

基于轻量级 PSPNet 网络的 TIG 焊熔池测量方法^①



林雨浩¹, 黎振龙², 赵运强², 邹 鹏¹, 奥列格·格纽申科³, 亚历山大·沃伊捷克³

¹(五邑大学 广东省摩托车先进设计与制造工程技术研究中心, 江门 529020)

²(广东省科学院 中乌焊接研究所 广东省材料连接与先进制造重点实验室, 广州 510650)

³(乌克兰国家科学院 乌克兰巴顿焊接研究所, 基辅 03150)

通信作者: 赵运强, E-mail: zhaoyq@gwi.gd.cn; 邹 鹏, E-mail: zonepeng@163.com

摘 要: 针对 TIG 焊接过程中强弧光、烟尘、极端热辐射等复杂工况, 以及液态金属动态流动引起的熔池区域反射特性不稳定对熔池视觉特征提取造成干扰的问题, 本研究提出一种改进型熔池测量方法, 包括基于注意力机制与多尺度特征融合的轻量级网络熔池分割方法和基于分割结果的闭运算、连通区域标记和最小外接矩形图像处理办法. 结果表明, 改进后的网络在自建熔池分割数据集上取得性能提升, 平均交并比 (*MIoU*) 达 95.44%, 平均像素精度 (*mPA*) 为 98.27%, 单帧推理耗时仅为 11.30 ms, 且有效提取所分割熔池的长度、宽度和面积.

关键词: 语义分割; PSPNet; TIG 焊; 熔池; 尺寸测量

引用格式: 林雨浩, 黎振龙, 赵运强, 邹鹏, 奥列格·格纽申科, 亚历山大·沃伊捷克. 基于轻量级 PSPNet 网络的 TIG 焊熔池测量方法. 计算机系统应用, 2026, 35(1): 246-254. <http://www.c-s-a.org.cn/1003-3254/10052.html>

Lightweight-PSPNet-based Molten Pool Measurement Method for TIG Welding

LIN Yu-Hao¹, LI Zhen-Long², ZHAO Yun-Qiang², ZOU Peng¹, Oleg GANUSHCHAK³, Oleksandr VOITENKO³

¹(Guangdong Advanced Design and Manufacturing Engineering Technology Research Center for Motorcycles, Wuyi University, Jiangmen 529020, China)

²(Guangdong Provincial Key Laboratory of Material Joining and Advanced Manufacturing, China-Ukraine Institute of Welding, Guangdong Academy of Sciences, Guangzhou 510650, China)

³(E.O. Paton Electric Welding Institute, National Academy of Sciences of Ukraine, Kyiv 03150, Ukraine)

Abstract: There is interference caused by complex working conditions such as strong arc light, smoke and dust, and extreme thermal radiation during the TIG welding, and interference for visual feature extraction of the molten pool due to the reflection characteristic instability of the molten pool region caused by the dynamic flow of liquid metal. In view of this, this study proposes an improvement method for molten pool measurement, which includes a lightweight network molten pool segmentation method based on the attention mechanism and multi-scale feature fusion, and an image processing method of closing operation, connected region labeling, and the minimum bounding rectangle based on the segmentation results. The results show that the improved network has enhanced performance on the self-built molten pool segmentation datasets. The mean intersection over union (*MIoU*) reaches 95.44%, the mean pixel accuracy (*mPA*) is 98.27%, and the inference time for a single frame is only 11.30 ms. Additionally, the length, width, and area of the segmented molten pool are effectively extracted.

Key words: semantic segmentation; PSPNet; TIG welding; molten pool; size measurement

① 基金项目: 国家重点研发计划 (2023YFE0201500); 广东省重点人才计划 (2023TQ07C702); 阳江市科技计划 (RCZX2024006); 广东省科学院青年人才专项杰出青年项目 (2024GDASQNR-0103)

收稿时间: 2025-06-17; 修改时间: 2025-07-07, 2025-08-01; 采用时间: 2025-08-15; csa 在线出版时间: 2025-11-04

CNKI 网络首发时间: 2025-11-05

钨极惰性气体保护焊 (TIG) 凭借其电弧稳定性和熔池可控性, 在航空装备、汽车工业等高精度制造环节中占据重要地位. 然而, 面对复杂焊接场景时, 实现熔池的实时分割仍面临多维度挑战^[1].

目前, 研究人员探索了多种监控 TIG 焊接过程的熔池形态的方法, 主要分为两类: 基于传统图像算法和基于主动轮廓模型方法^[2]. Liu 等^[3]对比 6 种不同边缘检测算子的结果, 最终确定采用某阈值 Canny 算子获取熔池理想边缘特征. Chen 等^[4]利用传统图像处理算法提取熔池的宽度、长度和表面高度, 并将这些数据用作网络模型的输入变量预测熔池背面宽度. Wang 等^[5]采用加权中值滤波器进行图像去噪, 结合双阈值分割和边缘细化的方法提取熔池轮廓, 并用 BP 网络对轮廓边缘进行优化. Wang^[6]提出一种新颖的成像与测量系统, 利用激光图案和结构光技术, 实现熔池三维形状一次性高精度重建. 然而, 由于焊接电弧光强度波动、熔池表面反射特性复杂以及环境中其他噪声源的干扰等因素, 熔池形态呈现动态变化特性. 其几何轮廓表现为圆形、椭圆形或不规则形状, 且随焊接过程持续动态演变; 同时, 焊接电流、电压、速度及保护气体流量等工艺参数的波动会显著影响熔池尺寸与形貌特征. 上述多因素干扰导致传统图像处理方法难以有效提取熔池轮廓^[7].

近年来, 一些研究人员积极探索深度学习在 TIG 焊接过程监测中的应用. Fang 等^[8]构建 U-Net 网络提取熔池形态, 以相对较低的平均计算耗时 (仅 37 ms) 达到了较高的 *MIoU* 值. Zhang 等^[9]提出一种集成深度学习与增强视觉技术的实时缺陷检测系统, 成功应用于锁孔 TIG 焊接场景. Lu 等^[10]提出一种基于视觉传感

器和深度残差网络的余高与熔深协同预测方法, 其预测平均误差小于 0.09 mm. Wang 等^[11]采用基于 ViT 的深度学习模型自动识别 GTAW 熔深, 结果表明, ViT-B/16 模型取得较高精度.

针对现有研究的问题, 本文提出了一种融合改进轻量化 PSPNet 分割网络与高效图像处理算法的焊接过程熔池测量方法. 其中, 改进网络以 MobileNetV2 为主干网络, 通过引入高效通道注意力模块和异构感受野融合模块提高图像分割的准确性和鲁棒性. 再结合迁移学习方法, 解决熔池样本稀缺的问题, 提高模型泛化性和精度. 最后, 利用高效图像处理算法测量分割结果, 提取熔池信息并验证模型效果.

1 焊接熔池测量系统搭建及熔池图像采集

1.1 焊接熔池测量系统搭建

本研究设计了一套融合主动轮廓模型与传统图像处理技术的熔池视觉检测系统. 针对 TIG 焊接过程中熔池的高动态性和强反射特性, 系统采用优化 PSPNet 作为核心分割网络架构并优化. 在模型选取的定量评估中, PSPNet 的金字塔池化模块通过多尺度池化特征融合机制, 显著提升弧光和金属反光等噪声抗噪能力. 相较于 U-Net 通过跳跃连接反复融合底层含噪特征的设计, PSPNet 以层级化方式聚合多感受野的上下文信息. 此外, 其并行提取多尺度信息与主干共享机制大幅降低计算冗余, 实现高效推理, 便于后续进行实时性优化和嵌入式系统部署. 在图像分割后, 通过形态学运算对分割后的二值化图像进行优化, 随后利用最小外接矩形等经典图像处理技术提取熔池几何特征参数, 如长度和宽度等. 整个熔池测量流程如图 1 所示.

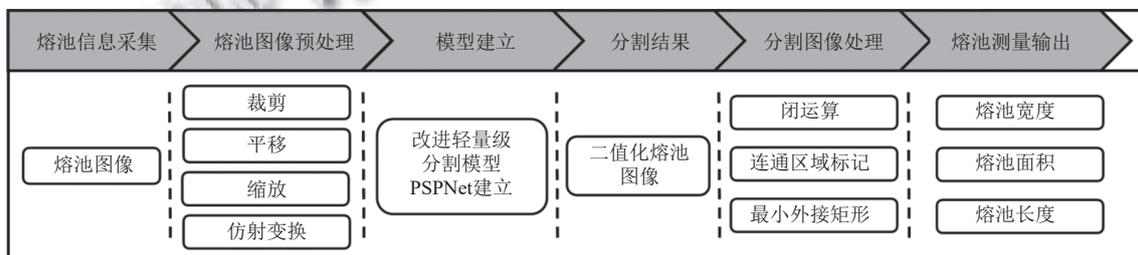


图 1 焊接过程熔池测量建模基本流程

本采集系统由焊接系统与图像采集系统组成. 焊接系统包括德国 EWM 交直流氩弧焊机、气冷式焊枪及控制系统. 其中焊枪采用 99.9% 氩气作为保护气

体. 图像采集系统包括 XVC-1000eHDR 的 CCD 相机、650 nm 波长滤光片及偏振镜. 实验平台结构如图 2 所示.

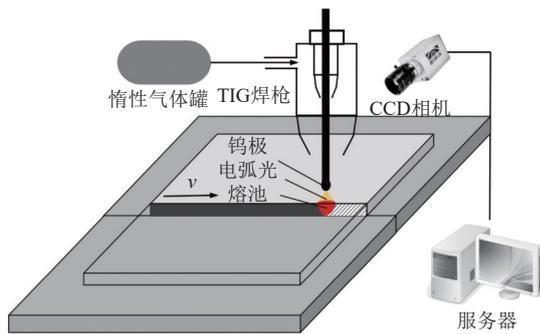


图2 实验平台结构图

1.2 焊接实验及熔池图像采集

在焊接过程中, 工作台上的工件被设定以特定速度运动并在尺寸为 100 mm×150 mm×4 mm 的 5083 铝合金上焊接, 保护气流量为 18 L/min, 选用钨极直径为 3 mm.

针对 TIG 熔池表面图像采集, 设置以焊接电流和焊接速度为变量的多组焊接工艺参数实验. 在熔池视觉传感系统从采集的 1920×1200 像素图像中, 提取出一个以熔池为中心的 512×512 像素 ROI 区域.

2 基于改进轻量级 PSP 网络的 TIG 熔池图像分割

2.1 PSPNet 改进模型

为满足 TIG 熔池监测中高实时性需求, 提升网络熔池分割性能, 本文对 PSPNet 进行改进. 主要包括 3 部分, 分别为主干网络、高效通道注意力 (efficient channel attention, ECA) 模块和异构感受野融合 (heterogeneous receptive fusion, HRF) 模块. 如图 3 所示.

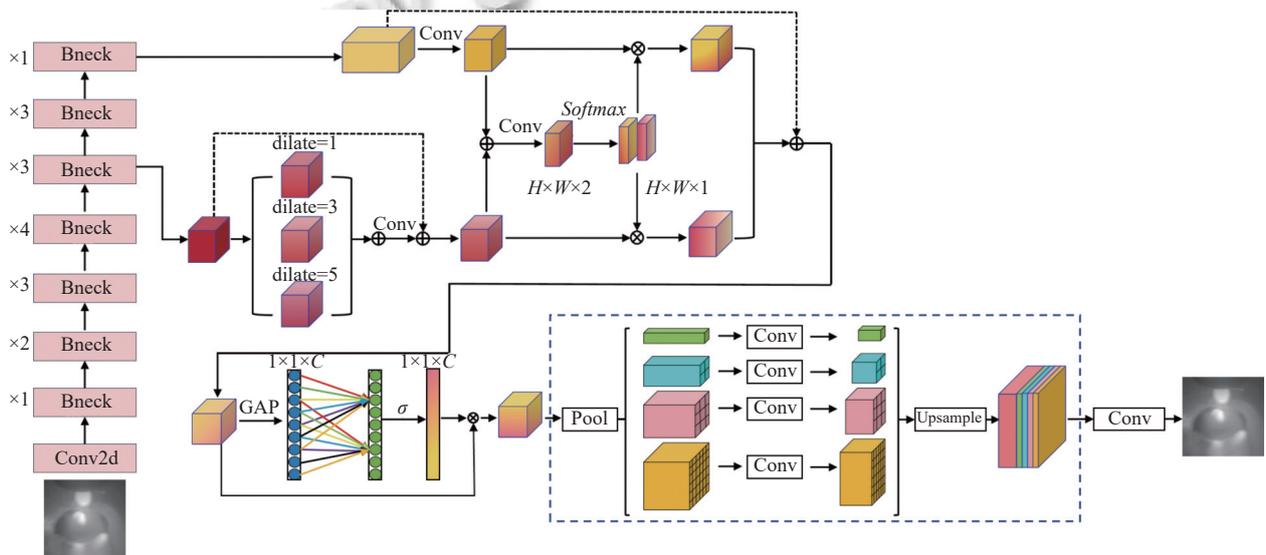


图3 PSPNet 的改进网络结构图

第 1 部分为主干网络. 采用优化 MobileNetV2 网络替代 ResNet50 网络作为 PSPNet 加强特征提取主干网络, MobileNetV2 是基于深度可分离卷积的网络, 其架构显著降低计算复杂度. 具体地, 由于语义分割不要分类层, 仅保留 MobileNetV2 的前 18 个操作阶段, 作为 PSPNet 的骨干网络, 如表 1 所示.

第 1 阶段是标准卷积层 (Conv2d), 第 2–18 阶段由 17 个瓶颈结构 (bottleneck) 堆叠而成. 由表 1 可知, 优化后的 MobileNetV2 在第 15 阶段取消下采样, 使下采样次数减少至 4 次, 有效避免特征图空间信息丢失, 维持不同尺度的特征图信息和分辨率的相对均衡. 在

减少下采样的同时, 针对高层特征 (第 16–18 阶段), 将深度卷积的膨胀率设置为 2, 利用空洞卷积的稀疏采样特性增大卷积的感受野, 补偿因分辨率提高所导致的感受野缩小. 单层膨胀卷积的理论感受野计算如式 (1) 所示:

$$RF = k + (k - 1) \times (d - 1) \quad (1)$$

其中, RF 代表单层膨胀卷积的理论感受野, k 代表空洞卷积核的大小, d 表示膨胀率. 由式 (1) 可知, 在参数数量一致时, 膨胀卷积比普通卷积拥有更大的感受野.

第 2 部分为 ECA 模块. 该轻量级注意力机制通过

增强像素局部邻域空间和通道信息的特征关注能力, 聚焦熔池分割中的关键判别特征. ECA 采用自适应选

择一维卷积核尺寸机制, 在显著减少参数量的同时, 有效保留重要的局部跨通道交互关系. 如图 4 所示.

表 1 MobileNetV2 的前 18 个操作阶段

Stage	Input	Operator	Stride	Padding	Stage	Input	Operator	Stride	Padding
1	512×512×3	Conv2d	2	1	10	32×32×64	Bottleneck, 3×3	1	1
2	256×256×32	Bottleneck, 3×3	1	1	11	32×32×64	Bottleneck, 3×3	1	1
3	256×256×16	Bottleneck, 3×3	2	1	12	32×32×64	Bottleneck, 3×3	1	1
4	128×128×24	Bottleneck, 3×3	1	1	13	32×32×96	Bottleneck, 3×3	1	1
5	128×128×24	Bottleneck, 3×3	2	1	14	32×32×96	Bottleneck, 3×3	1	1
6	64×64×32	Bottleneck, 3×3	1	1	15	32×32×96	Bottleneck, 3×3	1	1
7	64×64×32	Bottleneck, 3×3	1	1	16	16×16×160	Bottleneck, 3×3, dilate=2	1	2
8	64×64×32	Bottleneck, 3×3	2	1	17	16×16×160	Bottleneck, 3×3, dilate=2	1	2
9	32×32×64	Bottleneck, 3×3	1	1	18	16×16×160	Bottleneck, 3×3, dilate=2	1	2

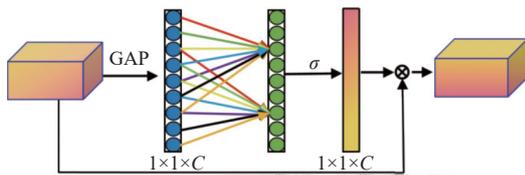


图 4 ECA 模块

ECA 模块通过全局平均池化对输入特征图 x_c 进行特征压缩, 得到通道特征向量 s_c , 可用式 (2) 表示:

$$s_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (2)$$

其中, H 是特征图高度, W 是特征图宽度.

再对特征向量 s_c 执行一维卷积进行局部交互学习, 经 Sigmoid 激活后输出通道权重 ω . 其中, 卷积核 k 值根据非线性函数 $\psi(C)$ 自动确定, 公式如下:

$$k = \psi(C) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \quad (3)$$

其中, $\lfloor \cdot \rfloor_{\text{odd}}$ 表示 k 只能取奇数, C 为特征图通道数, 超参数 γ 与 b 用于调节通道数与卷积核大小比例, 其最优设置参见文献 [12]. 通道权重 ω 计算如式 (4).

$$\omega = \sigma(C1D_k(s_c)) \quad (4)$$

此处 $C1D$ 表示一维卷积操作, 通过仅关联 k 个相邻通道的参数, 降低模型复杂度, 实现高效的特征交互.

最后, 将学习到的通道权重 ω 与原始输入特征图 x_c 逐通道相乘, 输出具备加权自适应校准能力的特征图. 该机制在维持计算轻量化的同时, 大幅提升模型对多尺度目标的空间捕获能力.

第 3 部分为异构感受野融合模块. 针对焊缝熔池的不同部分具有不同尺度特征, 例如熔池边缘可能需要小尺度的细节特征来准确分割, 而熔池的整体形状

需要依赖大尺度的语义特征, 本研究在 PSPNet 架构中嵌入 HRF 模块, 实现上下尺度特征的融合, 增强特征捕获的能力.

HRF 模块采用空洞卷积三支并行的结构, 增强低层特征的局部与全局特征关联, 其膨胀率分别为 1、3 和 5. 各分支完成特征提取后, 沿通道维度进行拼接, 拼接后通过步幅为 2 的 1×1 卷积调整特征图及通道数, 并与原始输入特征图残差连接. 高层特征则通过 1×1 卷积调整通道数. 具体结构如图 5 所示.

接着, 将处理后的低层和高层特征进行拼接融合, 经 3×3 卷积和 *Softmax* 操作, 生成动态空间权重图. 具体表示如式 (5)–(9):

$$x = f^{3 \times 3}(\text{Concat}([x'_{\text{low}}, x'_{\text{high}}], \text{dim} = 1)) \quad (5)$$

$$\beta_{\text{gate}} = \text{Softmax}(x, \text{dim} = 1) \quad (6)$$

$$\beta_{\text{gate}, c} = \frac{e^{x(b, c, j, i)}}{e^{x(b, 0, j, i)} + e^{x(b, 1, j, i)}} (c = 0, 1) \quad (7)$$

$$x'_{\text{low}}^w = x'_{\text{low}} \beta_{\text{gate}, 0} \quad (8)$$

$$x'_{\text{high}}^w = x'_{\text{high}} \beta_{\text{gate}, 1} \quad (9)$$

其中, x'_{low} 为处理后的低层特征, x'_{high} 为处理后的高层特征, $x(b, c, j, i)$ 为低层高层特征拼接与卷积后融合的特征, β_{gate} 为完整的动态门控权重矩阵, $\beta_{\text{gate}, c}$ 为单通道门控权重矩阵, x'_{low}^w 和 x'_{high}^w 分别为加权后的低层特征和加权后的高层特征, $\text{dim} = 1$ 表示沿通道维度操作, *Softmax*(\cdot) 表示归一化指数函数操作, *Concat*(\cdot) 表示矩阵拼接操作, $f^{a \times b}(\cdot)$ 表示进行 $a \times b$ 普通卷积, 且对于任意 $b \in [0, B - 1]$, $j \in [0, H - 1]$, $i \in [0, W - 1]$, B 为特征 x 批次大小, H 和 W 分别对应特征图 x 高度和宽度, 都满足 $\beta_{\text{gate}, 0} + \beta_{\text{gate}, 1} = 1$.

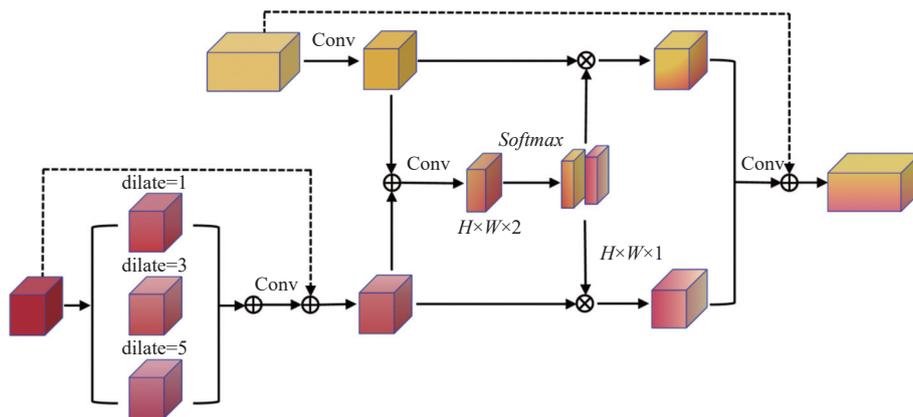


图5 HRF 模块

在动态门控权重调节后, 将加权后的低层特征 x_{low}^w 和加权后的高层特征 x_{high}^w 沿通道维度拼接, 再使用 1×1 卷积调整通道数并与高层特征进行残差连接, 以减少高层信息丢失. 最终融合特征既能保留高分辨率的几何细节, 又具备大感受野的语义完整性.

2.2 实验数据及硬件

在图像采集过程中, 共采集并挑选 2000 张熔池图片, 裁剪至 512×512 像素. 随后通过 OpenCV 对熔池图像进行平移、旋转和缩放等数据增强, 将数据集扩充至 6000 张, 并使用 LabelMe 软件对熔池区域进行语义标注. 最终随机选取 70% 作为训练集, 20% 作为测试集, 10% 作为验证集.

本实验在以下硬件和软件环境进行训练: CPU 为 Intel i5-9400F, 配备 NVIDIA GeForce RTX 3060 12 GB 显卡. 使用的深度学习框架为 PyTorch 1.9.1, CUDA 版本为 11.1, 操作系统为 Ubuntu.

在训练前, 超参数配置如下: 初始学习率设为 0.0005, 优化算法采用随机梯度 (Adam), 批次大小 (batch size) 为 8, 训练总轮次 (epoch) 为 70.

2.3 实验评价指标

本实验基于研究对象数据特征与评价指标相关性原则, 综合选取推理时间 (inference time)、模型参数量 (parameter quantity)、平均交并比 (MIoU) 和平均像素精度 (mPA) 作为评价指标. 其中, 模型参数量体现可学习参数总量, 决定存储与部署成本. 推理时间衡量端到端单帧处理耗时.

平均交并比 (MIoU) 通过逐类别计算预测掩码与真实标注掩码的交集与并集之间的几何重叠比率, 并基于多类别求均值, 实现模型区域覆盖精度的模型性

能评估. 其公式如下:

$$MIoU = \frac{1}{k+1} \sum_{i=1}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (10)$$

其中, p_{ij} 、 p_{ji} 、 p_{ii} 分别为真实类别 i 预测类别 j 的像素数量、真实类别 j 预测类别 i 的像素数量和真实类别 i 预测类别 i 的像素数量, k 为除背景类别数.

平均像素精度 (mPA) 通过逐类统计被准确归类的像素数量与该类别实际存在的像素总量的对应比率, 并基于类别维度进行全局平均计算. 其公式如下:

$$mPA = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{i=0}^k p_{ij}} \quad (11)$$

2.4 迁移学习消融实验

本文采用迁移学习, 利用大规模数据集上训练的模型进行数据增强, 解决熔池数据较少的问题. 该方法能够有效地利用预训练模型习得的丰富底层和中级视觉特征, 为分割任务提供较优的初始化模型, 从而提升其训练效率、精度和泛化性.

本实验首先在 VOC2012 数据集上预训练以初始化模型参数. 随后, 迁移学习阶段冻结 MobileNetV2 骨干网络及批量归一化层的参数, 以确保特征稳定迁移. 最后, 在熔池数据集上进行 70 轮的微调训练, 使网络适应熔池分割任务. 在微调过程中, 保持训练轮次、学习率等关键超参数不变.

由图 6 所示的迁移学习消融实验对比曲线可知, 引入迁移学习的模型在训练初期即表现出更高的 MIoU. 随着训练轮次的增加, 引入迁移学习 MIoU 均迅

速升高,在训练稳定阶段,迁移学习较未引入迁移学习的 $MIoU$ 提升约 2% 左右. 这表明,基于 VOC2012 数据集上学到的通用视觉特征进行迁移,使网络以更少的数据量高效收敛,并最终达到更高的熔池分割精度.

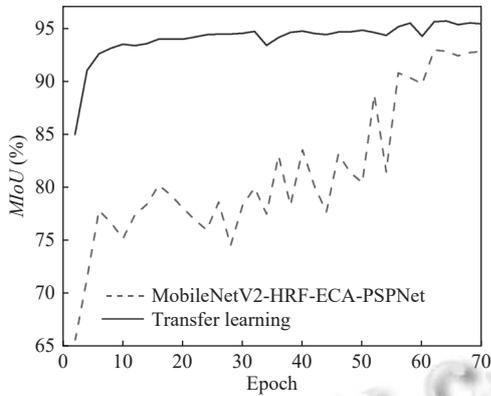


图6 迁移学习消融实验对比曲线图

2.5 消融实验

本文通过消融实验,共设置 A、B、C、D 这 4 组模型,在未迁移学习下深入探讨 ECA 与 HRF 模块对分割精度与计算效率的影响.表 2 为改进 PSPNet 网络的消融模型评价指标.

表2 改进 PSPNet 网络的消融模型评价指标

组别	Network model	$MIoU$ (%)	mPA (%)	Params (M)
A	MobileNetV2-PSPNet	91.74	95.69	2.41
B	MobileNetV2-ECA-PSPNet	92.29	96.53	2.41
C	MobileNetV2-HRF-PSPNet	92.58	96.76	2.91
D	MobileNetV2-HRF-ECA-PSPNet	92.77	96.64	2.91

在分割精度上,各项改进策略均有效提升性能. B 组引入 ECA 模块后, $MIoU$ 提升 0.55%. C 组引入 HRF 模块, $MIoU$ 和 mPA 分别提高 0.84% 和 1.07%. D 组的 $MIoU$ 达 92.77%, 相比 A 组显著提升 1.03%, 且相较于仅含 HRF 模块的 C 组,其 $MIoU$ 和 mPA 分别提升 0.22% 与 0.12%. 结果表明,采用轻量化优化 MobileNetV2 骨干网络后,结合 HRF 和 ECA 模块,可有效提升熔池分割精度.

在计算效率上, A 组引入优化的 MobileNetV2 轻量级骨干网络后,其参数量、权重大小和计算量均远低于未改进前的 PSPNet 网络,使其更易于部署在性能受限的边缘设备上. 具体数据表明, C 组较 A 组增加了 0.39M 的参数量,同时 $MIoU$ 提升 1.07%. 而 D 组相较于仅含 HRF 模块的 C 组,在仅增加极少量参数的情况下, $MIoU$ 仍提升了 0.22%.

2.6 对比分析

为验证改进后网络在熔池数据集中精度和实时性上具有竞争力,在上述同一软硬件配置及训练环境下使用迁移学习方式训练,将其与 KNet、SegFormer、HRNet、U-Net 和 PSPNet 在测试集上对比实验. 各模型的评价指标详见表 3.

表3 模型的评价指标

模型	$MIoU$ (%)	mPA (%)	Params (M)	Inference time (ms)
KNet	82.29	84.75	62.70	88.02
SegFormer	84.73	87.25	81.97	89.21
U-Net	95.15	97.76	24.89	70.26
HRNet	94.37	97.51	9.63	37.26
PSPNet	93.77	97.02	49.06	35.62
本文算法	95.44	98.27	2.91	11.30

本算法在 PSPNet 架构基础上,通过深度可分离卷积重构特征提取主干,在保持 PSPNet 基准性能的同时,将参数量压缩至 2.91M,压缩率达 94.1%. 改进后的模型在熔池数据集上 $MIoU$ 达 95.44%, mPA 为 98.27%,性能超越 U-Net. 相较 HRNet,参数量减少约 69.8%,综合表现优于 PSPNet、KNet 和 SegFormer.

值得注意的是,尽管 U-Net 的 95.15% $MIoU$ 略高于原始 PSPNet,但本文提出的改进方案通过优化主干网络等手段,最终实现了 0.29 个百分点的反超. 同时,其推理时间缩短至 11.30 ms,为原始 PSPNet 的 31.7% 和 U-Net 的 16.1%,FPS 提升至 87.42. 本文算法不仅具备轻量化结构与较高的 $MIoU$ 指标,还兼具高效计算特性,完全满足熔池监测中实时处理需求.

仅通过一些量化指标,如平均像素精度 (mPA)、平均交并比 ($MIoU$) 等不足以全面评价各个模型分割效果,还需要直观观察. 从图 7 不同模型的分割标签可见 6 种分割网络均可分割熔池,但熔池形态及精度各有不同. KNet 和 SegFormer 分割出的区域与标签图真实形态偏差明显,对边缘贴合度欠佳,细微轮廓捕捉不足. U-Net 能够较好地分割出目标区域,但因易引入噪声与冗余信息,在细节处理、边缘的精细度上存在欠缺. 例如,在目标与背景交界的细微凸起或凹陷处,出现“锯齿状”边缘,使分割结果边缘生硬、缺乏平滑过渡. 虽然 PSPNet 和 HRNet 均可分割出目标区域大致轮廓,且边缘都较为平滑,但在部分图片中, PSPNet 和 HRNet 分割边缘不够精准、对目标细节的捕捉不够细致. 而本文算法能较好分割目标,边界贴合度高,细节捕捉能力强,分割边缘均平滑无缺陷.

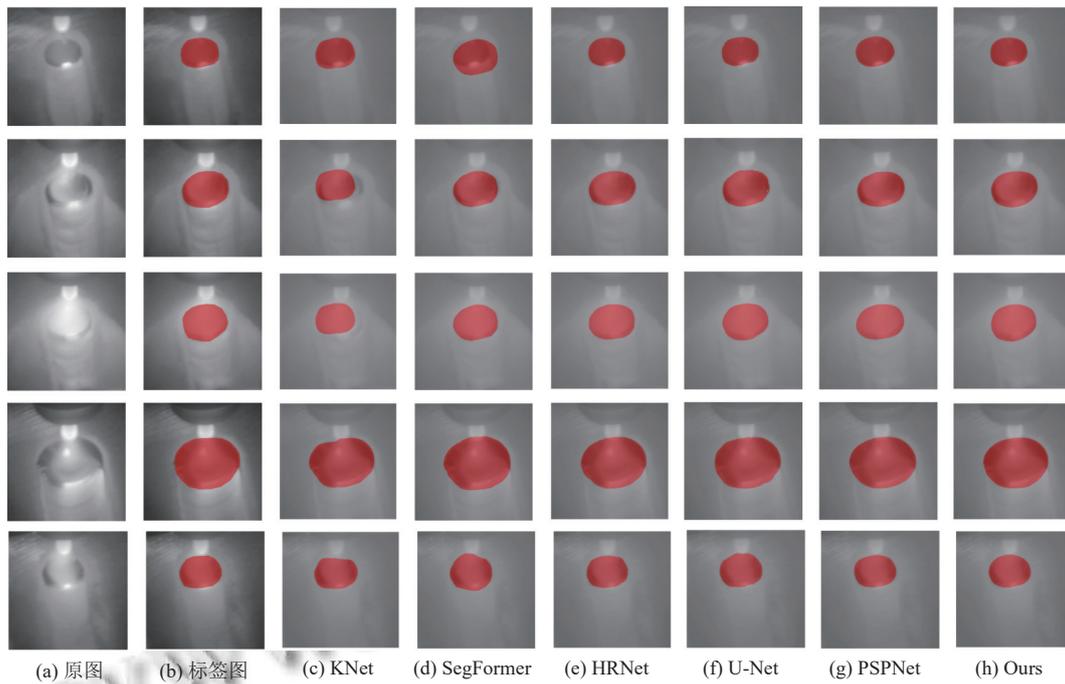


图7 不同模型的分割标签

3 焊接熔池图像测量

3.1 形态学运算及外接矩形测量

在焊接过程监测中,需要实时监测熔池宽度、长度及面积.完成分割后,对熔池二值化图像进行形态学运算,包括闭运算和连通区域标记,以填补图像中的微小空隙,标记各独立区域,并筛选符合预设条件的有效区域.

形态学运算后,利用最小外接矩形计算分割熔池的宽度、长度及面积.定义二值图像中灰度值为255的点集合 $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, n 为描述点集合熔池像素面积.设 x_{\min} 、 x_{\max} 、 y_{\min} 、 y_{\max} 分别表示为目标点集合 S 在 x 和 y 方向的最小值和最大值,则熔池像素宽度 W 和长度 L 可表示为:

$$W = x_{\max} - x_{\min} \tag{12}$$

$$L = y_{\max} - y_{\min} \tag{13}$$

3.2 不同模型熔池测量验证

为验证本算法在熔池几何特征测量上的优势,由于 KNet 和 SegFormer 分割效果差,因此选取 PSPNet、U-Net、HRNet 及本文算法作为比较对象.实验使用在某个特定焊接参数稳定工况下采集的 117 张熔池图像,在上述同一软硬件配置及训练环境上进行分割.通过计算分割结果与真实标签之间的均方差 (MSE)

来衡量算法对熔池特征分割误差,均方差公式如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \tag{14}$$

其中, n 表示样本数量; \hat{y}_i 表示第 i 个样本的预测值; y_i 表示第 i 个样本的真实值.

图8显示各模型预测的熔池长度均在 190–220 像素间波动,但本文算法以最低 MSE 值体现熔池宽度的测量精度优势.图9所示长度测量中,本文算法与 U-Net 虽均表现较优,但结合图7观察, U-Net 因底层特征噪声导致边缘存在锯齿状缺陷,而本文算法在保持低误差的同时实现分割边界的平滑贴合.图10进一步表明,本文算法 MSE 较次优模型降低 15.95%,验证其分割区域与真实标签的高度一致性.因此,本文算法在长度、像素长度及面积这3项关键指标上均取得较低误差,与分割标签定性描述完全吻合.

4 结论与展望

(1) 针对 TIG 交流焊接熔池动态监测里边缘模糊性、形态多样及尺寸多变的技术难题,本研究面向熔池几何特征解析,提出一种熔池测量方法.首先采用优化后的 MobileNetV2 网络替代原 PSPNet 主干特征提取网络以实现参数量压缩;其次构建异构感受野融合

模块,通过三支并空卷积结构,结合动态门控方法加权融合深低层特征,实现跨尺度特征融合.同时引入ECA注意力机制,聚焦核心特征并抑制焊接飞溅噪

声对特征传递的干扰;最后结合最小外接矩形等方法测量不同模型在焊接过程的熔池参数,以此验证本文算法性能优势.

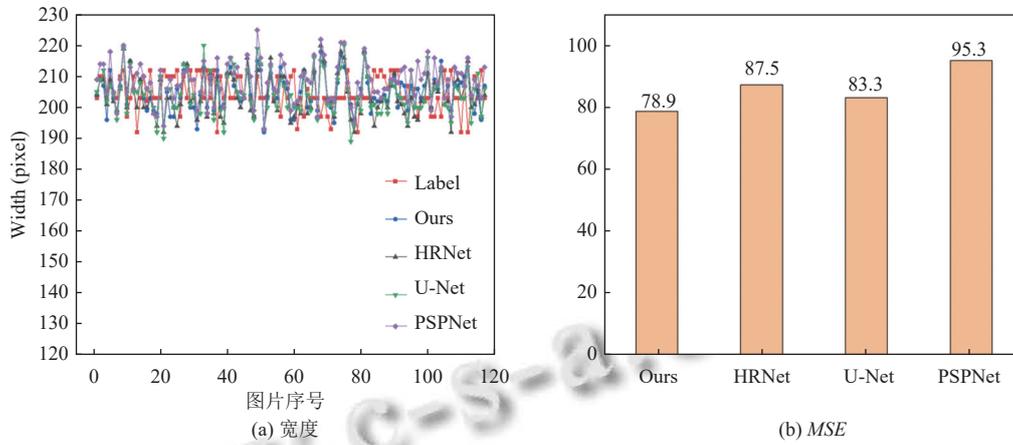


图8 不同模型的熔池宽度及 MSE

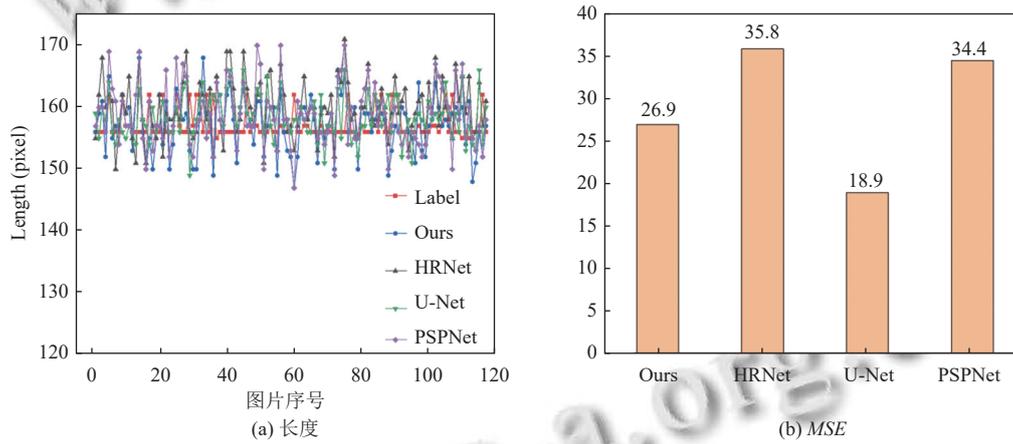


图9 不同模型的长度及 MSE

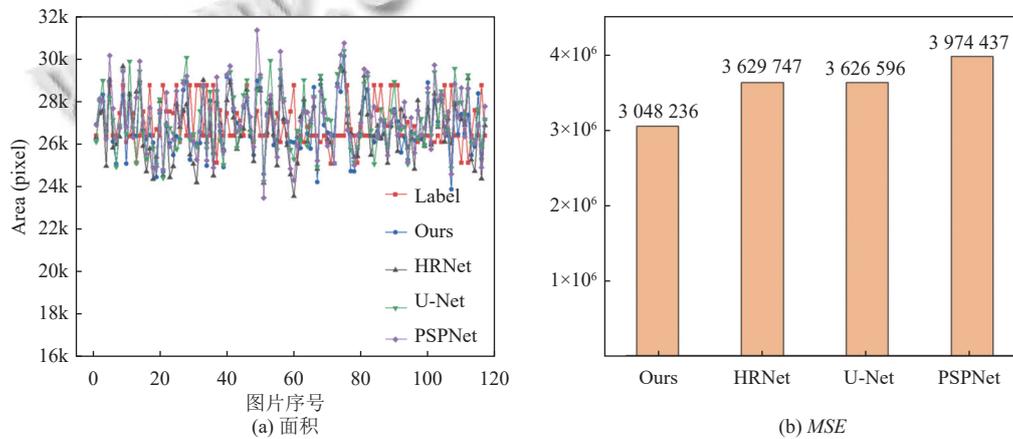


图10 不同模型的面积及 MSE

(2) 改进后的模型在熔池数据集表现出色, $MIoU$ 达 95.44%, mPA 为 98.27%, 单图推理时间仅 11.30 ms, 模型参数量为 2.91M. 与 KNet、SegFormer、HRNet、U-Net 和 PSPNet 等其他分割网络相比, 本文算法大幅降低参数量, 显著缩短单图推理时间, 仍保持较高的平均交并比. 在有效去除电弧光干扰的同时, 兼顾实时处理能力与分割精度, 可精确提取焊接过程中熔池长度、宽度及面积等几何特征参数.

(3) 在焊接智能化的发展趋势下, 熔池监测技术正朝着高实时性、强适应性的方向发展. 采用轻量化网络可显著提升在线监测系统的响应速度. 同时, 通过多场景验证增强算法的泛化能力及其在不同焊接参数下的稳定性. 此外, 该技术可进一步拓展至激光焊、电弧增材制造等领域, 推动焊接智能化监测的广泛应用. 通过持续优化数据融合与深度学习算法, 有望实现更高精度和可靠性的熔池动态监测.

参考文献

- 1 Fan XA, Gao XD, Liu GQ, *et al.* Research and prospect of welding monitoring technology based on machine vision. *The International Journal of Advanced Manufacturing Technology*, 2021, 115(11-12): 3365-3391. [doi: [10.1007/s00170-021-07398-4](https://doi.org/10.1007/s00170-021-07398-4)]
- 2 Ai YW, Han SB, Lei C, *et al.* The characteristics extraction of weld seam in the laser welding of dissimilar materials by different image segmentation methods. *Optics & Laser Technology*, 2023, 167: 109740.
- 3 Liu XG, Zhao B. Based on the CO₂ gas shielded welding molten pool image edge detection algorithm. *Applied Mechanics and Materials*, 2013, 437: 840-844. [doi: [10.4028/www.scientific.net/AMM.437.840](https://doi.org/10.4028/www.scientific.net/AMM.437.840)]
- 4 Chen ZY, Chen J, Feng ZL. Welding penetration prediction with passive vision system. *Journal of Manufacturing Processes*, 2018, 36: 224-230. [doi: [10.1016/j.jmapro.2018.10.009](https://doi.org/10.1016/j.jmapro.2018.10.009)]
- 5 Wang JJ, Lin T, Chen SB. Obtaining weld pool vision information during aluminium alloy TIG welding. *The International Journal of Advanced Manufacturing Technology*, 2005, 26(3): 219-227. [doi: [10.1007/s00170-003-1548-7](https://doi.org/10.1007/s00170-003-1548-7)]
- 6 Wang ZZ. An imaging and measurement system for robust reconstruction of weld pool during arc welding. *IEEE Transactions on Industrial Electronics*, 2015, 62(8): 5109-5118. [doi: [10.1109/TIE.2015.2405494](https://doi.org/10.1109/TIE.2015.2405494)]
- 7 Lei KY, Qin XP, Liu HM, *et al.* Weld pool edge extraction in wide-band laser cladding based on local region active contour model. *Journal of Optoelectronics-Laser*, 2018, 29(5): 516-522.
- 8 Fang QH, Tan ZB, Li H, *et al.* In-situ capture of melt pool signature in selective laser melting using U-Net-based convolutional neural network. *Journal of Manufacturing Processes*, 2021, 68: 347-355. [doi: [10.1016/j.jmapro.2021.05.052](https://doi.org/10.1016/j.jmapro.2021.05.052)]
- 9 Zhang X, Zhao SB, Wang MD. Deep learning-based defects detection in keyhole TIG welding with enhanced vision. *Materials*, 2024, 17(15): 3871. [doi: [10.3390/ma17153871](https://doi.org/10.3390/ma17153871)]
- 10 Lu J, Shi YM, Bai LF, *et al.* Collaborative and quantitative prediction for reinforcement and penetration depth of weld bead based on molten pool image and deep residual network. *IEEE Access*, 2020, 8: 126138-126148. [doi: [10.1109/ACCESS.2020.3007815](https://doi.org/10.1109/ACCESS.2020.3007815)]
- 11 Wang ZM, Chen HY, Zhong QM, *et al.* Recognition of penetration state in GTAW based on vision Transformer using weld pool image. *The International Journal of Advanced Manufacturing Technology*, 2022, 119(7-8): 5439-5452. [doi: [10.1007/s00170-021-08538-6](https://doi.org/10.1007/s00170-021-08538-6)]
- 12 Wang QL, Wu BG, Zhu PF, *et al.* ECA-Net: Efficient channel attention for deep convolutional neural networks. *Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle: IEEE, 2020. 11531-11539.

(校对责编: 李慧鑫)