m$	峰度 $Kurt$	各频带能量 平均值 $\bar{E}$	能量方差 $S_{E^2}$	各频带衰减系数 平均值 $\bar{\alpha}(\text{dB/mm})$	衰减系数 方差 $S_{\alpha^2}$		
1	2.74	0.136	1.172	0.603	0.409	0.138	0.321	2.52	0.68	16.67	
2	2.65	0.158	1.172	0.456	0.389	0.656	0.815	2.82	0.35	18.72	
3	2.65	0.042	1.172	0.664	0.527	0.950	0.235	1.75	0.67	19.06	
4	2.64	0.067	1.172	0.974	0.495	0.865	0.310	0.96	1.92	14.32	
5	2.56	0.354	1.172	0.655	0.493	0.515	0.827	2.13	1.17	13.14	
6	2.79	0.207	1.367	0.566	0.442	0.994	0.944	1.97	0.39	15.18	
7	2.86	0.409	1.172	0.505	0.341	0.877	0.584	3.14	0.26	17.81	
:	:	:	:	:	:	:	:	:	:	:	
93	2.65	0.223	0.780	0.378	0.325	0.632	0.384	3.72	2.64	16.16	
94	2.53	0.154	1.367	0.489	0.366	0.853	0.226	1.49	0.85	15.72	

### 3 基于人工神经网络的点焊接头拉剪强度分类研究

#### 3.1 基于BP神经网络算法的点焊接头拉剪强度分类

为了研究不同特征值参数对BP神经网络算法的影响,分别将2个时域特征值、3个频域特征值、

4个小波包特征值以及全部特征值作为输入参数,点焊最大拉剪强度类别作为输出参数,利用BP神经网络模型进行分类后的结果如图11所示,可以明显看出,采用时域特征值对20个测试样本进行分类后,正确识别的数量为8个,识别准确率为40%;采用频域特征值,识别准确率为45%;采用小波包特征值,识别准确率为55%,如果采用全部特

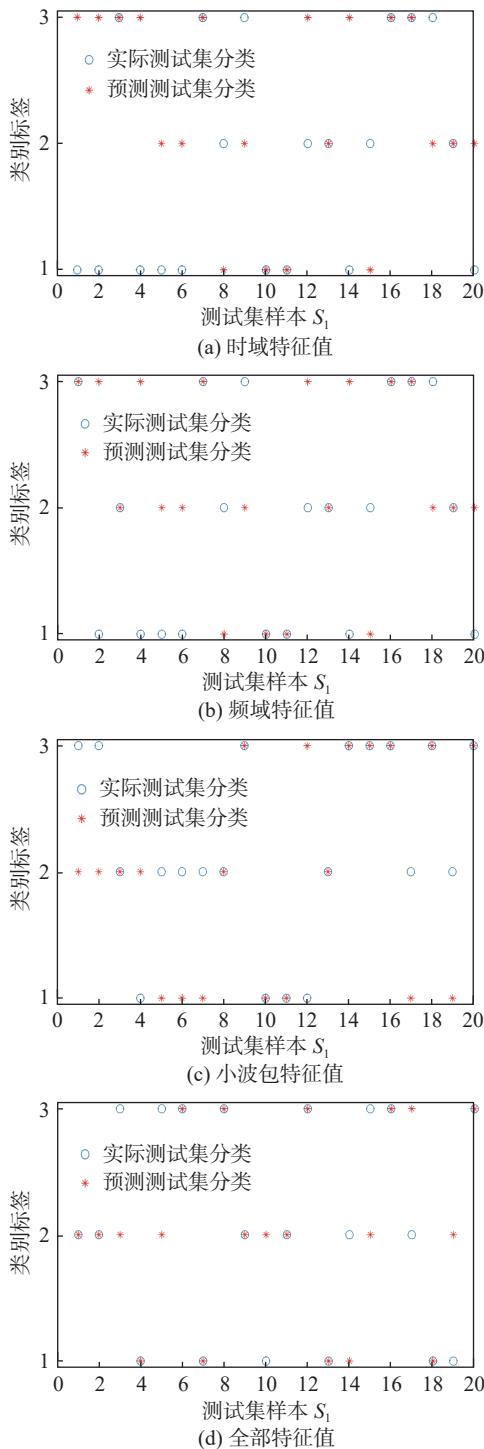


图 11 BP 神经网络测试集分类结果

Fig. 11 Classification results of BP neural network test set. (a) time domain eigenvalue; (b) frequency domain eigenvalue; (c) wavelet packet domain eigenvalue; (d) all eigenvalue

征值,识别准确率为 65%。

### 3.2 基于 PSO-SVM 的点焊接头拉剪强度分类

按照 PSO-SVM 算法,首先运用 psoSVMcgForClass 函数对 74 组训练样本进行 SVM 最佳参数的寻找,经 PSO 算法优化后,得到 RBF 核函数参数

$g$  和惩罚因子  $c$ ,然后将其输入测试集中。随后分别将 2 个时域特征值、3 个频域特征值、4 个小波包特征值和全部特征值作为输入参数,点焊强度类别作为输出参数,对 PSO-SVM 神经网络分类器的准确率进行验证,结果如图 12 所示。可以看出,采用时

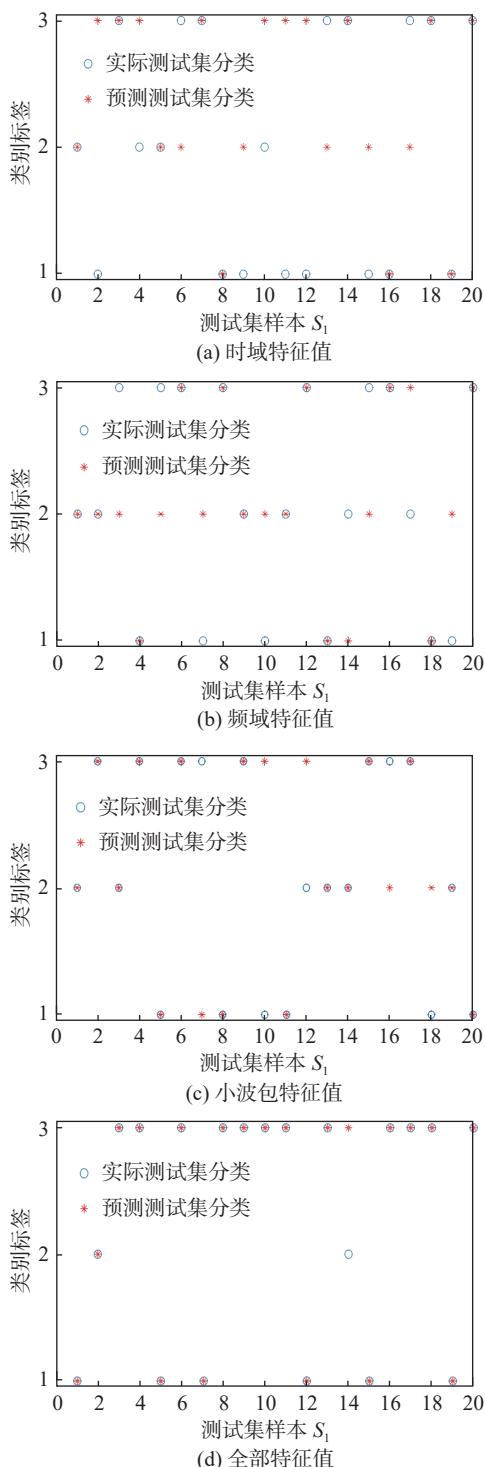


图 12 PSO-SVM 神经网络测试集分类结果

Fig. 12 Classification results of PSO-SVM neural network test set. (a) time domain eigenvalue; (b) frequency domain eigenvalue; (c) wavelet packet domain eigenvalue; (d) all eigenvalue

域特征值对20个测试样本进行分类,正确识别的数量为10个,识别准确率为50%;采用频域特征值,准确率为60%;采用小波包特征值,准确率为75%,采用全部特征值,识别准确率为95%。

采用时域特征值和全部特征值作为PSO-SVM神经网络分类器的输入参数,其最终的适应度曲线分别如图13和图14所示。可以明显看出,当采用全部特征值进行寻优后,其适应度曲线值更高,预测的准确率能达到95%,由此可以确定,与传统BP神经网络算法相比,采用PSO-SVM神经网络分类器的分类准确率得到明显提高。

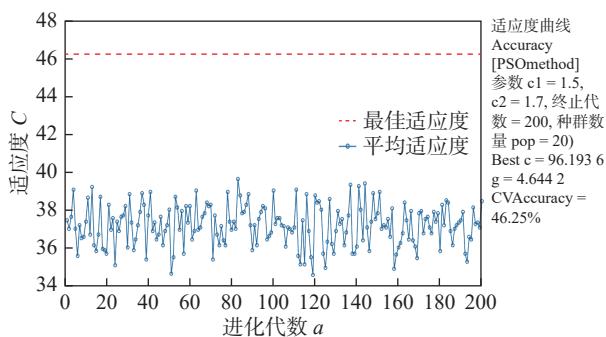


图13 PSO-SVM寻找最佳参数的适应度曲线(部分特征值)

Fig. 13 Fitness curve of PSO-SVM to find the best parameters (partial eigenvalue)

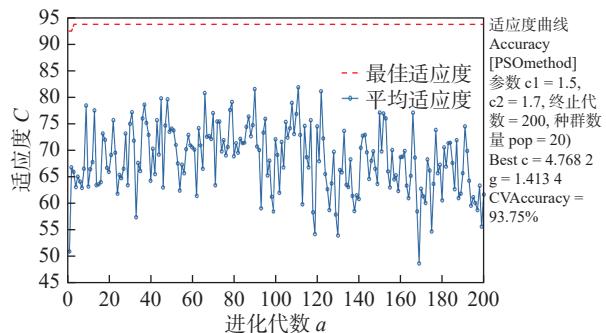


图14 PSO-SVM寻找最佳参数的适应度曲线(全部特征值)

Fig. 14 Fitness curve of PSO-SVM for finding the best parameters (all eigenvalue)

### 3.3 两种神经网络分类结果对比与分析

采用传统BP神经网络分类器和PSO-SVM神经网络分类器,对点焊拉剪强度进行分类的识别结果见表2,当输入相同的特征值时,PSO-SVM神经网络分类器识别准确率均高于传统BP神经网络分类器,其原因在于通过PSO粒子群算法能获得最优惩罚因子 $c$ 和函数参数 $g$ ,SVM分类器的性能明显提高,从而获得了更高的分类准确率。

表2 不同神经网络分类器的识别准确率

Table 2 Recognition accuracy of different neural network classifiers

特征值类型	BP神经网络		PSO-SVM神经网络	
	正确识别数量 $N_1$	准确率 $A$	正确识别数量 $N_2$	准确率 $A$
时域特征值	8	40%	10	50%
频域特征值	9	45%	12	60%
小波包特征值	11	55%	15	75%
全部特征值	13	65%	19	95%

点焊超声检测信号的特征值是其拉剪强度识别的前提和关键,选取合适的特征值可有效提高识别的准确率。通过表2中的数据还可以发现,不管是传统BP神经网络还是PSO-SVM神经网络的分类结果,采用小波包特征值作为输入端,分类器的识别准确率均明显高于频域特征值和时域特征值的识别效果。原因在于点焊内部组织结构信息和缺陷信息在超声检测时域信号和频域信号中表现不明显或被噪音埋没,当含有不同类型缺陷和表面质量的点焊超声检测信号经小波包分解后,其能量和衰减系数在各频带上的分布是不同的,而且7个高分子带信号能量分布的波动性和不均匀性也不同,反映不同类型缺陷对不同频率信号反射能量不同,因此将其作为点焊拉剪强度的识别特征值,能显著提高识别效果,如果同时结合全部时域、频域以及小波包子带特征值作为神经网络分类器的输入参数,测试样本识别准确率还可以进一步提升,说明输入端特征值越多,神经网络分类器训练效果越好,该结果也验证了运用PSO-SVM神经网络对点焊拉剪强度进行分类的可行性和正确性。

## 4 结论

(1)通过观察点焊拉剪试样的变形过程和最终断裂形式,可以将点焊断裂类型分为母材撕裂、熔核拔出、分界面撕裂等3种形式,结合实际拉剪强度数据,可以将点焊样本分为良好焊点(最大拉剪强度 $F_A > 16.4$  kN),合格焊点(最大拉剪强度 $16.4 \geq F_B \geq 14.8$  kN)和不合格焊点(最大拉剪强度 $F_C < 14.8$  kN)。

(2)以提取的点焊超声检测信号的特征值数据库为输入参数,点焊最大拉剪强度数据库作为分类识别,分别采用BP神经网络和PSO-SVM神经网

络分类器对数据库参数进行分类,结果表明,PSO-SVM 的分类精度明显优于 BP 神经网络。

(3) 不同特征值参数的输入对分类器的识别准确率有不同的影响,结合所有 9 个特征值参数,可以实现最佳的识别准确率。

## 参考文献

- [1] Abbas Moghanizadeh. Evaluation of the physical properties of spot welding using ultrasonic testing[J]. *The International Journal of Advanced Manufacturing Technology*, 2016, 85(1/4): 535 – 545.
- [2] Esmaeil Mirmahdi. Numerical and experimental modeling of spot welding defects by ultrasonic testing on similar sheets and dissimilar sheets[J]. *Russian Journal of Nondestructive Testing*, 2020, 56(8): 620 – 634.
- [3] Dong J, Xu G C, Wei L B, et al. Ultrasonic C-scan detection research for effective connection area of arc-stud-weld joints[J]. *The International Journal of Advanced Manufacturing Technology*, 2019, 104(9/12): 4007 – 4021.
- [4] Fan Q Y, Xu G C, Gu X P. Ultrasonic nondestructive evaluation of porosity size and location of spot welding based on wavelet packet analysis[J]. *Journal of Nondestructive Evaluation*, 2020, 39(1): 7 – 9.
- [5] Elangovan S, Anand K, Prakasan K. Parametric optimization of ultrasonic metal welding using response surface methodology and genetic algorithm[J]. *The International Journal of Advanced Manufacturing Technology*, 2012, 63(8): 561 – 572.
- [6] Yu Hyo-Sun, Ahn Byung-Guk. A study on ultrasonic test for evaluation of spot weldability in automotive materials[J]. *KSME International Journal*, 1999, 13(11): 775 – 782.
- [7] Siljamaa Oskar, Koskinen Tuomas, Jessen-Juhler Oskari, et al. Automated flaw detection in multi-channel phased array ultrasonic data using machine learning[J]. *Journal of Nondestructive Evaluation*, 2021, 40(3): 67 – 80.
- [8] 张佳莹,丛森,刚铁,等.基于频率-相位编码信号激励的焊缝超声检测分析 [J]. *焊接学报*, 2018, 39(7): 7 – 11.
- Zhang Jiaying, Cong Sen, Gang Tie, et al. Research on weld ultrasonic testing based on frequency-phase coded excitation[J]. *Transactions of the China Welding Institution*, 2018, 39(7): 7 – 11.
- [9] Wang T, Wang C S, Xu G C, et al. Analysis of ultrasonic C-scan image features and image processing for spot welding[J]. *China Welding*, 2015, 24(2): 52 – 56.
- [10] Liu J, Xu G C, Gu X P, et al. Ultrasonic test of resistance spot welds based on wavelet package analysis[J]. *Ultrasonics*, 2014, 56: 557 – 565.
- [11] Sumathi S. A new wavelet transform based feature extraction and classification of life-threatening cardiac arrhythmias[J]. *International Medical Journal*, 2016, 3: 244 – 248.
- [12] Yang P, Li Q F. Wavelet transform based feature extraction for ultrasonic flaw signal classification[J]. *Neural Computing & Applications*, 2014, 24(3-4): 817 – 826.
- [13] 吴刚,关山月,汪小凯,等.薄板点焊超声检测信号特征分析与缺陷识别 [J]. *焊接学报*, 2019, 40(4): 112 – 118.  
Wu Gang, Guan Shanyue, Wang Xiaokai, et al. Feature analysis and defect recognition of ultrasonic detection signal for spot welding of sheet[J]. *Transactions of the China Welding Institution*, 2019, 40(4): 112 – 118.
- [14] 吴刚,关山月,汪小凯,等.基于超声信号增益补偿的电阻点焊熔核直径评估算法 [J]. *中国测试*, 2018, 44(8): 13 – 19.  
Wu Gang, Guan Shanyue, Wang Xiaokai, et al. Resistance spot welding nugget diameter estimation algorithm based on ultrasonic signal gain compensation[J]. *China Measurement & Test*, 2018, 44(8): 13 – 19.
- [15] Xu M X, Shi J Q, Chen W, et al. A band selection method for hyperspectral image based on particle swarm optimization algorithm with dynamic sub-swarms[J]. *Journal of Signal Processing Systems*, 2018, 90(8/9): 1269 – 1279.
- [16] Ye F. Evolving the SVM model based on a hybrid method using swarm optimization techniques in combination with a genetic algorithm for medical diagnosis[J]. *Multimedia Tools and Applications*, 2018, 77(3): 3889 – 3918.

**第一作者:**吴刚,博士,副教授;主要研究方向为智能焊接与无损检测;Email: 2623800082@qq.com.

(编辑: 刘启明)