

# 融合空间和通道特征的等离子弧焊熔池熔透状态预测方法

陈宸<sup>1</sup>, 周方正<sup>2</sup>, 李成龙<sup>1</sup>, 刘新锋<sup>1</sup>, 贾传宝<sup>2</sup>, 徐瑶<sup>1</sup>

(1. 山东建筑大学, 济南, 250101; 2. 山东大学, 济南, 250100)

**摘要:** 为了提高等离子弧焊熔池熔透状态预测的准确率, 满足工业应用的需求, 提出了一种融合图像空间和通道特征的熔池熔透状态预测模型 PCSCNet。在该模型中对残差网络 (residual network, ResNet50) 结构进行改造, 并融入压缩和激励网络来同时提取熔池正面图像的空间和通道特征信息。采用恒定电流等离子弧焊试验的数据集进行测试, 建立了熔池正面图像与熔池熔透状态的对应关系。结果表明, 模型预测准确率提升到 95% 以上。采用 Grad-CAM 方法对模型进行可视化, 分析并揭示了模型预测的聚焦区域, 与实际熔池的图像特征进行对比, 验证了模型的合理性。

**创新点:** (1) 提出了一种新型的等离子弧焊熔池熔透状态预测模型, 显著提高熔池熔透状态预测精度。  
(2) 改进了残差网络模块, 新构建模型能够同步提取熔池图像的空间特征信息和通道特征信息。

**关键词:** 深度学习; 等离子弧焊; 空间和通道特征; 压缩和激励网络; 残差网络

**中图分类号:** TG 444      **文献标识码:** A      **doi:** 10.12073/j.hjxb.20220516001

## 0 序言

随着国内制造强国战略任务的提出, 信息技术与制造技术正在加速融合, 智能制造逐渐成为一种新型的生产方式<sup>[1]</sup>。焊接技术作为一种传统的材料加工连接技术, 追求高质量、高效率、高精度的发展前景, 特别是在船舶、航天设备、桥梁等大型复杂结构的制造过程中, 对中厚板焊接技术提出越来越高的要求。等离子弧具备能量密度高、电弧挺度大、等离子流力强的特点<sup>[2]</sup>, 对应开发的穿孔等离子弧焊设备具有良好的工艺性能, 接头内部缺陷率低、焊件变形小<sup>[3-4]</sup>。等离子弧焊技术可以克服传统焊接技术工艺复杂、效率低下等缺点, 提高焊接质量和生产效率, 在现代工业生产中具有极大的应用潜力。

穿孔等离子弧焊过程中, 熔池前部在持续的等离子弧作用下会形成一个贯穿工件的小孔。小孔的状态, 也称熔池熔透状态, 决定了工件是否完全熔

透, 是影响焊接过程稳定性和焊接接头质量的重要因素。在实际焊接过程中稳定穿孔焊接的规范参数范围窄, 容易造成间断性的熔透、未穿孔等质量缺陷问题, 限制了等离子弧焊技术在工业领域的广泛应用<sup>[5]</sup>。因此等离子弧焊熔池熔透状态的准确检测成为一个亟待解决的问题。在实际焊接过程中, 焊接工作者采用工业相机获取熔池图像, 提取熔池尺寸等几何特征信息, 并根据这些特征信息判断熔池熔透状态, 但这种方式容易忽略电弧状态、熔池灰度等隐含特征信息, 导致判断结果不准确。而深度学习算法<sup>[6]</sup>在图像特征提取和识别领域中表现效果优异, 为熔池熔透状态预测提供了新的思路。

近年来, 卷积神经网络 (convolutional neural network, CNN) 在传统的焊接熔池图像处理领域取得了重大进展。覃科等人<sup>[7]</sup>为了通过熔池图像对焊接状态进行判断, 提出了一种 CO<sub>2</sub> 气体保护焊熔池状态识别卷积神经网络。使用预处理的熔池图像作为网络输入, 从而避免了人工提取图像特征的主观性产生的不良影响, 同时使用 RELU 激活函数、随机 Dropout 及 SVM 分类器, 降低了样本集稀少可能产生的网络过拟合现象。虽然此网络在识别速度

和识别率方面取得了优良的性能表现, 但它只能建立熔池特征参数与熔透状态的关系, 预测仅仅依靠熔池图像的边缘信息并不能充分利用熔池内部包含的丰富信息。李海超等人<sup>[8]</sup>针对建立熔池与熔透状态的关系问题, 提出一种基于卷积神经网络的钨极气体保护焊(gas tungsten arc welding, GTAW)背面熔透预测模型, 建立了熔池边缘, 反光点位置和熔池尾部等特征与背面熔透情况的关系, 具有良好的预测效果。Li 等人<sup>[9]</sup>为了支持控制焊接接头在工业生产线上的应用, 提出了一种基于 CNN 的焊缝熔透状态识别方法。使用一种先进的熔池传感系统来同时捕捉反射的点结构激光图案和相应的焊缝背面图像, 达到较好的识别精度。

基于 CNN 在传统焊接工艺熔池图像处理上取得的优良效果, 展现了 CNN 对等离子弧焊熔池图像处理的优良前景。刘新锋<sup>[10]</sup>基于在 ImageNet 数据集上预训练的 AlexNet 网络进行迁移学习, 建立深度学习训练模型, 得到正面熔池图像特征与熔池熔透状态的内在关联, 实现了熔池熔透状态的准确预测, 模型精度达 90% 以上, 为等离子弧焊提供了一个有前景的检测方式。

尽管深度学习模型在传统焊接工艺方式下的熔池图像分类任务中具备良好表现, 但由于等离子弧焊方式下的正面熔池图像电弧干扰更大、图像细节更多、不同熔池熔透状态下的图像区分度更小, 导致结构简单的 CNN 网络难以实现更高精度的熔透状态分类效果。因此为了满足等离子弧焊实际工业应用需求, 熔透状态的分类准确率仍需要进一步提升, 基于残差激励网络的设计思想, 改进 ResNet50 网络结构, 同时提取熔池图像的空间特征信息和通道特征信息, 提出了一种融合图像空间特征信息和通道特征信息的等离子弧焊熔池熔透状态预测模型 PCSCNet, 并且使用数据预处理和数据增强的方法来处理数据集, 在等离子弧焊正面熔池图像数据集上进行模型训练和测试, 实现等离子弧焊熔池熔透状态高精度、高可靠性的预测。

## 1 数据集获取与预处理

### 1.1 数据采集与数据集建设

试验所用的等离子弧视觉检测平台示意图如图 1 所示, 由等离子弧焊系统和侧向视觉检测系统两部分组成。

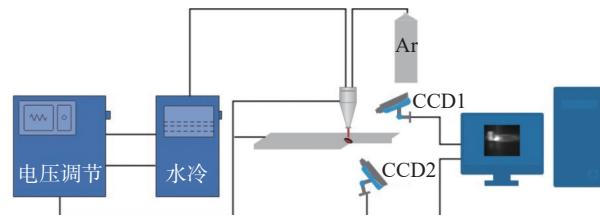


图 1 等离子弧视觉检测平台示意图

Fig. 1 Diagram of plasma arc visual detection platform

等离子弧焊时采用等离子弧焊系统进行不同参数条件下的焊接试验, 在焊接试验时采用侧向视觉检测系统同步采集实时图像。等离子弧焊系统主要包括等离子弧焊机、电源、冷却水箱、气瓶等; 侧向视觉检测系统主要包括工业 CCD 摄像机、图像采集卡、滤光片以及图像处理程序。

侧向视觉检测系统中两台工业 CCD 摄像机分别捕获正面焊接熔池和熔孔出口图像。其中 CCD1 垂直于焊缝的侧面, 用于拍摄完整、清晰的正面熔池图像, CCD2 从工件背面同步监控熔孔出口。两台工业 CCD 摄像机同时工作, 以 30 帧/s 的帧速率和 640 像素 × 320 像素的分辨率捕获图像。对厚度为 6 mm 的不锈钢板焊接过程进行拍摄, 采集卡同时采集两台工业 CCD 摄像机拍摄到的熔池图片。

该试验设计开展 16 组恒流等离子弧焊工艺试验, 试验时采用 6 mm 厚度的不锈钢板进行焊接, 采用侧向视觉检测系统捕捉清晰的正面熔池图像, 背面熔孔 CCD 检测传感装置, 获取熔池熔透状态及制备图像标签。其中, 分别设计逐渐增大焊接电流、焊接速度、等离子气体流速和电弧电压的试验, 以获取不同焊接工艺参数下熔池图像数据。16 组试验参数如表 1 所示。

试验采集共 10 176 对图像, 其中每组试验中大约采集 600 ~ 700 对图像。每对图像包括一个正面熔池图像和一个背部小孔出口图像, 组成该试验的数据集, 并按照 3:1:1 的比例分配训练集、验证集和测试集, 试验数据分布情况如表 2 所示。

### 1.2 数据预处理与数据增强

在构建数据集的过程中, 预处理是去除图像噪音的关键步骤, 同时对图像数据进行预处理可以简化数据, 提高网络模型的训练速度, 从而提升图像特征提取和识别的可靠性。工业 CCD 摄像机采集图像的原始像素值是 640 像素 × 320 像素。而根据实际观察熔池和电弧区域集中于上部图像的中心,

表 1 焊接工艺参数  
Table 1 Welding paraments

试验编号	氩气流量 $Q/(L \cdot min^{-1})$	焊接电流 $I/A$	焊接速度 $v/(mm \cdot min^{-1})$	电弧电压 $U/V$
1	2.6	125	120	29.12
2	2.6	130	120	30.06
3	2.6	135	120	30.99
4	2.6	140	120	31.93
5	2.6	145	120	32.86
6	2.6	150	120	33.80
7	2.6	125	90	35.10
8	2.6	125	100	35.24
9	2.6	125	110	35.38
10	2.6	125	120	35.52
11	2.6	125	130	35.66
12	2.4	125	120	29.79
13	2.6	125	120	30.02
14	2.8	125	120	30.24
15	3.0	125	120	30.47
16	3.2	125	120	30.69

表 2 数据集中样本数量  
Table 2 Sample quantity in data set 个

数据集	穿孔状态样本数 $n_0$	未穿孔状态样本数 $n_1$
训练集	3 267	2 801
验证集	1 088	946
测试集	1 088	946

因此为了减少熔池图像信息中的无用干扰, 把原始图像根据目标区域进行裁剪形成 371 像素  $\times$  320 像素。同时为了适应网络模型的输入形式, 在实际输入时将图像大小调整成 224 像素  $\times$  224 像素。相比于大型数据, 试验数据集 10 176 对图像的数据集容量相对较小。而数据量过小通常会使 CNN 在训练过程中出现过拟合问题, 因此为了获得更高的准确率, 使用数据增强的方法对原始数据集进行扩充, 例如缩放、翻转、旋转、放大以及亮度变化等, 从而增加样本数量。如图 2 所示。然后使用特征归一化将特征的数值缩放到一个度量相同的区间内, 消除特征之间的量纲, 避免某一特征对整体数据起到决定性的作用。并且采用线性函数归一化的方式, 将数据映射到 (0,1) 区间内, 从而达到消除量纲的目的。函数归一化方式为

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

式中:  $X_{\text{norm}}$  为函数归一化值;  $X$  为原始数据;  $X_{\min}$  为

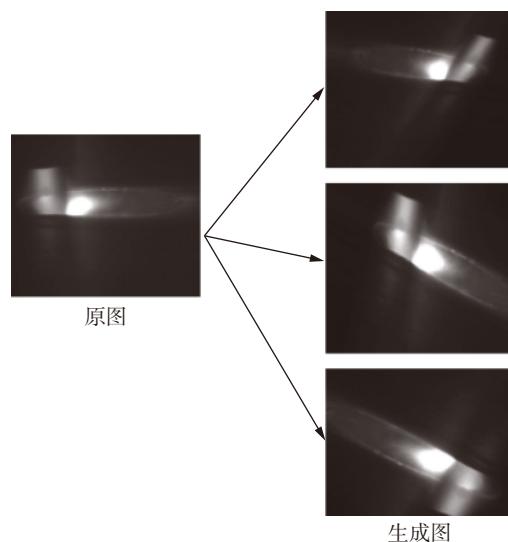


图 2 数据增强图样例  
Fig. 2 Sample diagram of data enhancement

最小值;  $X_{\max}$  为最大值。特征归一化让基于梯度优化方法的神经网络求解更快, 各个参数的更新速度一致, 从而避免更新路径呈现 Z 字型, 同时也避免了某些数值过大或过小导致的计算问题, 对各个数据之间的重要性进行平均, 避免某些特征因量纲太小而被其它特征淹没。

## 2 网络模型

### 2.1 骨干网络选型

CNN 是以卷积算子为基础搭建的神经网络, 是目前计算机视觉应用领域代表性最强、应用最广的算法之一<sup>[11]</sup>。CNN 主要的优点是可以模拟人的视觉, 以一个较小的感受野从局部提取图像的抽象特征, 经过网络连续的学习实现图像分类任务。CNN 基本结构一般由输入层、卷积层、池化层、全连接层和输出层构成, 卷积层和池化层交替设置, 之后将提取的特征图进行展平处理后形成一维的特征向量输入全连接层, 经过输出层输出结果。图 3 为一个简单的 CNN 模型结构。

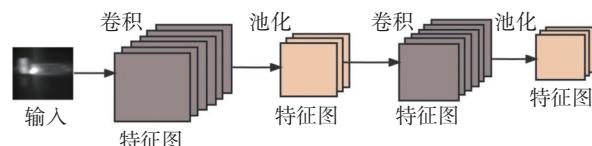


图 3 CNN 结构示意图  
Fig. 3 CNN structure diagram

在计算机视觉图像分类预测任务中模型性能是评价模型是否适合实际生产应用需求的重要指

标, 而提升网络性能的一个主要方法是增加网络深度, 但网络层数的盲目加深极容易导致网络在反向传播的时候出现梯度消失或梯度爆炸的现象。He 等人<sup>[12]</sup>提出的 ResNet 证明了深度学习网络能够继续增加网络层数, 而且残差块结构的提出有效缓解了深层网络梯度的问题。残差块单元结构如图 4 所示。

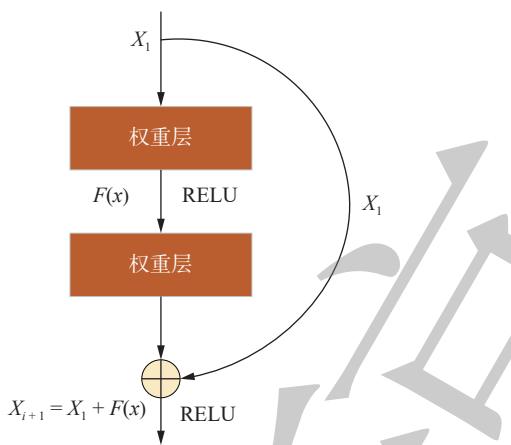


图 4 残差块单元结构

Fig. 4 Residual block element structure

ResNet50 首先经过一个卷积层和池化层, 然后经过 4 个残差块, 得到图像的特征后输入到全连接层中进行预测分类。ResNet 延续了深度卷积神经网络 (visual geometry group network, VGGNet) 中使用小卷积核堆叠扩大感受野的思想, 网络结构主要使用  $3 \times 3$  的小卷积核进行搭建。

在残差块中首先经过不会改变特征图形状的卷积, 再经过一个批量归一化层后, 使用 RELU 函数进行激活, 该条线路可以被称为主线路。残差块中的“捷径”是将输入数据  $X$  跳过这两个卷积层与主线路的输出进行元素级相加, 之后再经过一次 RELU 激活得到输出数据, “捷径”让数据能够更快

地传播并缓解了梯度消失等问题的发生。基于以上残差网络的特性, 选用 ResNet50 作为模型的骨干网络。由于等离子弧焊过程中产生的弧光会导致熔池图像特征的淹没, 干扰模型空间特征的提取。并且在等离子弧焊的工业生产过程中需要同时考虑预测精度和预测速度的实际问题。需要对骨干网络进行改进, 以满足熔池图像检测的需要。

## 2.2 通道特征提取模块

传统神经网络中的卷积变换, 是将各个通道的卷积结果进行求和之后进行输出, 即

$$\mathbf{U} = F(\mathbf{X}) = \sum_{i=1}^C v_c^i x^i \quad (2)$$

式中:  $\mathbf{U}$  为该层最终的输出矩阵,  $\mathbf{U} \in R^{H \times W \times C}$ ;  $\mathbf{X}$  为对应层输入特征矩阵,  $\mathbf{X} \in R^{H \times W \times C}$ ;  $F$  为由  $\mathbf{X}$  转为  $\mathbf{U}$  的卷积操作;  $v_c^i$  为一个卷积核, 用于学习特征空间关系, 但传统卷积计算是对各个通道的卷积结果直接进行相加, 通道特征关系与卷积核学习到的空间特征关系结合在一起。这种传统卷积计算中的卷积操作只是实现对图像空间上的特征融合, 没有考虑到不同通道间的特征融合, 由于每个通道的重要程度不同, 通道特征也是极为关键的分类特征。

为了优化传统卷积忽略特征图通道信息的问题, Hu 等人<sup>[13]</sup>提出了一种压缩和激励网络 (squeeze and excitation network, SENet), 其主要模块压缩-激励 (squeeze and excitation, SE) 模块结构如图 5 所示, 能够在保持原通道数并且不引入新的特征维度的情况下, 充分利用特征通道间的关系, 并利用反向传播学习每个特征通道的权重系数, 该权重系数代表着该通道的重要程度, 不同重要程度的通道配置不同的权重, 最后按照权重大小去提升对分类重要的特征, 抑制对分类无用的特征, 以此来提升网络分类性能。

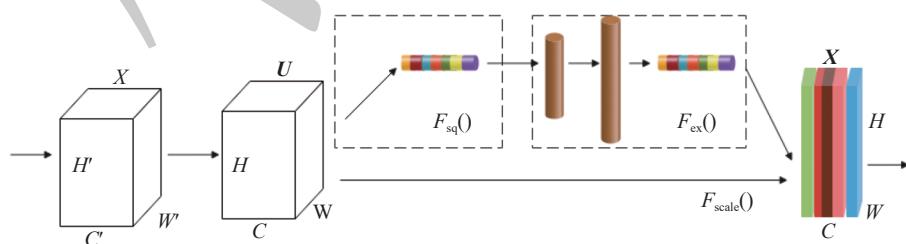


图 5 SE 模块的总体结构

Fig. 5 Overall structure of SE module

首先是压缩操作, 为了使网络模型学习特征通道的信息, 将得到的特征图  $\mathbf{U}$  沿空间维度的方向进

行特征压缩, 将每个特征通道都压缩成一个实数, 从而利用这个实数来代表所对应的特征通道的全

局分布。因此特征图  $\mathbf{U}$  中的  $C$  个特征通道的特征图变成了  $1 \times 1 \times C$  的特征图, 压缩操作输出的实数数量与输入的特征通道数量相同。该操作即为图 5 中的  $F_{\text{sq}}()$ 。

$$Z = F_{\text{sq}}(\mathbf{U}) = \frac{1}{W \times H} \sum_{i=1}^W \sum_{j=1}^H u_c(i, j) \quad (3)$$

式中:  $Z$  为压缩操作后的结果;  $W, H$  为输入特征图的尺寸;  $C$  为输入特征图的通道数;  $u_c(i, j)$  则代表输入特征图第  $C$  个通道中第  $i$  行第  $j$  列的值。

通过压缩操作得到了全局描述特征, 接下来为了学习通道之间的非线性关系, 从而降低模型复杂度以及提升模型的泛化能力, SENet 提出了激励操作, 通过引入一个参数  $W_t$  来为每个特征通道生成相应权重, 权重的不同代表着特征通道的重要程度的不同, 即图 5 中的  $F_{\text{ex}}()$ 。

$$S = F_{\text{ex}}(Z, W_t) = \sigma[(W_2 \delta(W_1 Z))] \quad (4)$$

式中:  $\delta$  和  $\sigma$  分别代表激活函数 RELU 和 sigmoid。

将压缩和激励两个操作学习到的各个通道的激活值  $S$  乘以  $\mathbf{U}$  的原始特征来实现特征通道的重标定, 即图 5 中的  $F_{\text{scale}}()$  操作。

$$\tilde{\mathbf{X}} = F_{\text{scale}}(\mathbf{U}, S) = S \mathbf{U} \quad (5)$$

式中:  $\tilde{\mathbf{X}} \in R^{H \times W \times C}$  为 SE 模块的输出矩阵。

SENet 模块让模型可以更加关注对分类性能影响最大的通道特征, 而抑制那些不重要的通道特征, 从而实现对一个局部区域通道上的特征融合。

### 2.3 骨干网络优化

等离子弧焊工业生产过程中需要及时准确地对熔池状态进行预测, 因此为了适应等离子弧焊的工业应用需求, 需要综合考虑模型的精度和运算速度。因此对 ResNet50 模型进行改造, 来进行熔池图像的空间特征提取, 使其获得在运算速度和精度上的综合提升。ResNet50 网络结构由输入阶段、四个子序列阶段与模型输出阶段组成。

为了提升 ResNet50 模型的计算速度, 对模型的输入部分进行调整, 如图 6 所示。在输入阶段, 设计使用 3 个  $3 \times 3$  的卷积核来代替原本  $7 \times 7$  的卷积核。卷积的计算消耗是卷积核长宽的二次函数<sup>[14]</sup>, 因此一个  $7 \times 7$  的卷积比一个  $3 \times 3$  的卷积计算量大 5.4 倍, 通过这种改进可以显著地提高计算速度。

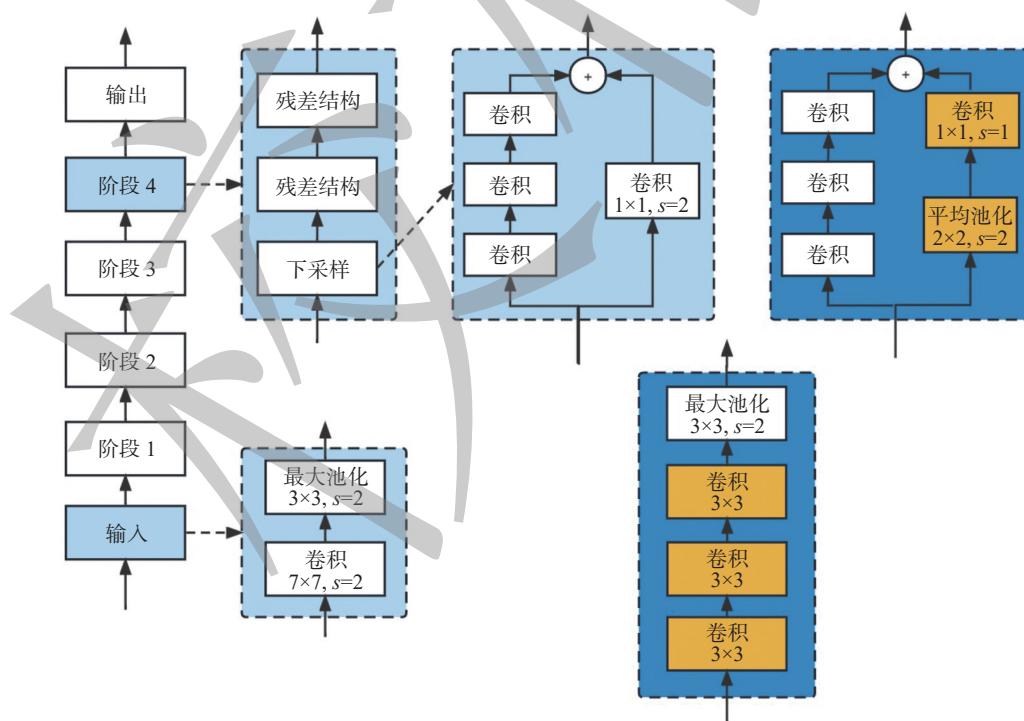


图 6 ResNet50 模型改进  
Fig. 6 ResNet50 model improvement

对于模型性能, 通常认为模型提取的特征越多, 相应的模型性能会更好。而原始的 ResNet 模型在残差结构中采用的是步长为 2 的  $1 \times 1$  卷积进行

下采样, 这种卷积会忽略  $3/4$  的特征映射<sup>[14]</sup>, 针对于模型的这种问题, 将  $1 \times 1$  的卷积步长改为 1, 并在卷积前添加步长为 2 的  $2 \times 2$  的全局池化层, 使

模型在不改变输出形状的基础上,不忽略特征信息,从而提高模型特征提取能力。

为了使模型在提取熔池图像的空间特征的同时,能够提取图像的通道特征,将 Se-block 嵌入到 50 层的深度残差网络结构中,在 ResNet50 网络结构中 Se-block 使用全局平均池化来对特征图进行压缩,对特征图中每个通道生成相应权重,然后使用两个全连接层来实现激励操作,用于表达不同特征通道间的相关性和依赖性。其中为了减少模型的计算量同时保持特征通道数不变,设置压缩参数为 1/16 来对第一个全连接层进行降维,压缩后的特征图通过 RELU 激活函数后,输入第二个全连接层中,第二个全连接层设置压缩参数为 16,来对通道数进行还原。使用 sigmoid 函数将权重归一化后将其与原始特征图进行加权,实现通道维度上的特征重标定。Se-ResNet50 网络中残差模块结构如图 7 所示。

对于 Se-block 模块在 ResNet50 网络结构中的嵌入位置,设计在每个 bottle neck 结构后都插入 Se-block 模块。而 ResNet 的网络结构中的 bottle

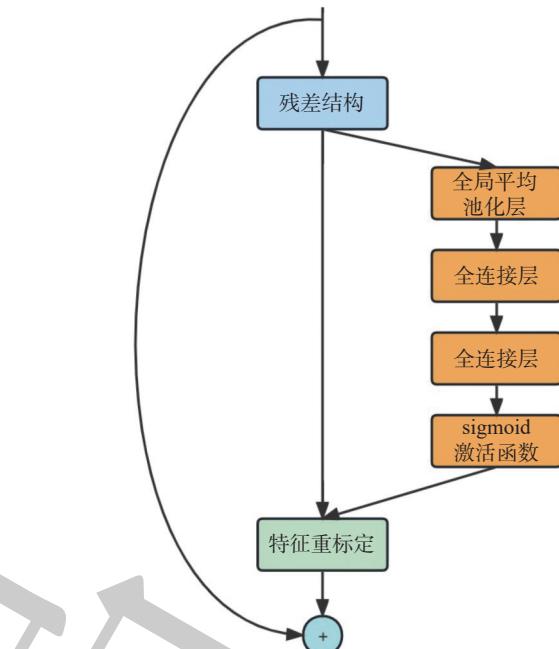


图 7 Se-block 结构

Fig. 7 Se-block structure

neck 具有两种不同的形式,如图 8 所示,分别为 4 个子序列第一个阶段的具有降维作用的 bottle neck 1 和其它阶段的 bottle neck 2 结构。



图 8 Se-block 嵌入位置  
Fig. 8 Se-block embedding location

### 3 试验结果与分析

试验使用的计算配置如下:64 位的 Windows 10 操作系统,192 G RAM,CPU 为 Intel Xeon Silver 4110@2.10 GHz,GPU 为 NVIDIA GeForce TITAN Xp 12 GB。试验环境为:Python = 3.6, TensorFlow-gpu = 1.13.1,Keras = 2.2.4。

#### 3.1 模型评价指标

评价指标是衡量模型性能的标准,对等离子弧熔池熔透状态的分类预测使用的评价指标有准确率( $A$ )、精度( $P$ )、召回率( $R$ )、 $F_1$ 指数值( $F_1$ ),即

$$A = \frac{T_P + T_N}{T_P + F_P + T_N + F_N} \quad (6)$$

$$P = \frac{T_P}{T_P + F_P} \quad (7)$$

$$R = \frac{T_P}{T_P + F_N} \quad (8)$$

$$F_1 = 2 \frac{PR}{P+R} \quad (9)$$

式中: $T_P$ (true positives) 代表真正例,即被正确预测为正例的个数; $F_N$ (false negatives) 代表假负例,即被错误预测为负例的个数; $F_P$ (false positives) 代表假正例,即被错误预测为正例的个数; $T_N$ (true negatives) 代表真负例,即被正确预测为负例的个数。

#### 3.2 试验参数设计与分析

在深度学习的模型训练过程中,采用的优化方法、学习率和迭代次数等是一个重要的初始选择的设置,模型的调参是一个重要的过程。为了找到模型最优的参数设置,在提出的 PCSCNet 模型上进行不同的参数对照试验,结果如表 3 所示。经过试验对比,该试验过程中的最优参数设置为:epoch = 100, batch\_size = 32,  $l_r = 0.0001$ 。损失函数选用 binary\_crossentropy, 优化器选用 Adam。同时为了提高模型的准确率以及降低损失值,优化器在设置

了初始学习率后采用自动降低学习率的方法来调节学习率, 设置缩放学习率的值为 0.2, 学习率将以  $l_r = l_r f$  的形式被减少,  $f$  为学习率缩放因子, 设置检测值为 val\_loss, 经过 20 个 epoch 后模型性能若不再提升, 则会触发学习率衰减, 直到设置的 epoch 训练完或学习率达到设置的最低值 0.000 01 时, 学习率衰减函数才会停止运行.

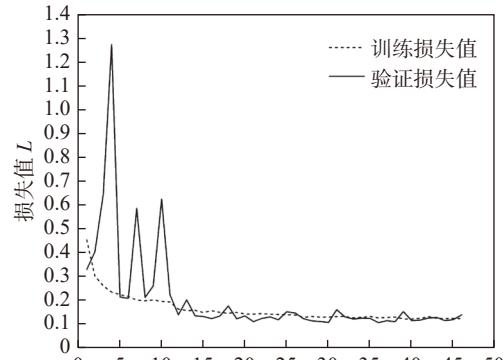
表 3 试验参数设置  
Table 3 Experimental parameter setting

试验编号	优化器	学习率 $l_r$	批大小 $p$	迭代次数 N/次	精度 P(%)
1	SGD	0.001	32	100	59.14
2	Adam	0.001	32	100	95.47
3	Adam	0.01	32	100	53.56
4	Adam	0.000 1	32	100	95.84
5	Adam	0.000 1	64	100	95.57
6	Adam	0.000 1	16	100	95.28
7	Adam	0.000 1	32	200	95.17
8	Adam	0.000 1	32	50	95.15

在模型训练过程中, 希望更好地拟合数据以获得最好地泛化性能, 但网络模型训练过程中很容易过拟合. 通常情况下, 用模型在验证集上的表现来评估模型的泛化能力. 随着网络的不断训练优化, 期望模型在训练集上的损失值不断降低, 精度不断提升的同时, 模型在验证集上也有同样良好的表现. 反之, 当模型在训练集上表现良好, 但在验证集上表现较差时, 一般是模型出现了过拟合的现象. 解决过拟合的问题主要有两个方向: 一种是降低参数的数量, 主要是剪枝<sup>[15]</sup> 和权重共享<sup>[16]</sup>, 另一种是降低每个参数维度的有效规模, 主要是正则化的方法, 如权重衰减和早停法<sup>[17]</sup> 等. 试验中采用早停法来解决过拟合的问题. 通过迭代次数截取的方法, 在模型对训练数据集迭代收敛之前停止迭代来防止过拟合. 把验证集的损失值作为模型监测性能的指标. 设置模型在 20 次迭代之后没有改进便早停来结束训练. 图 9 为 PCSCNet 模型的训练验证准确率曲线和训练验证损失曲线.

### 3.3 消融试验设计与分析

为了验证通道注意力模块和 ResNet50 改进结构等组件的作用, 设计了消融试验. 以 ResNet50 网络作为基准方法, 在此基础上依次增加通道特征提取模块 (SE-ResNet50) 和 ResNet50 改进结构



(a) PCSCNet 训练验证损失

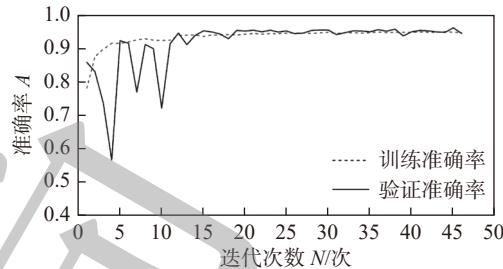


图 9 模型训练曲线

Fig. 9 Model training curve. (a) loss of PCSCNet training and validation; (b) accuracy of PCSCNet training and validation

(PCSCNet). 两种组合在等离子弧熔池图像数据集上的表现如表 4 所示.

表 4 不同网络结构对预测性能的影响  
Table 4 Effects of different network structures on prediction performance

模型名称	准确率 $A$	精度 $P$	召回率 $R$	$F_1$	%
ResNet50	93.02	93.24	89.17	91.16	
SE-ResNet50	94.64	94.81	94.71	94.76	
PCSCNet	95.55	93.42	96.19	94.79	

由表 4 可知, 通道注意力模块能够提高熔池图像特征提取能力, 相比于原始网络在预测准确率和  $F_1$  指标上分别提升了 1.62% 和 3.60%. 而 ResNet50 改进结构可以进一步提升预测性能, 在预测准确率和  $F_1$  指标上分别提升了 0.91% 和 0.03%. ResNet50 模型在融合了通道注意力模块和 ResNet50 改进模块后, 在等离子弧熔池图像数据集上预测准确率和  $F_1$  指标上分别达到了 95.55% 和 94.79%.

### 3.4 模型对比分析

为了证明提出的模型效果, 在等离子弧焊熔池图像数据集上设计一组试验, 使用几种经典的图像分类方法 AlexNet-trans, VGG16, ResNet50,

InceptionNetV3<sup>[18]</sup>与提出的PCSCNet模型进行训练测试,并对比这5种模型在等离子弧焊熔池图像数据集上的性能表现。

表5展示了5种模型在熔池图像测试集中的综合表现,在评估模型性能好坏的时候,采用准确率、精度、召回率和 $F_1$ 作为模型的综合评价指标。其中baseline模型来自文献[19]基于Alexnet网络和迁移学习设计的熔透状态预测模型,是深度学习在等离子弧焊领域应用的最新进展。从表中可以看出PCSCNet模型在各个评价指标中都表现最好。特别是对比于baseline模型,PCSCNet模型在准确率上有0.95%的提升,同时在F1综合指标上有8.31%的提升。展现了PCSCNet模型不仅在预测准确率上有良好的表现,而且在综合性能上也具有显著的优越性。

表5 模型在测试集上的性能表现

Table 5 Performance of the model on the test set %

模型名称	准确率A	精度P	召回率R	$F_1$
VGG16	90.28	88.50	92.80	90.60
ResNet50	93.02	93.24	89.17	91.16
InceptionNetV3	94.59	91.28	97.16	94.27
PCSCNet	95.55	93.42	96.19	94.79
AlexNet-trans	94.60	80.00	94.10	86.48

### 3.5 模型可行性分析

为了适应工业场景的应用,现场运行环境复杂,需要验证模型性能的可行性与可解释性,图10为正面熔池图像的主要特征点。等离子弧焊熔池主要是由熔池前端、等离子弧、等离子云和熔池后端4个部分组成。根据传统的人工经验,等离子弧焊的熔池熔透状态的差别主要在等离子弧和等离子云部分,熔池前端与熔池后端同样有部分差异,但差别较小。所以传统焊接过程中的穿孔状态的判断

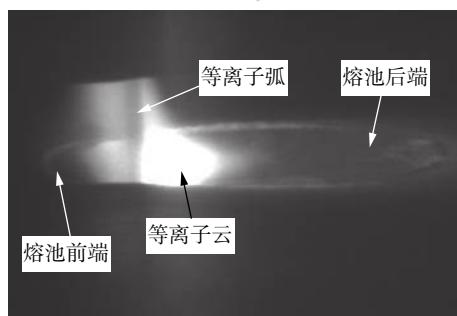


图10 正面熔池图像特征

Fig. 10 Front molten pool image feature

主要依赖于观察等离子弧与等离子云的特征变化。

为了验证PCSCNet模型的可行性,使用Grad-CAM<sup>[20]</sup>方法对其进行视觉上的可视化解释,来显示模型的分类依据,该方法使用包含有最多特征信息的最后一个卷积层为模型中每个神经元分配权重,进行特定的关注决策。通过生成与卷积特征图大小相同的热力图来表示不同特征对分类的影响程度。热力图中越红的区域代表对分类决策的影响越大,越蓝的区域则代表对分类决策的影响越小。

图11为Grad-CAM可视化结果。图11a为原始正面熔池图像,图11b为生成的相同大小的热力图,图11c为原始图像与热力图融合后的图像。从可视化结果可以看出,红色区域主要集中在熔孔入口附近,说明模型分类过程中主要关注于正面熔池图像的等离子弧和等离子云部分区域,这与实际焊接过程中的经验特征信息相符,验证了模型的可靠性。

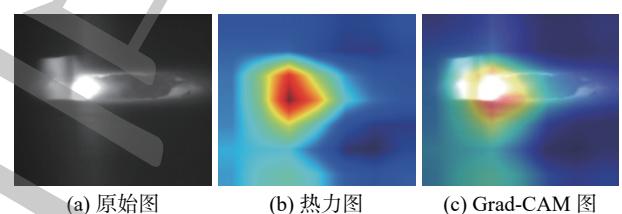


图11 Grad-CAM 可视化结果

Fig. 11 Grad-cam visualization results. (a) original diagram; (b) thermodynamic diagram; (c) Grad-CAM diagram

## 4 结论

(1) 针对等离子弧焊的实际应用场景,通过对ResNet50的输入和残差结构进行更改并同步提取熔池图像的空间和通道特征信息,提出了一种新型的等离子弧焊熔池熔透状态预测模型PCSCNet。模型熔透状态预测准确率达到95%以上。

(2) 使用一种基于梯度定位的深度网络可视化方法Grad-CAM来可视化模型的分类依据,与人工焊接过程中的经验特征信息相符,体现了模型熔透状态预测的依据是正确的,验证了模型的可行性。

## 参考文献

- [1] 陈健,苏金花,张毅梅.《中国制造2025》与先进焊接工艺及装备发展[J].*焊接*,2016(3):1-5.

- Chen Jian, Su Jinhua, Zhang Yimei. 《Made in China 2025》 and the development of advanced welding technology and equipment[J]. Welding & Joining, 2016(3): 1 – 5.
- [2] 忻建文, 吴东升, 李芳, 等. 小孔型等离子弧焊条形气孔形成机理 [J]. 焊接学报, 2021, 42(12): 54 – 61,86.
- Xin Jianwen, Wu Dongsheng, Li Fang, et al. Formation mechanism of strip porosity in small hole plasma arc welding[J]. Transactions of the China Welding Institution, 2021, 42(12): 54 – 61,86.
- [3] 武传松, 赵晨昱, 贾传宝. 穿孔等离子弧焊接工艺研究进展 [J]. 航空制造技术, 2015, 58(20): 34 – 39.
- Wu Chuansong, Zhao Chenyu, Jia Chuanbao. Research progress of piercing plasma arc welding process[J]. Aeronautical Manufacturing Technology, 2015, 58(20): 34 – 39.
- [4] 何建萍, 吴鑫, 吉永丰, 等. 100 μm 超薄不锈钢板脉冲微束等离子弧焊成形机理 [J]. 焊接学报, 2021, 42(6): 77 – 84.
- He Jianping, Wu Xin, Ji Yongfeng, et al. 100 μm forming mechanism of pulsed micro beam plasma arc welding of ultra-thin stainless steel plate[J]. Transactions of the China Welding Institution, 2021, 42(6): 77 – 84.
- [5] 李挺, 黄健康, 陈秀娟, 等. 旁路耦合微束等离子弧热特性及焊缝成形特点 [J]. 焊接学报, 2018, 39(9): 55 – 60.
- Li Ting, Huang Jiankang, Chen Xiujuan, et al. Thermal characteristics and weld forming characteristics of bypass coupled micro beam plasma arc[J]. Transactions of the China Welding Institution, 2018, 39(9): 55 – 60.
- [6] 刘建伟, 刘媛, 罗雄麟. 深度学习研究进展 [J]. 计算机应用研究, 2014, 31(7): 1921 – 1942.
- Liu Jianwei, Liu Yuan, Luo Xionglin. Research progress of deep learning[J]. Application Research of Computers, 2014, 31(7): 1921 – 1942.
- [7] 覃科, 刘晓刚, 丁立新. 基于卷积神经网络的 CO<sub>2</sub> 焊接熔池图像状态识别方法 [J]. 焊接, 2017(6): 21 – 26.
- Tan Ke, Liu Xiaogang, Ding Lixin. State recognition method of CO<sub>2</sub> welding pool image based on convolution neural network[J]. Welding & Joining, 2017(6): 21 – 26.
- [8] 李海超, 刘景凤, 谢吉兵, 等. 基于卷积神经网络的 GTAW 熔透预测 [J]. 机械工程学报, 2019, 55(17): 22 – 28.
- Li Haichao, Liu Jingfeng, Xie Jibing, et al. GTAW penetration prediction based on convolutional neural networks[J]. Journal of Mechanical Engineering, 2019, 55(17): 22 – 28.
- [9] Li C, Wang Q, Jiao W, et al. Deep learning-based detection of penetration from weld pool reflection images[J]. Welding Journal, 2020, 99(9): 239s – 245s.
- [10] 刘新锋. 基于正面熔池图像和深度学习算法的 PAW 穿孔/熔透状态预测 [D]. 济南: 山东大学, 2017.
- Liu Xinfeng. Prediction of PAW perforation/penetration state based on frontal molten pool image and depth learning algorithm[D]. Jinan: Shandong University, 2017.
- [11] Gu J, Wang Z, Kuen J, et al. Recent advances in convolutional neural networks[J]. Pattern Recognition, 2015, doi: [10.48550/arXiv.1512.07108](https://doi.org/10.48550/arXiv.1512.07108).
- [12] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA, 2016: 770 – 778.
- [13] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA, 2018: 7132 – 7141.
- [14] He T, Zhang Z, Zhang H, et al. Bag of tricks for image classification with convolutional neural networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Angeles, USA, 2019: 558 – 567.
- [15] Han S, Jeff P, John T, et al. Learning both weights and connections for efficient neural networks[C]//NIPS'15: 28th International Conference on Neural Information Processing Systems. MIT Press Cambridge, USA, 2015: 1135 – 1143.
- [16] Pham H, Guan MY, Zoph B, et al. Efficient neural architecture search via parameters sharing[C]//International Conference on Machine Learning. PMLR, Stockholm, Sweden, 2018: 4095 – 4104.
- [17] 吕国豪, 罗四维, 黄雅平, 等. 基于卷积神经网络的正则化方法 [J]. 计算机研究与发展, 2014, 51(9): 1891 – 1900.
- Lyu Guohao, Luo Siwei, Huang Yaquan, et al. Regularization method based on convolution neural network[J]. Journal of Computer Research and Development, 2014, 51(9): 1891 – 1900.
- [18] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA, 2016: 2818 – 2826.
- [19] Jia C B, Liu X F, Zhang G K, et al. Penetration/keyhole status prediction and model visualization based on deep learning algorithm in plasma arc welding[J]. The International Journal of Advanced Manufacturing Technology, 2021, 117(11): 3577 – 3597.
- [20] Selvaraju R R, Cogswell M, Das A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization[C]//IEEE International Conference on Computer Vision and Pattern Recognition. Hawaii, USA, 2017: 618 – 626.

**第一作者:** 陈宸, 硕士; 主要从事工业大数据研究; Email: 819221454@qq.com.

**通信作者:** 刘新锋, 博士, 副教授; Email: liuxinfeng18@sdu.edu.cn.