

# 基于动态权重的自适应 PSO-BP 神经网络焊接缺陷成因诊断

高昶霖<sup>1</sup>, 宋燕利<sup>1,2,3</sup>, 左洪洲<sup>4</sup>, 章诚<sup>1</sup>

(1. 武汉理工大学, 现代汽车零部件技术湖北省重点实验室, 武汉, 430070; 2. 武汉理工大学, 汽车零部件技术湖北省协同创新中心, 武汉, 430070; 3. 武汉理工大学, 湖北省材料绿色精密成形工程技术研究中心, 武汉, 430070; 4. 湖北省齐星汽车车身股份有限公司, 随州, 441300)

**摘要:** 焊接缺陷产生原因复杂, 影响因素众多, 基于人工智能的缺陷成因诊断算法成为焊接智能化的发展方向. 将 PSO-BP 神经网络应用于焊接缺陷成因诊断, 利用神经网络的连接学习机制代替传统专家系统的规则推理机制, 并对 PSO 算法进行自适应调整, 引入动态权重因子, 搭建自适应 PSO-BP 神经网络模型. 结果表明, 与传统 PSO-BP 神经网络模型相比, 改进的 PSO-BP 神经网络模型训练所需要的迭代次数减少 13.1%, 诊断结果准确率从 93.3% 提高至 96.7%, 精确率从 91.3% 提高至 98.3%, 综合能力指标从 91.7% 提高至 96.9%. 改进算法能够明显提升焊接缺陷成因诊断的效率和精度, 具有较好的工程应用价值.

**创新点:** (1) 建立具有动态权重因子的自适应 PSO-BP 神经网络模型.

(2) 通过 BP 算法与 PSO 算法的密切结合形成神经网络连接学习机制, 代替传统专家系统的规则推理机制.

**关键词:** 焊接缺陷成因; 神经网络; 动态权重; 自适应

**中图分类号:** TG 409      **文献标识码:** A      **doi:** 10.12073/j.hjxb.20210515001

## 0 序言

为适应高性能智能化制造国际发展趋势与国家重大需求, 焊接缺陷智能诊断技术成为新兴的前沿制造方向. 焊接缺陷产生的原因分析历来是焊接领域的难点, 由于缺陷种类形态多样, 缺陷形成原因复杂, 因而缺陷成因诊断过于依赖人工经验, 导致效率和可靠性极低. 为解决此问题, 具有智能诊断功能的焊接专家系统逐渐得到应用<sup>[1-2]</sup>.

目前, 应用于专家系统的智能算法有随机森林、决策树、神经网络等. 其中随机森林、决策树是基于一定的规则条件, 无法准确反映缺陷特征、工艺参数与焊接缺陷成因之间复杂的非线性关系, 诊断准确率较低. 神经网络算法具有大规模并行处理、学习能力强、非线性度高等特点, 利用神经网络

的连接机制代替传统专家系统的规则表示, 更适合于焊接热源建模、焊接工艺优化和缺陷诊断识别这类非线性、多分类问题<sup>[3-5]</sup>.

虽然神经网络有许多优点, 但其缺点也很明显, 即容易陷入局部极小值, 需要长期学习, 收敛速度慢等<sup>[6]</sup>, 因而需要将其它方法与神经网络进行结合. 刘占军等人<sup>[7]</sup>提出神经网络缺陷诊断专家系统, 对铝合金焊接气孔缺陷成因进行诊断, 借助补偿模糊控制使其诊断误差最小化, 提高诊断精度及置信度. 姜洪权等人<sup>[8]</sup>提出将随机森林与卷积神经网络相结合的强化特征选择方法对汽轮机的焊接缺陷诊断, 通过提高特征选择能力, 使得所提方法比传统卷积神经网络方法具有更高的缺陷识别率. Ravi 等人<sup>[9]</sup>采用图像金字塔及图像重构技术与卷积神经网络结合, 对 AA1100 铝合金的裂纹、凹坑等焊接缺陷进行分类, 给出了焊道表面横截面中各类缺陷的密度, 有助于焊接参数监测系统的搭建. Bacioiu 等人<sup>[10]</sup>使用高动态范围成像与神经网络相结合, 对 5083 铝合金的烧穿、未熔合等焊接缺陷进行分类, 但未给出缺陷成因.

收稿日期: 2021-05-15

**基金项目:** 湖北省技术创新专项 (2019AAA014); 湖北省重点研发计划项目 (2020BAB143); 新能源汽车科学与关键技术学科创新引智基地 (B17034); 教育部创新团队发展计划资助项目 (IRT\_17R83).

目前焊接缺陷诊断主要集中在缺陷种类识别,对缺陷成因的智能推理研究较少,且均简单地采用神经网络与其它方法联合以提高识别能力,缺少对模型内部结构自适应调整算法的探讨.基于此,提出粒子群-反向传播 (particle swarm optimization-back propagation, PSO-BP) 神经网络数学描述方法,构建具有内部结构自适应调整功能的焊接缺陷成因诊断神经网络模型.该模型能够有效提升焊接缺陷成因诊断的效率和精度,为焊接工艺优化提供可靠依据.

## 1 基于动态权重的自适应 PSO-BP 神经网络算法

### 1.1 PSO 优化算法

PSO 算法的主要思想是通过种群中个体之间的协作和信息共享寻找最优解<sup>[1]</sup>.系统初始化为一组随机解,通过迭代搜寻最优值.在 PSO 算法中,每个粒子代表这个优化问题的一个潜在解.在模型运行时,首先初始化一群随机粒子(随机解),然后每个粒子都对应一个由被优化函数所决定的适应度,在不断的迭代中,每个粒子通过跟踪个体极值(粒子本身所找到的最优解)和全局极值(整个种群当前找到的最优解)更新直到找到最优解<sup>[12-13]</sup>.

设共有  $M$  个粒子,其中,第  $i$  个粒子的位置在  $D$  维解空间的位置表示为  $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ ,速度表示为  $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ ,其中  $i = 1, 2, \dots, M$ .将位置  $\mathbf{X}_i$  带入适应度函数可计算出该粒子当前位置所对应的适应度.第  $i$  个粒子所经过的历史最佳位置向量记为  $\mathbf{P}_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ ,整个粒子群所经历过的历史最佳位置向量记为  $\mathbf{P}_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ .整个粒子群通过更新自身的速度和位置来搜索整个状态空间.

$$v_{in}(t+1) = \omega v_{in}(t) + c_1 r_1 (p_{in}(t) - x_{in}(t)) + c_2 r_2 (p_{gn}(t) - x_{gn}(t)) \quad (1)$$

$$x_{in}(t+1) = x_{in}(t) + v_{in}(t) \quad (2)$$

式中:  $n = 1, 2, \dots, D$ , 表示粒子对应的维度;  $t$  为当前迭代次数;  $v_{in}(t)$ ,  $x_{in}(t)$ ,  $p_{in}(t)$  分别表示第  $i$  个粒子在迭代  $t$  次后第  $n$  个维度的速度、位置、历史最佳位置;  $x_{gn}(t)$ ,  $p_{gn}(t)$  分别表示整个粒子群在迭代  $t$  次后第  $n$  个维度的位置、历史最佳位置;  $\omega$  为惯性权重;  $c_1, c_2$  为学习因子;  $r_1$  和  $r_2$  为每次迭代生成的  $[0, 1]$  内的随机数.

### 1.2 传统 PSO-BP 神经网络算法

PSO-BP 神经网络的基本原理就是利用 BP 神经网络建立焊接缺陷特征及工艺参数和缺陷形成原因之间的拓扑关系,使用 PSO 算法来代替 BP 模型中的初始化方法确定神经网络的初始网络参数.

在 PSO-BP 神经网络中,神经元之间所有的网络参数对应粒子群中一个粒子在当前迭代次数的位置, BP 神经网络每进行一次网络参数的更新则视作粒子位置的改变.设 BP 神经网络输入层、隐藏层、输出层个数为  $n_i, n_h, n_o$ , 则第  $i$  个粒子的位置可表示为

$$\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{iD}) = (w_{11}, w_{12}, \dots, w_{n_i n_h}, u_{11}, u_{12}, \dots, u_{n_h n_o}, \alpha_1, \alpha_2, \dots, \alpha_{n_h}, \beta_1, \beta_2, \dots, \beta_{n_o}) \quad (3)$$

式中:  $w_{pq}$  ( $p = 1, 2, \dots, n_i; q = 1, 2, \dots, n_h$ ) 表示输入层到隐藏层的连接权值;  $u_{qr}$  ( $q = 1, 2, \dots, n_h; r = 1, 2, \dots, n_o$ ) 表示隐藏层到输出层的连接权值;  $\alpha_q, \beta_r$  分别为隐藏层和输出层各神经元对应的偏置项.  $D$  的值等于  $w_{pq}, u_{qr}, \alpha_q, \beta_r$  4 类参数的个数总和.

损失函数是用来评价模型预测值与真实值不同程度的指标,损失函数值越小,表明预测值与实际值越接近,因而模型的性能越好.由于 BP 神经网络损失函数采用交叉熵作为损失函数,故 PSO 算法中粒子的适应度函数  $f_i$  如式 (4) 所示.

$$f_i = -\frac{1}{n} \sum_j [Y_{jk} \ln y_{jk} + (1 - Y_{jk}) \ln (1 - y_{jk})] \quad (4)$$

式中:  $n$  为样本个数;  $Y_{jk}$  为第  $j$  个样本的第  $k$  个实际输出值,  $y_{jk}$  为第  $j$  个样本的第  $k$  个预测输出值.

在模型训练时,神经网络参数就对应了 PSO 算法中的粒子位置.将神经网络模型初始化后的神经网络参数拉伸成一维,输入给 PSO 算法,即得到 PSO 算法中粒子的位置.通过 PSO 算法优化后的参数再带入神经网络中,再采用梯度下降算法,进行网络参数的更新,最终输出最优的网络模型.

### 1.3 基于动态权重的自适应 PSO-BP 神经网络算法

在传统 PSO-BP 神经网络算法的基础上,对网络参数的更新方式进行了改进.

#### 1.3.1 惯性权重

在 PSO 算法初始化神经网络参数时,选取一个合适的惯性权重值  $\omega$  可以平衡粒子全局搜索能力和局部搜索能力,增强粒子群的寻优性能.传统 PSO 算法中,惯性权重是一个定值,不能随着迭代次数进行变化,使得模型的灵活性和泛化能力不足.基于此提出了一种自适应惯性权重  $\omega$ .

在初始搜索阶段,此时粒子的适应度较大,惯性权重采用初始值较小的线性变化,以削弱这些粒子在粒子更新中所起的作用,使得算法在此阶段具有更强的全局搜索能力,并能尽快进入局部搜索;而在寻优后期,粒子适应度较小时,采用非线性的惯性权重,增大单个粒子在更新中的作用,使得算法能够快速收敛.设计的惯性权重如式(5)所示.

$$\omega = \begin{cases} 1 + \omega_{\max} - l_1(t), f_i < f_{\min} \\ \omega_{\min} + (\omega_{\max} - \omega_{\min})l_2(t), f_i \geq f_{\min} \end{cases} \quad (5)$$

式中:  $\omega_{\max}$  与  $\omega_{\min}$  分别为惯性权重  $\omega$  的最大值和最小值;  $l_1(t)$  为非线性函数;  $l_2(t)$  为线性函数;  $f_i$  为当前粒子的适应度;  $f_{\min}$  为粒子最小适应度.

$$\begin{cases} l_1(t) = e^{30\left(\frac{t}{8t_{\max}}\right)^{15}} \\ l_2(t) = \frac{t}{t_{\max}} \end{cases} \quad (6)$$

式中:  $t$  为模型当前迭代次数;  $t_{\max}$  为模型最大迭代次数.

### 1.3.2 学习因子

在 PSO 算法中,除了惯性权重这一重要参数外,学习因子  $c_1$ ,  $c_2$  也起到了至关重要的作用,  $c_1$  表示单个粒子的更新速率,  $c_2$  表示整个粒子群的更新速率.合适的学习因子可以加快粒子的搜索速度,减少算法陷入局部最优的可能性.在算法的初期,采取较大学习因子  $c_1$  和较小学习因子  $c_2$ ,每个粒子都要注意自身的历史信息,以保证各粒子状态变化的多样性.但是,在搜索后期,  $c_1$  减少,而  $c_2$  增加,使得粒子更加关注群体的社会信息,保持快速收敛.

设计的惯性权重如式(7)所示.

$$\begin{cases} c_1 = (c_{\max} - c_{\min})\cos\left(\frac{\pi}{2}\frac{t}{t_{\max}}\right) + c_{\min} \\ c_2 = (c_{\max} - c_{\min})\sin\left(\frac{\pi}{2}\frac{t}{t_{\max}}\right) + c_{\min} \end{cases} \quad (7)$$

式中:  $c_{\max}$  与  $c_{\min}$  分别为学习因子  $c$  的最大值和最小值.

### 1.3.3 动态权重因子

传统的梯度下降法如式(8)所示.在 BP 神经网络结构中,网络参数的更新方式保留了原本 BP 网络的梯度下降算法,引入动态权重因子  $\eta$ ,将 PSO 算法与梯度下降法结合,如式(9)所示.

$$x = x - \nabla x \cdot c \quad (8)$$

$$x = (1 - \eta) \cdot (x - \nabla x \cdot c) + \eta \cdot x_{\text{PSO}} \quad (9)$$

式中:  $x$  为神经网络参数;  $\eta$  为权重因子,代表更新参

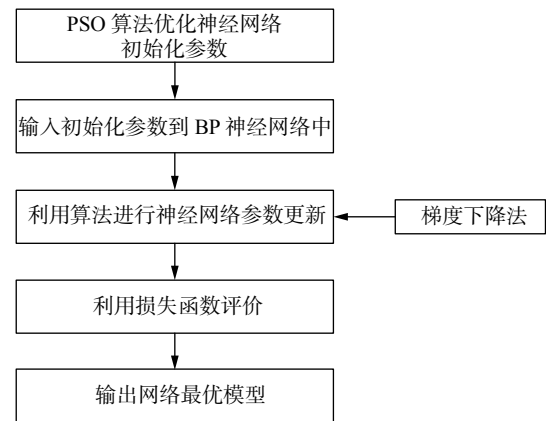
数时 PSO 算法所占比重,取值为 (0, 1);  $\nabla x$  为神经网络参数在该方向的梯度;  $c$  为神经网络中的学习率;  $x_{\text{PSO}}$  为由 PSO 算法确定的神经网络参数.

动态权重因子  $\eta$  由式(10)确定.

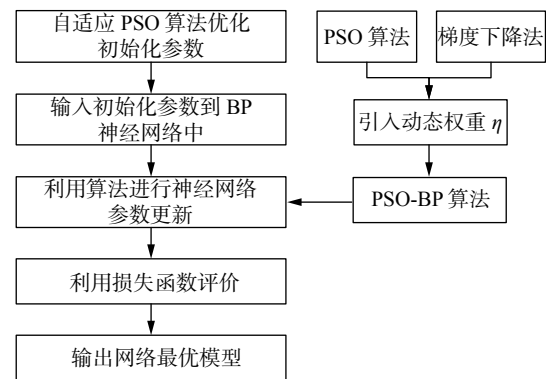
$$\eta = 1 - \frac{t}{t_{\max}} \quad (10)$$

在参数更新时,采用动态权重匹配,在更新初始阶段,动态权重接近于 1,使得算法的更新以 PSO 算法为主,此时算法能更好地进行全局搜索.当模型迭代不断进行时,动态权重系数开始线性下降,在此阶段,采用 PSO 与梯度下降法相结合的算法,使得算法训练速度和效率加快,能够稳定地找到最优的神经网络参数.

图 1 显示了传统 PSO-BP 算法流程与改进的 PSO-BP 算法流程.



(a) 传统 PSO-BP 算法



(b) 基于动态权重的自适应 PSO-BP 算法

图 1 不同算法流程

Fig. 1 Different algorithms flow. (a) traditional PSO-BP algorithm; (b) adaptive PSO-BP algorithm based on dynamic weighting

## 2 焊接缺陷成因推理机制

焊接缺陷成因诊断采用数据驱动的正向推理

策略,将缺陷特征及焊接工艺参数输入到网络的输入层神经元,求出隐藏层神经元的输出作为输出层的输入,最终得到输出层神经元的输出.采用由阈值函数判定输出层神经元的最终输出结果.取阈值为 $\varphi$ ,则将 $y_j \geq \varphi$ ( $j$ 为缺陷成因种类数,取值为 $1,2,\dots,11$ )的结果进行输出,其余的结果进行归零处理.取 $\varphi$ 为第三大值,则输出结果表示 3 种最有可能造成缺陷的原因及其置信度.具体算法流程图如图 2 所示.

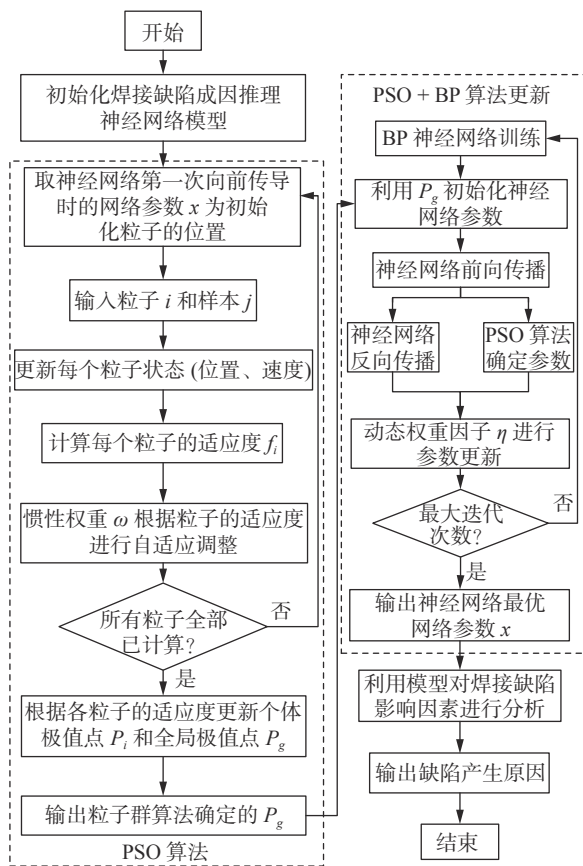


图 2 焊接缺陷成因智能诊断算法流程  
Fig. 2 Intelligent diagnosis algorithm process for welding defect causes

改进的 PSO-BP 神经网络混合算法的流程如下.

(1) 初始化 BP 网络结构,包括设定网络的输入层、隐藏层、输出层的神经元个数,损失函数和学习率等.初始化粒子群规模,包括粒子的初始位置、速度、惯性权重最大值 $\omega_{\max}$ 、惯性权重最小值 $\omega_{\min}$ 、学习因子 $c_{\max}$ 、 $c_{\min}$ 、最大迭代次数 $t_{\max}$ 、每个粒子历史最佳位置 $P_i$ 和粒子群历史最佳位置 $P_g$ 等.

(2) 根据专家系统知识库建立神经网络的拓扑结构,将神经元之间所有的连接权值和偏置编码成一维实数数组,每一个一维实数数组对应一个粒子在当前神经网络中迭代次数的初始位置.对每一个

样本而言,都可以按式 (4) 计算出粒子的适应度 $f_i$ ,并与该粒子的最小适应度 $f_{\min}$ 进行比较,若 $f_i < f_{\min}$ ,则将粒子的最小适应度 $f_{\min}$ 取值为 $f_i$ , $f_i$ 对应的位置就是最佳位置 $P_i$ ,并将惯性权重按式 (5) 进行非线性调整;若 $f_i \geq f_{\min}$ ,则将惯性权重按式 (5) 进行线性调整,最小适应度 $f_{\min}$ 及最佳位置 $P_i$ 保持不变.

(3) 利用式 (1) 更新粒子的速度 $v_{in}$ 与 $V_i$ .利用式 (2) 更新粒子的位置 $x_{in}$ 与 $X_i$ .

(4) 计算粒子群的全局最小适应度 $f_g = \min \{f_1, f_2, \dots, f_M\}$ ,若当前迭代次数达到最大迭代次数,则迭代停止;否则转到第 2 步继续更新.

(5) 输出整个粒子群所确定的神经网络参数 $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 作为神经网络结构的初值.再结合 BP 神经网络反向传播梯度下降算法,利用式 (9) 对神经网络权值和偏置进一步更新.输出改进后的 PSO-BP 算法所确定的神经网络权值和偏置,并建立最优的模型.

(6) 利用建立好的模型对焊接缺陷形成原因进行诊断,输出缺陷产生的原因,算法结束.

### 3 变量筛选及模型建立

#### 3.1 基于平均影响值的变量筛选

以 5083 铝合金中厚板脉冲焊接为例,采用焊接试验及仿真方式获取试验数据,利用 X 射线进行无损探伤,利用图像处理得到缺陷特征,并给出缺陷形成原因.通过随机设置不同的焊接工艺参数,共得到 180 组有效数据.

在实际焊接缺陷成因诊断时,涉及到的焊接参数众多,独立性较差,使得神经网络输入特征难以确定,很容易将一些不重要的特征引入进来,造成模型的精度下降,因此选择合理且重要的特征变量是十分有意义的.参考 Li 等人<sup>[14]</sup>的研究,采用平均影响值 (mean impact value, MIV) 与 BP 神经网络相结合,来筛选对缺陷成因影响灵敏度高的焊接参数进行建模. MIV 的主要原理是通过控制不同参数的变化来确定参数与预测结果的重要性.其具体计算过程为:首先基于完整训练集训练模型;再通过添加/减去每个特征向量值的 10% 的比例,生成新的输入值 $(X_1, X_2)$ ,与其它特征向量构成新的输入;使用新输入运行训练模型,计算新输出 $(Y_1, Y_2)$ 之间的差值为影响值 (IV),最后将 IV 按观测例数平均得出该自变量对应变量 MIV. MIV 的绝对值大小

代表焊接参数相对于焊接缺陷成因影响的灵敏程度, 正负值则代表相关的方向. 此时, 可将 MIV 绝对值较大的参数挑选出来进行建模, 从而实现对焊接参数的筛选. 对焊接试验涉及的 10 个焊接参数进行基于 MIV 的变量筛选, 结果如表 1 所示. 由表 1 可知, 焊接缺陷成因的影响因素主要是缺陷种类、缺陷长宽比、焊接电流、焊接电压、焊接速度、送丝速度和气体流量这 7 个变量, 其 MIV 值所占比例之和达到了 94.216%. 故将这 7 个变量作为 BP 神经网络的输入, 将缺陷形成原因作为输出, 以此构建神经网络结构.

表 1 基于 MIV 的焊接成因诊断输入特征变量灵敏度分析  
Table 1 Sensitivity analysis of input characteristic variables for welding cause diagnosis based on MIV

焊接参数	平均影响值 $\delta_{IV}$	各焊接参数 MIV 所占的比例 $\eta$ (%)
缺陷种类 $C$	0.637 5	26.042
缺陷相对中心距离 $l_1/\text{mm}$	0.060 5	2.471
两缺陷最近距离 $l_2/\text{mm}$	0.029 8	1.217
缺陷长宽比 $\delta$	-0.207 3	8.468
板厚 $b/\text{mm}$	0.051 3	2.096
焊接电流 $I/\text{A}$	0.337 2	13.775
焊接电压 $U/\text{V}$	0.570 3	23.296
焊接速度 $v/(\text{mm}\cdot\text{s}^{-1})$	-0.179 7	7.341
送丝速度 $v_s/(\text{m}\cdot\text{min}^{-1})$	0.139 9	5.715
气体流量 $Q/(\text{L}\cdot\text{min}^{-1})$	-0.234 5	9.579

### 3.2 BP 神经网络模型的建立

理论证明, 对于任何在闭区间内的一个连续函数都可以用一层隐藏层的 BP 神经网络来逼近, 因而一个单隐藏层的 BP 网络可以完成任意的  $n$  维到  $m$  维的映射<sup>[15]</sup>. 可以用图 3 所示的一个单隐藏层神经网络来搭建焊接缺陷分析模型.

对于如何确定隐藏层神经元的数目, 目前还没有明确而广泛的结论. 根据 Sheela 等人<sup>[16]</sup>综述中提到的经验公式初步确定隐藏层神经元个数  $n_h$ .

$$n_h = \text{int}\left(\frac{2}{3}n_i + \frac{2}{3}n_o\right) \quad (11)$$

式中:  $\text{int}()$  为向下取整函数;  $n_i, n_o$  分别为输入层、输出层神经元个数. 由上述隐藏层节点公式, 初步确定隐藏层神经元个数为 14.

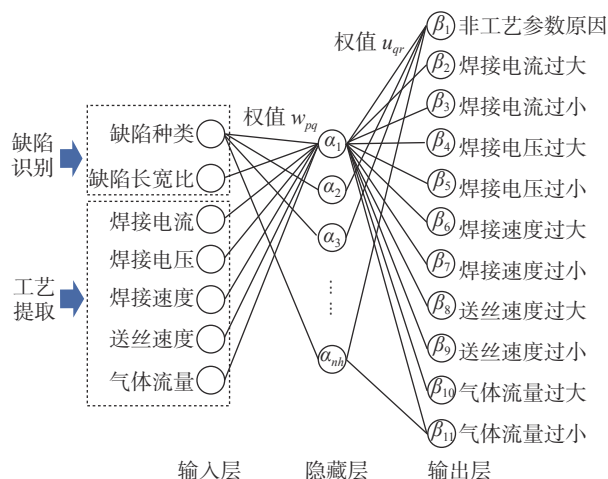


图 3 BP 神经网络焊接缺陷分析模型

Fig. 3 BP neural network model for welding defect analysis

## 4 缺陷成因诊断试验方案

### 4.1 缺陷成因诊断试验方案

试验硬件采用 Intel Core i5-9300H 处理器和 Nvidia GeForce GTX 1660Ti 独立显卡. 软件环境采用 Windows10 操作系统, 深度学习框架 Tensorflow-gpu-2.1.0. 在得到试验数据之后, 对试验数据进行预处理, 进行归一化、标准化处理, 将各个特征处于同一数量级, 从而消除奇异样本数据导致的不良影响. 将收集到的试验数据随机分为 4:1:1 作为训练集、验证集和测试集 (测试集不用于神经网络训练, 仅作为试验最后的验证). 采用改进的单隐藏层 PSO-BP 神经网络, 在使用 BP 算法的前向传播计算时, 使用  $\tanh()$  函数作为第一层的激活函数, 使用  $\text{sigmoid}()$  函数作为第二层的激活函数. 采用交叉熵作为损失函数. 为了缓解过拟合现象, 采用 Adam 正则化. 设置学习率为 0.4, 迭代 2000 次. 使用 PSO 算法时, 惯性权重最小值  $\omega_{\min} = 0.4$ , 最大值  $\omega_{\max} = 1$ , 学习因子最小值  $c_{\min} = 0.6$ , 学习因子最大值  $c_{\max} = 1.5$ , 粒子初始化的位置在  $(-1, 1)$  之间, 粒子的最大速度为 0.5.

### 4.2 网络模型结构参数选择

试验用网络结构隐藏层神经元个数初定为 14, 设置学习率为 0.4, 再采用网格搜索法, 在一定的取值范围内取多组参数值 (隐藏层神经元个数) 建立 BP 神经网络, 并利用获得的有效样本数据进行训练, 迭代 2000 次, 测试结果如图 4 所示. 从图 4 可

以看出,隐藏层神经元个数为 14 时,网络迭代 2000 次的损失函数值最低;神经元个数为 16 时,准确率 达到 93.33%,且此时的损失函数值与损失函数值最低值接近.考虑到准确率与损失函数值带来的影响,最终选择隐藏层神经元个数为 16 的单隐藏层神经网络进行模型的训练.

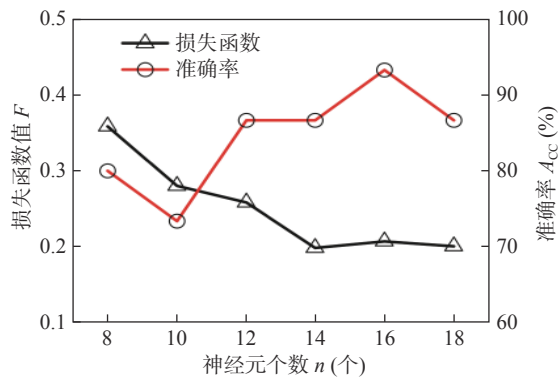


图 4 网格搜索法确定隐藏层神经元个数

Fig. 4 Grid search to determine the number of neurons in the hidden layer

### 4.3 缺陷成因诊断试验结果

#### 4.3.1 改进的 PSO-BP 算法训练结果

将经过 MIV 变量筛选后的数据放入搭建好的基于动态权重的自适应 PSO-BP 神经网络模型中,模型在训练集、验证集上的表现如图 5 所示.从图 5 可以看出,训练集与验证集的损失函数值均降至 0.5 以下.经过该网络训练后的模型,可以很好的对铝合金不同类型的焊接缺陷形成原因的进行诊断,满足焊接缺陷分析要求.

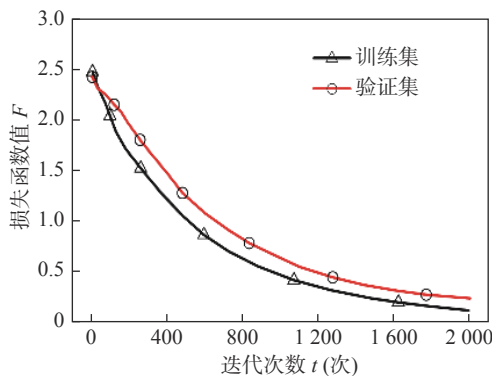


图 5 损失函数曲线

Fig. 5 Loss function curve

#### 4.3.2 不同算法的对比试验

为了验证基于动态权重的 PSO-BP 神经网络的优越性,设置 BP 神经网络和传统 PSO-BP 神经网络进行对照,在传统 PSO-BP 神经网络中,参数

设置参考王东风等人<sup>[17]</sup>的研究,设置学习因子 $c_1$ 为 2.043 4,  $c_2$ 为 0.948 7, 惯性权重 $\omega$ 为 0.729 8, 其它设置与基于动态权重的自适应 PSO-BP 神经网络保持一致.试验结果如图 6 所示.从图 6 可以看出,以损失函数值降至 0.5 以下为参考标准, BP 神经网络所需的迭代次数为 1000, 传统 PSO-BP 神经网络需要 610 次,而改进后的 PSO-BP 神经网络则只需要 530 次就能将损失函数值降至 0.5 以下,减少了 13.1%. 因此,改进后的 PSO-BP 神经网络对模型训练效率有了明显的提升.

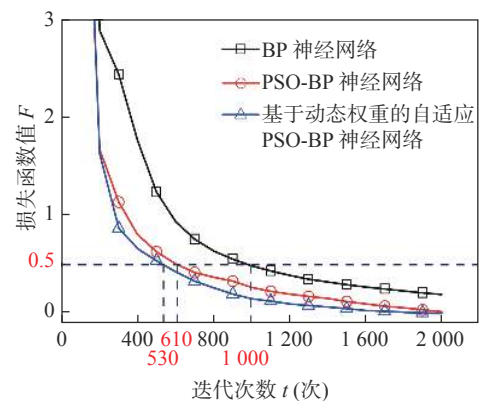


图 6 不同算法神经网络损失函数曲线

Fig. 6 Loss function curve of neural networks with different algorithms

#### 4.3.3 不同算法的预测试验

混淆矩阵也称误差矩阵,是表示精度评价的一种标准格式,用  $n$  行  $n$  列的矩阵形式来表示.混淆矩阵的每一列代表了预测类别,每一列的总数表示预测为该类别的数据的数目;每一行代表了数据的真实归属类别,每一行的数据总数表示该类别的数据实例的数目.

将测试集 30 组数据作为验证,利用训练好的改进的 PSO-BP 神经网络模型、传统 PSO-BP 神经网络模型和 BP 神经网络模型对缺陷进行诊断,缺陷形成原因混淆矩阵如图 7 所示.

图 7 中纵坐标为真实缺陷形成原因标签,横坐标为预测缺陷形成原因标签,共 10 类不同的缺陷成因分别对应数字 1~10, 1 类非工艺参数原因对应数字 0; 右侧灰色条状图表示缺陷形成原因样本量的多少,样本量越多,颜色越深,与图中方格内数字对应.每个网格对应了一组真实值和预测值,例如 (5, 5) 表示预测缺陷形成原因为第 5 类 (焊接速度过大), 真实缺陷形成原因也为第 5 类 (焊接速度过大), 网格方格中的数字 4 表示试验共有 4 组数据

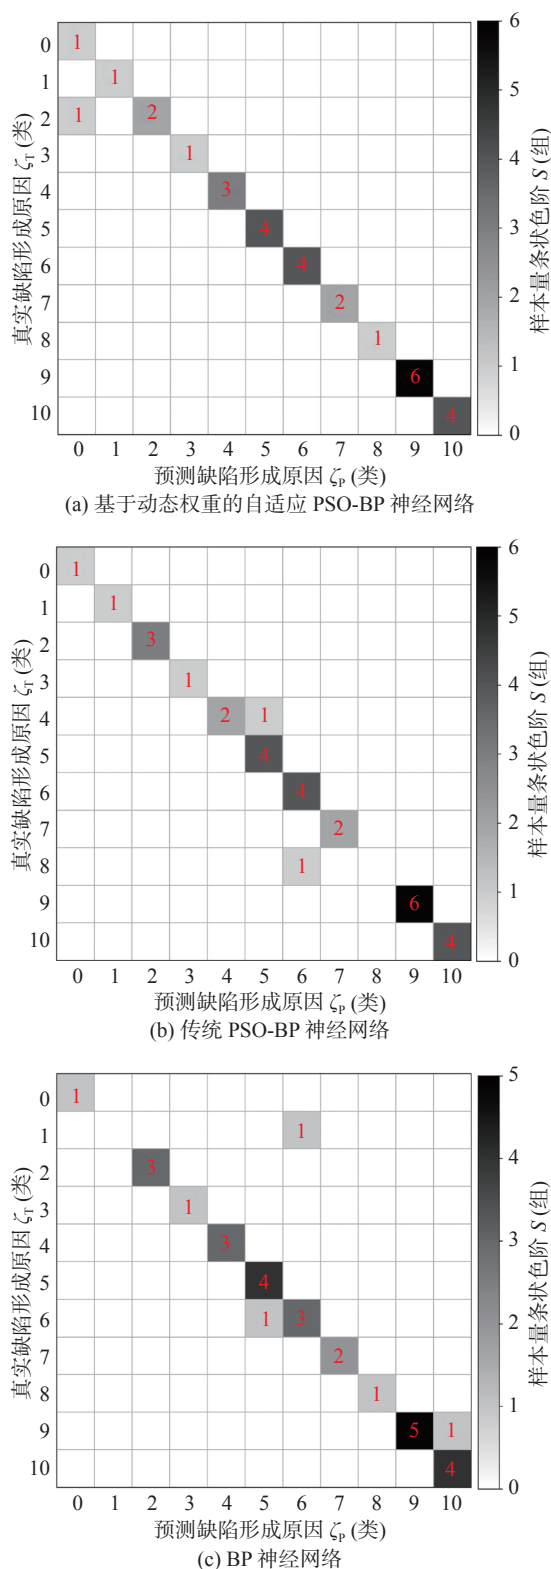


图 7 缺陷形成原因混淆矩阵对比

Fig. 7 Comparison of confusion matrix of defect causes. (a) adaptive PSO-BP algorithm based on dynamic weighting; (b) traditional PSO-BP algorithm; (c) BP neural network

为 (5, 5).

从图 7 可以看出, 改进的 PSO-BP 神经网络只有 1 组诊断错误, 剩余 29 组诊断结果均与真实缺陷

陷成因相符, 准确率为 96.67%; 传统 PSO-BP 神经网络有 2 组诊断错误, 准确率为 93.33%; BP 神经网络有 3 组诊断错误, 准确率为 90.00%.

对于二分类问题常用的评价指标是精确率和召回率. 通常以关注的类为正类, 其它类为负类, 分类器在数据集上的预测有 4 种情况:  $TP$  表示正类预测为正类;  $FP$  表示负类预测为正类;  $TN$  表示负类预测为负类;  $FN$  表示正类预测为负类.

将二分类的分类指标引入多分类问题中, 考虑到样本不均衡对结果可能带来的影响, 评价指标引入加权平均, 以精确率  $P_{\text{weighted}}$  为例.

$$P_{\text{weighted}} = \sum_{i=1}^K \lambda_i P_i = \sum_{i=1}^K \lambda_i \frac{TP_i}{TP_i + FP_i} \quad (12)$$

式中:  $K$  为类别数; 下标  $i$  表示其属于哪一类;  $\lambda_i$  表示该类在总样本数中的占比;  $P_i$  表示某类别的精确率.

表 2 为基于不同算法的缺陷成因诊断准确程度. 从分类的各评价指标可以发现, 在加权平均准确率方面, 改进的 PSO-BP 神经网络为 96.7%, 优于传统 PSO-BP 神经网络的 93.3%; 在加权平均精确率方面, 改进的 PSO-BP 神经网络为 98.3%, 优于传统 PSO-BP 神经网络的 91.3%; 在表示模型综合能力指标的  $F_1$  值上, 改进的 PSO-BP 算法为 96.9%, 优于传统 PSO-BP 算法的 91.7%.

表 2 基于不同算法的焊接缺陷成因诊断结果

Table 2 Diagnosis results of welding defects based on different algorithms

神经网络种类	加权平均评价指标			
	准确率 $A_{cc}(\%)$	精确率 $P(\%)$	召回率 $R(\%)$	综合能力 指标 $F_1(\%)$
基于动态权重的 自适应 PSO-BP	96.7	98.3	96.7	96.9
传统 PSO-BP	93.3	91.3	93.3	91.7
BP	90.0	88.0	90.0	88.6

#### 4.4 实际诊断试验

为了验证实际生产中该模型的应用效果, 随机在罐体生产中选择 5 条测试样本, 测试样本的输入特征如表 3 所示. 缺陷成因真实值及网络输出结果如表 4 所示.

以气孔缺陷 (样本 1) 诊断为例进行分析, 可以看出, 经过改进的神经网络模型的诊断, 输入的气孔缺陷有 99.51% 的可能性是由焊接速度过大造成, 有 0.38% 的可能性是由气体流量过大造成, 有

表 3 测试样本的输入特征  
Table 3 Input features of the test samples

样本编号	缺陷种类 $C$	缺陷长宽比 $\delta$	焊接电流 $I/A$	焊接电压 $U/V$	焊接速度 $v/(\text{mm}\cdot\text{s}^{-1})$	送丝速度 $v_s/(\text{m}\cdot\text{min}^{-1})$	气体流量 $Q/(\text{L}\cdot\text{min}^{-1})$
1	气孔	1.10	171.5	19.2	10.90	9.30	18
2	焊穿	8.81	180.0	20.6	9.33	10.00	20
3	未焊透	7.33	126.0	19.5	6.67	8.00	20
4	焊穿	6.49	143.5	19.6	4.00	8.00	19
5	裂纹	10.45	178.0	19.2	9.67	9.30	19

表 4 缺陷成因真实值及网络输出结果  
Table 4 Real value of defect causes and network output results

输出特征	真实值 $T(\%)$					网络输出值 $P_o(\%)$				
	样本1	样本2	样本3	样本4	样本5	样本1	样本2	样本3	样本4	样本5
非工艺参数原因	0	0	0	0	0	0	0	0	0	0
焊接电流过大	0	0	0	0	100	0	0	0	0	96.61
焊接电流过小	0	0	100	0	0	0	0	96.11	2.58	2.15
焊接电压过大	0	100	0	0	0	0	95.08	0	3.32	0
焊接电压过小	0	0	0	0	0	0	0	0	0	0
焊接速度过大	100	0	0	0	0	99.51	2.75	1.46	0	0
焊接速度过小	0	0	0	100	0	0	0	2.43	94.10	0
送丝速度过大	0	0	0	0	0	0	0	0	0	0
送丝速度过小	0	0	0	0	0	0	0	0	0	0
气体流量过大	0	0	0	0	0	0.38	0	0	0	1.24
气体流量过小	0	0	0	0	0	0.11	2.17	0	0	0

0.11% 的可能性是由气体流量过小造成。

图 8 为参数调整前后的焊缝形貌. 图 8a 显示了样本 1 优化调整前焊缝的成形情况, 焊缝处存在气

孔缺陷, 利用改进的神经网络模型进行诊断, 得出缺陷成因可能为焊接速度过大. 使用调整后的参数进行焊接, 最终得到如图 8b 中成形质量良好的焊缝, 从而证明了模型在实际生产应用中的价值.

5 结 论

(1) 针对焊接缺陷多种形成原因, 结合 BP 神经网络, 提出了基于动态权重的自适应 PSO-BP 神经网络的焊接缺陷成因智能诊断方法, 为焊接缺陷多影响因素分析及智能专家系统研发提供了新的推理思路.

(2) 与传统 PSO-BP 算法相比, 改进后的 PSO-BP 算法将损失函数值降至 0.5 以下所需的迭代次数减少了 13.1%, 模型准确率由 93.3% 提高至 96.7%, 精确率由 91.3% 提高至 98.3%, 综合能力指标由 91.7% 提高至 96.9%. 改进后的 PSO-BP 神经网络算法能有效提高缺陷形成原因诊断的效率与精度, 具有良好的工程应用价值.

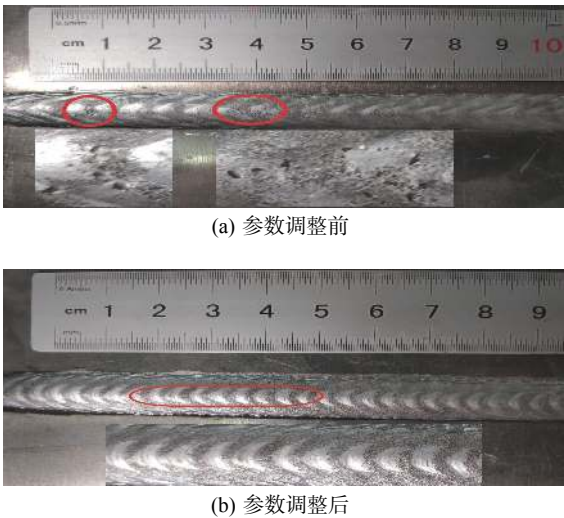


图 8 参数调整前后焊缝形貌  
Fig. 8 Weld morphology before and after parameter adjustment. (a) before parameter adjustment; (b) after parameter adjustment

## 参考文献

- [1] 吴叶军, 魏艳红. 智能化焊接 CAPP 的分析与开发 [J]. 焊接学报, 2015, 36(7): 109 – 112.  
Wu Yejun, Wei Yanhong. Analysis and development of intelligentized welding CAPP system[J]. Transactions of the China Welding Institution, 2015, 36(7): 109 – 112.
- [2] Tsoukalas V D, Kontesis M, Badogiannis E, *et al.* WELDES: An intelligent defects expert system for aluminum welding process[J]. Wseas Transactions on Information Science & Applications, 2007, 4(2): 339 – 345.
- [3] 宋燕利, 余成, 戴定国, 等. 基于 BP 和 GA 的激光焊接热源模型参数优化 [J]. 塑性工程学报, 2017, 24(1): 218 – 222.  
Song Yanli, Yu Cheng, Dai Dingguo, *et al.* Parameter optimization of heat source model for laser welding based on BP neural network and genetic algorithm[J]. Journal of Plasticity Engineering, 2017, 24(1): 218 – 222.
- [4] 邵晴, 于庆斌, 尹华, 等. 焊接热输入对高速动车组转向架侧梁焊接变形的影响及优化 [J]. 焊接学报, 2020, 41(12): 25 – 32, 48.  
Shao Qing, Yu Qingbin, Yin Hua, *et al.* Effect of welding heat input on welding deformation of bogie side beam of high-speed EMU and optimization[J]. Transactions of the China Welding Institution, 2020, 41(12): 25 – 32, 48.
- [5] Liu J, Xu G C, Ren L, *et al.* Defect intelligent identification in resistance spot welding ultrasonic detection based on wavelet packet and neural network[J]. The International Journal of Advanced Manufacturing Technology, 2017, 90(9-12): 2581 – 2588.
- [6] Li Z K, Zhao X H. BP artificial neural network based wave front correction for sensor-less free space optics communication[J]. Optics Communications, 2017, 385: 219 – 228.
- [7] 刘占军, 单宝峰, 贺平. 小波神经网络在铝合金焊接缺陷诊断中的研究 [J]. 振动、测试与诊断, 2005, 25(3): 219 – 221.  
Liu Zhanjun, Shan Baofeng, He Ping. Wavelet neural network application to diagnosing defect of aluminum alloy welding[J]. Journal of Vibration, Measurement & Diagnosis, 2005, 25(3): 219 – 221.
- [8] 姜洪权, 贺帅, 高建民, 等. 一种改进卷积神经网络模型的焊缝缺陷识别方法 [J]. 机械工程学报, 2020, 56(8): 235 – 242.  
Jiang Hongquan, He Shuai, Gao Jianmin, *et al.* An improved convolutional neural network for weld defect recognition[J]. Journal of Mechanical Engineering, 2020, 56(8): 235 – 242.
- [9] Ravi R, Aaquib R K, Chirag P, *et al.* Classification and identification of surface defects in friction stir welding: An image processing approach[J]. Journal of Manufacturing Processes, 2016, 22: 237 – 253.
- [10] Bacioiu D, Melton G, Papaeflias M, *et al.* Automated defect classification of aluminium 5083 TIG welding using HDR camera and neural networks[J]. Journal of Manufacturing Processes, 2019, 45: 603 – 613.
- [11] Zhang Z, Jia L M, Qin Y. Modified constriction particle swarm optimization algorithm[J]. Journal of Systems Engineering and Electronics, 2015, 26(5): 1107 – 1113.
- [12] 张爱华, 高佛来, 牛小革, 等. 基于 BP 神经网络的钢轨闪光对接接头灰斑面积预测 [J]. 焊接学报, 2016, 37(11): 11 – 14.  
Zhang Aihua, Gao Folai, Niu Xiaoge, *et al.* Prediction of gray-spot area in rail flash butt welded joint based on BP neural network[J]. Transactions of the China Welding Institution, 2016, 37(11): 11 – 14.
- [13] Avidan S. Ensemble tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(2): 261 – 271.
- [14] Li J Y, Men C, Qi J F, *et al.* Impact factor analysis, prediction, and mapping of soil corrosion of carbon steel across China based on MIV-BP artificial neural network and GIS[J]. Journal of Soils and Sediments, 2020, 20(8): 3204 – 3216.
- [15] 刘碧瑶. 基于 BP 神经网络的住院费用建模研究 [D]. 杭州: 浙江大学, 2006.  
Liu Biyao. Research of establishing hospitalization charge fitting model by using BP neural network[D]. Hangzhou: Zhejiang University, 2006.
- [16] Sheela K G, Deepa S N. Review on methods to fix number of hidden neurons in neural networks[J]. Mathematical Problems in Engineering, 2013(6): 425740.
- [17] 王东风, 孟丽. 粒子群优化算法的性能分析和参数选择 [J]. 自动化学报, 2016, 42(10): 1552 – 1561.  
Wang Dongfeng, Meng Li. Performance analysis and parameter selection of PSO algorithms[J]. Acta Automatica Sinica, 2016, 42(10): 1552 – 1561.

第一作者: 高昶霖, 硕士研究生; 主要研究方向为专家系统、智能制造; Email: 506070302@qq.com.

通信作者: 宋燕利, 博士, 教授, 博士研究生导师; Email: ylsong@whut.edu.cn.

(编辑: 张芷晴)