第 46 卷 第 5 期 焊 接 学 报 Vol. 46(5):26 − 34, 41
2025 年 5 月 TRANSACTIONS OF THE CHINA WELDING INSTITUTION May 2025

基于熔池动态形变知识增强的 GTAW 熔透状态预测

洪宇翔[1,2]， 谢乡志[1]， 何星星[1]， 都东[3]， 常保华[3]

(1. 中国计量大学, 机电工程学院, 杭州, 310018; 2. 中国计量大学, 浙江省智能制造质量大数据溯源与应用重点实验室, 杭州, 310018; 3. 清华大学, 先进成形制造教育部重点实验室, 北京, 100084)

摘要: 为了实现对焊接熔透状态的在线监测, 保障焊缝质量并推动机器人智能化技术发展, 提出了一种熔池动态形变知识增强的钨极惰性气体保护焊 (gas tungsten arc welding, GTAW) 熔透状态预测方法. 采用高速高动态范围工业相机获取熔池图像, 利用 DeepLabv3 + 语义分割模型进行熔池动态分割以精准地获取熔池区域, 在此基础上进行多帧熔池轮廓图像融合, 以描述熔池在焊接过程中的动态形变. 将融合后熔池轮廓图像和原始熔池图像合成输入 CNN, 学习同一位置熔池轮廓像素变化, 指导 CNN 预测熔透状态. 结果表明, 基于熔池动态形变知识增强的 CNN 能够准确识别部分熔透、适度熔透和过度熔透三种典型焊缝状态, 分类准确率可达到 97.1%, 单帧预测时间 0.86 ms. 与未融合熔池动态形变专家知识的深度学习方法相比, 该方法在少样本数据情况下表现出更高的鲁棒性和准确率.

创新点: (1) 提出一种基于知识增强的深度学习 GTAW 熔透状态预测方法, 有效降低对大规模标注数据的依赖.

(2) 提出一种基于熔池动态形变知识增强 CNN 的焊接熔透状态预测框架, 结合语义分割和熔池轮廓融合方法提取熔池动态形变专家知识, 通过学习熔池轮廓像素变化先验知识指导 CNN 预测熔透状态.

关键词: 焊接质量监测; 钨极惰性气体保护焊; 知识增强; 熔池动态分割; 图像融合

中图分类号: TG 409 **文献标识码:** A **doi:** 10.12073/j.hjxb.20240115003

Prediction of GTAW penetration state based on enhanced knowledge of dynamic morphology molten pool

HONG Yuxiang[1,2], XIE Xiangzhi[1], HE Xingxing[1], DU Dong[3], CHANG Baohua[3]

(1. School of Mechanical and Electrical Engineering, China Jiliang University, Hangzhou, 310018 , China; 2. Key Laboratory of Intelligent Manufacturing Quality Big Data Tracing and Analysis of Zhejiang Province, China Jiliang University, Hangzhou, 310018, China; 3. Key Laboratory for Advanced Materials Processing Technology, Ministry of Education, Tsinghua University, Beijing, 100084, China)

Abstract: To achieve online monitoring of welding penetration status, ensure weld quality, and promote the development of robotic intelligent technology, a knowledge-enhanced prediction method for Gas Tungsten Arc Welding (GTAW) penetration status based on molten pool dynamic deformation is proposed. High-speed, high-dynamic-range industrial cameras are employed to capture molten pool images, and the DeepLabv3+ semantic segmentation model is utilized for dynamic segmentation of the molten pool to obtain precise molten pool regions. On this basis, multi-frame molten pool contour image fusion is performed to describe the dynamic deformation of the molten pool during the welding process. The fused molten pool contour images and original molten pool images are combined and input into a CNN to learn pixel-level changes in the molten pool contours at the same location, enabling the CNN to predict penetration status. Experimental results demonstrate that the CNN enhanced with molten pool dynamic deformation knowledge can accurately identify three typical weld states: partial penetration, adequate penetration, and excessive penetration, achieving a classification accuracy of 97.1% with a single-frame prediction time of 0.86 ms. Compared to deep learning methods without integration of expert knowledge on molten pool dynamic deformation features, this method exhibits higher robustness and accuracy in scenarios with limited sample data.

收稿日期: 2024 − 01 − 15

基金项目: 国家自然科学基金资助项目 (51605251); 浙江省自然科学基金 (LY22E050009); 浙江省教育厅科研资助项目 (Y202249427); 浙江省教育厅科研资助项目 (Y202147838); 浙江省属高校基本科研业务费专项资金资助 (2023YW41)

Highlights: (1) A deep learning GTAW penetration state prediction method based on knowledge enhancement is proposed to effectively reduce the dependence on large-scale labeled data.

(2) A prediction framework of welding penetration state based on knowledge-enhanced CNN for dynamic morphology of the molten pool is proposed. The expert knowledge of molten pool dynamic morphology is extracted by combining semantic segmentation and molten pool contour fusion method, and the CNN is guided to predict the penetration state by learning the prior knowledge of molten pool contour pixel change.

Key words: welding quality monitoring; gas tungsten arc welding; knowledge enhancement; dynamic segmentation of the molten pool; image fusion

0　序言

焊接质量在线监测是智能化焊接的关键技术之一[1], 其中, 焊接熔透状态的在线识别/预测作为一种不可或缺的焊接质量监测手段, 能够为焊接工艺参数的在线控制提供实时反馈, 对提升焊缝质量稳定性与生产效率具有重要意义.

熔池形态与焊缝成形质量密切相关. 目前, 光谱传感[2]、电弧声信号[3] 和视觉传感[4−6] 等多种传感技术已广泛用于获取智能机器人弧焊过程中的瞬态信息. 与其他传感技术相比, 视觉传感器具有抗干扰能力强、成本低、信息量大、非接触式等突出优点, 因此, 许多研究者倾向于使用视觉传感器实现焊接熔透的评估和控制. 此外, 视觉传感器与机器学习方法的结合已成为焊接质量监测发展的新趋势. CHEN 等人[7] 基于主动外观模型 (AAM) 的熔池视觉特征提取和随机森林 (RF) 算法实现脉冲 GTAW 熔透状态预测; 洪宇翔等人[8] 提出一种新的熔池特征“平直度特征”, 在单一特征输入条件下支持向量机 (SVM) 模型 TIG 缺陷分类准确率达 95.94%. 然而, 传统机器学习方法的监测性能严重依赖人工定义和提取的显式特征, 需要全面的专家知识.

近年来, 以卷积神经网络 (CNN) 为代表的深度学习算法因其出色的高级特征学习和非线性信息处理能力在焊接监测任务中表现突出, 显著优于传统机器视觉算法. 例如, 马晓峰等人[9] 提出一种结合生成对抗网络 (GAN) 与改进 PSPNet 的熔池深度学习监测方法, 实现对熔池的动态跟踪与精准检测; CAI 等人[10] 采用 U-Net 语义分割模型精准提取熔池和锁孔轮廓, 并构建 CNN 模型用于预测四种激光熔透状态; 李春凯等人[11] 构建深度卷积神经网络建立了熔池表面激光反射条纹与脉冲钨极气体保护焊 (P-GTAW) 不同熔透状态的映射关系. 然而, 焊接是一个具有不确定性的非线性时变过程[12], 虽然深度学习可以很好地处理数据, 但由于动态焊接过程的复杂性[13], 有效的熔池动态建模仍然是一个难题. 基于正面熔池和匙孔图像提取的时序几何特征信息, 刘秀航等人[14] 提出的 WPD-LSTM 算法对激光—熔化极惰性气体复合焊过程中出现的根部驼峰预测准确率达到 97.85%; JIAO 等人[15] 通过 CNN 将焊缝熔透状态与多帧熔池图像融合后的复合图像相关联, 该方法有效提高了 GTAW 的熔透状态预测精度. 尽管上述方法能够自适应地提取复杂、抽象的高级特征, 但它们都属于黑箱建模方法, 模型的可解释性较差. 此外, 在实际焊接生产中, 采集大量不同熔透状态的数据样本用于训练深度学习模型成本高昂.

通过利用先验知识降低深度学习对大规模标注数据的依赖, 成为当前焊接熔透状态智能预测领域的一支新兴研究方向. GAO 等人[16] 利用激光线图像提取坡口槽角作为人工先验知识, 并结合 DenseNet 模型提取的深度特征用于熔化极气体保护焊 (GMAW) 的背部熔宽预测; WU 等人[17] 将基于人类焊工先验知识提取的锁孔几何特征和 CNN 提取的高级判别特征相结合, 开发了一种焊工智能增强深度随机森林融合 (WI-DRFF) 方法准确预测四种典型变极性等离子弧焊 (VPPAW) 焊缝熔透状态; LIU 等人[18] 提出了一种新的知识和数据混合驱动模式激光焊熔透状态识别方法. 具体来说, 设计了一种标签语义注意机制 (LSA) 建模人类先验知识, 从而利用标签语义特征指导 CNN 学习判别性的视觉特征. 可以看出, 知识增强的深度学习方法可以同时利用知识和数据两者的优势, 从而有效提高目标任务的完成效果. 然而, 上述文献主要侧重于对静态熔池几何形态特征专家知识的利用, 未考虑熔池在焊接过程中的动态演变信息, 可能丢失能反映熔透状态的重要时序特征.

文中提出了一种基于熔池动态形变知识增强的深度学习 GTAW 熔透状态预测框架. 通过语义分割和多帧图像的熔池轮廓融合方法, 提取熔池动

态形变特征作为专家先验知识，将动态熔池轮廓图像和单帧原始熔池图像合成，学习同一位置熔池轮廓像素变化，指导 CNN 模型预测熔透状态. 该方法有效缓解了经典卷积神经网络对训练数据的高要求，在提高识别精度的同时增强了模型的可解释性. 与未融合熔池动态形变特征专家知识的深度学习方法相比，模型预测性能更优.

1 试验系统与分析

如图 1 所示，焊接试验系统包括焊枪、焊接电源、冷却水箱、保护气体、机械臂及执行机构、工控机、工业计算机和视觉传感系统. 焊接电源的工作模式为直流正接 (DCEN)，焊接材料为 2219 铝合金. 视觉传感系统由 Photonfocus 高速摄像机 CMOS 和一个窄带滤光片 (660 nm + 10 nm) 组成，该滤光片置于高速摄像机前方，抑制弧光辐射. 摄像机帧率为 250 帧/s，获取的熔池图像如图 2 所示，

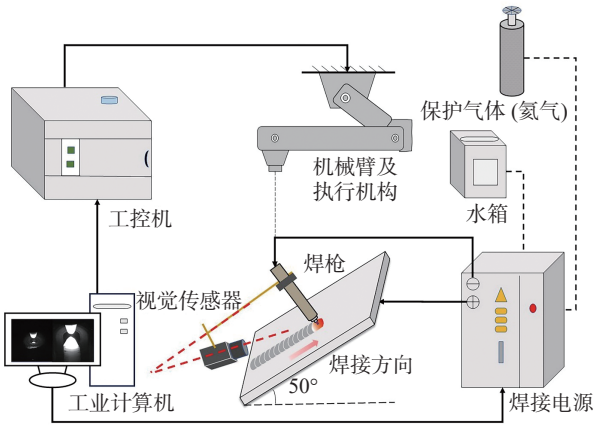


图 1 焊接试验系统示意图

Fig. 1 Schematic diagram of welding experiment system

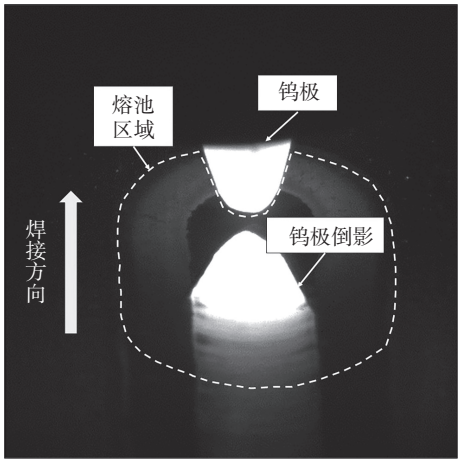


图 2 熔池示意图

Fig. 2 Schematic image of molten pool

主要包含钨极、钨极倒影和熔池区域 3 个部分. 将高速摄像机采集的熔池图像传输到工业计算机，在工业计算机上进行图像处理、模型训练和熔透状态预测，焊接试验参数见表 1.

表 1 焊接试验参数

Table 1 Welding experiment paraments

焊件尺寸 ($L \times W \times H$)/mm	氦气流量 q/(L·min^{-1})	焊接电流 I/A	焊接速度 v/(mm·s^{-1})	钨极直径 d/mm
300 × 150 × 5	12	155 ~ 175	270	5.0

为了预测 GTAW 典型熔透状态，在不同的焊接电流下进行了一系列焊接试验，文中将熔透状态分为三类，即部分熔透、适度熔透和过度熔透，如图 3 所示.

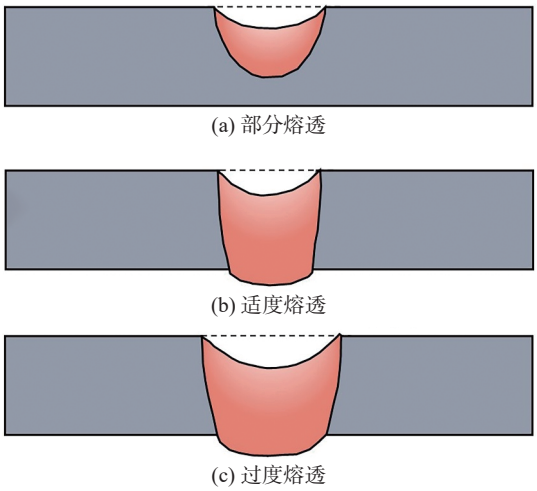


图 3 熔透状态示意图

Fig. 3 Schematic of penetration states. (a) partial penetration; (b) full penetration; (c) excessive penetration

2 基于知识增强 CNN 熔透预测方法

2.1 DeepLabv3 + 语义分割模型

文中基于 MobileNetv2 和 ASSP 构建模型 DeepLabv3 + ，如图 4 所示. 在编码器阶段，使用 MobileNetv2 骨干网络进行特征提取，该网格在使用深度可分离卷积的基础上引入了倒转残差模块和线性瓶颈层结构，大大减少了模型参数的数量，使网络收敛速度更快. 对于倒转残差模块，首先采用 1 × 1 卷积对输入特征进行升维，随后深度卷积进行过滤并提取特征图，并使用 ReLU6 作为激活函数，最后使用 1 × 1 卷积对特征进行降维处理以

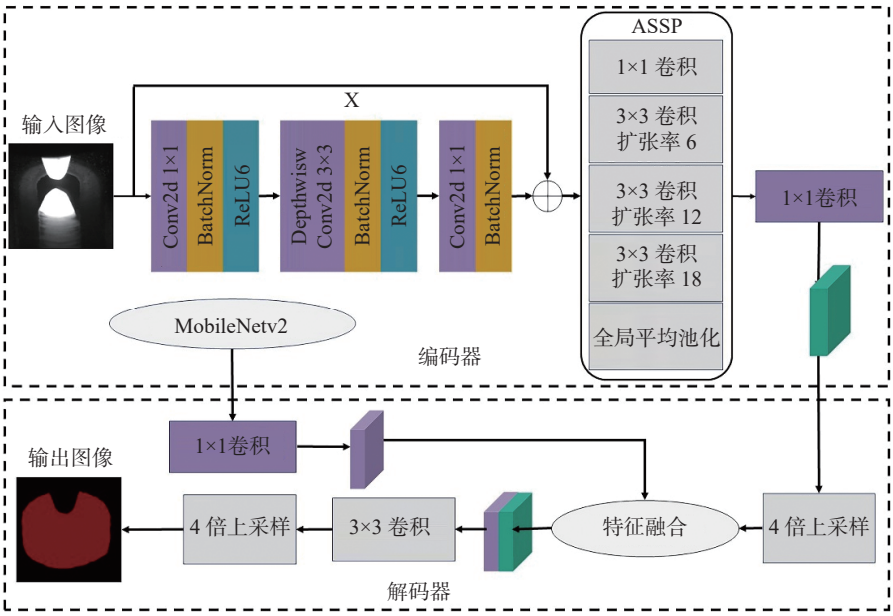


图 4　DeepLabv3 + 网络架构

Fig. 4　Structure of DeepLabv3 + model

获得特征信息. ASPP 是由空洞卷积与空间金字塔池化融合组成, 将基于骨干网络 MobileNetv2 提取的特征图送入 ASPP 模块. 在 ASPP 模块中, 首先进行 1 × 1 卷积操作, 随后进行不同扩张率的 3 × 3 卷积操作, 最后进行池化处理对特征图进行降维, 将每个分支得到的特征映射进行连接, 最后使用 1 × 1 的卷积对特征进行压缩和整合.

在解码器阶段, 采用双线性插值对融合深度特征图进行 4 倍上采样, 然后将其与 MobileNetv2 提取的底层特征图进行拼接融合, 最后通过 3 × 3 卷积和 4 倍上采样双线性插值恢复到原始图像的大小, 得到最终的输出图像.

2.2　多帧熔池轮廓图像融合方法

对语义分割得到的熔池区域进行阈值分割和边缘轮廓检测图像处理算法提取熔池轮廓, 熔池轮廓可以反应熔池动态变化, 通过多帧熔池轮廓图像融合提取熔池动态形变, 可以有效提供焊接过程中的动态演变信息, 为 GTAW 熔透状态预测提供先验知识, 如图 5 所示.

为了提取熔池动态形变特征, 建立熔池轮廓图像序列, 进行加权图像融合, 即

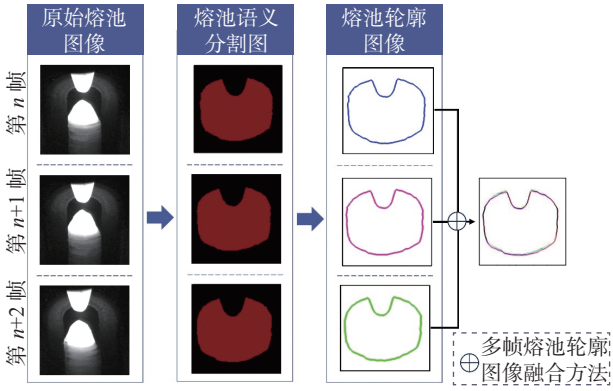


图 5　多帧熔池轮廓图像融合方法

Fig. 5　Multi-frame molten pool contour image fusion method

$$R = \sum_{i=1}^{N} w_i F_i \tag{1}$$

式中: R为融合后图像; F_i为待融合图像; w_i为加权系数, 文中采用 3 帧熔池轮廓图像融合, 所以$N = 3$, 算法流程如下.

(1) 将连续 3 帧熔池图像作为一个序列, 通过遍历序列中图像, 从序列中选取第一帧 (t + 0 ms), 第二帧 (t + 4 ms), 第三帧 (t + 8 ms) 图象, 3 帧的熔池轮廓图分别为F_1, F_2和F_3.

(2) 计算相关系数, 对于图像F_1, F_2和F_3, 相关系数可以表示为

$$C(F_1,F_2) = \frac{\sum_{m-1}\sum_{n-1}\left(F_1(m,n)-\overline{F_1}\right)\cdot\left(F_2(m,n)-\overline{F_2}\right)}{\sqrt{\sum_{m-1}\sum_{n-1}\left(F_1(m,n)-\overline{F_1}\right)^2\cdot\sum_{m-1}\sum_{n-1}\left(F_2(m,n)-\overline{F_2}\right)^2}} \tag{2}$$

式中: $\overline{F_1}$和$\overline{F_2}$分别是图像F_1和F_2的均值; m 代表图像像素行号; n代表图像像素列号. 类似也可以计

算$C(F_1,F_3)$, $C(F_2,F_3)$.

(3) 计算加权系数 w, 由于相关系数衡量了两幅图像之间的相似度, 根据相关系数的不同, 每个图像的权重也不同. 这些权重表示每个源图像在融合过程中的贡献程度, 为了保证融合后的图像能够正确地反映源图像的特征, 需要确保计算得到的权重之和为 1, 即

$$\begin{cases} w_1 = \dfrac{1}{3}(1-C(F_2,F_3)) \\ w_2 = \dfrac{1}{3}(1-C(F_1,F_3)) \\ w_3 = 1-w_1-w_2 \end{cases} \tag{3}$$

(4) 计算最终融合图像 R, 即

$$R(m,n) = w_1 \cdot F_1(m,n) + w_2 \cdot F_2(m,n) + w_3 \cdot F_3(m,n) \tag{4}$$

为了更直观表现熔池形变特性, 通过不同颜色的熔池轮廓序列表示熔池动态形变, 以表现时间和空间的连续性.

2.3 构建知识增强的 CNN 熔透状态预测模型

通过上述语义分割和熔池轮廓融合提取熔池动态形变, 通过熔池动态形变在各个局部区域表现出动态变化, 因此, 熔池动态形变可以为 CNN 模型提供先验知识. 如图 6 所示, 将融合后的动态熔池轮廓图像和其图像序列中对应的第二帧原始熔池图像一起输入 CNN 模型, 并通过相同感受野提取同一位置的像素变化. 合成图像不仅包含比单幅图像更多的信息, 而且蕴含了焊接过程中的时序信息, 有效融合专家先验知识, 因此该方法能更全面的预测熔透状态.

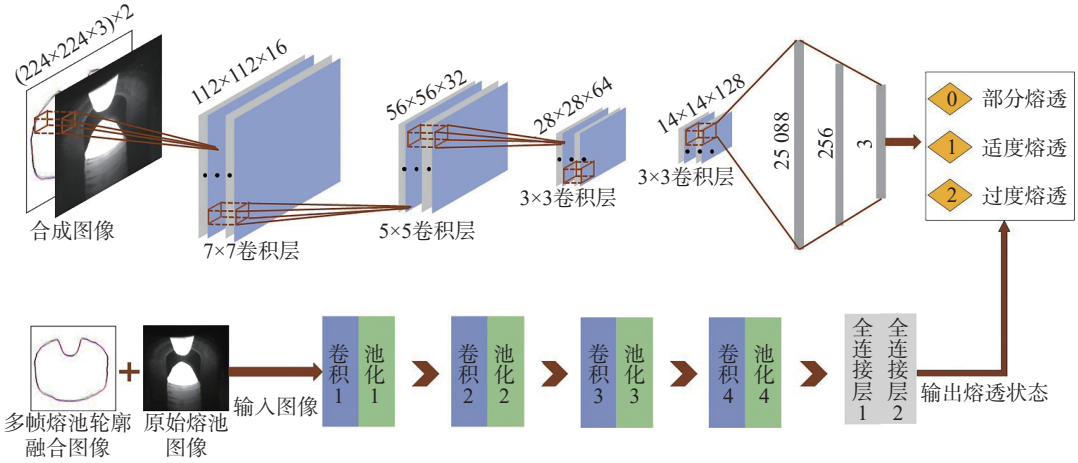


图 6 知识增强的 CNN 熔透状态预测架构

Fig. 6 Knowledge-enhanced CNN penetration prediction architecture

基于先验知识提取的熔池轮廓有效剔除了图像冗余信息, 而且基于多帧熔池轮廓图像融合方法获得的图像能够在一定程度上反映熔池动态形变, 因此, 通过缩小输入图像尺寸和减小卷积核大小可以降低计算复杂度, 同时避免模型过拟合. 文中建立卷积神经网络, 以合成图像作为输入, 输出三种熔透状态, 这些模型由卷积层、池化层和全连接层组成. 所有模型的第一卷积层核大小为 [7 × 7], 第二层卷积层的核大小为 [5 × 5], 第三层和第四层为 [3 × 3], 卷积运算的步长是 1, 下采样使用最大池化方法, 核大小为 [2 × 2], 步长为 2. 特征图像每经过池化层一次, 图像大小就会减少一半. 在 CNN 模型对图像进行处理的过程中, 输入图像越大, 模型学习到的图像细节越多, 如果输入图像太小, 模型将无法学习到足够的细节, 模型可能拟合不足. 而较小的卷积核通常能够捕获更细粒度的特征, 较大的卷积核可以捕获更广阔的空间信息, 有助于学习到更大尺度的特征. 因此, 选择适当的输入图像大小和卷积核大小可以提高模型精度, 有效缩短延迟. 文中设置了 4 个 CNN 模型, 用于探究输入图像大小与卷积核规模对模型性能的影响, 见表 2. 其中, CNN-1 作为基准对照组, 采用 360 × 360 输入尺寸和逐级递增的卷积核配置; CNN-2 在保持相同卷积核规模的前提下, 将输入尺寸压缩至 224 × 224, 全连接层对应调整为 [14 × 14 × 128,3]; CNN-3 在 CNN-2 基础上将各层卷积核数量翻倍; CNN-4 则进一步将输入尺寸缩减至 128 × 128, 全连接层结构变为 [8 × 8 × 256,3]. 通过这四种模型可以系统验证输入图像尺寸大小与特征提取能力之间的平衡关系.

表 2　CNN 架构
Table 2　Architecture of the proposed CNN

模型	输入大小	卷积核1	卷积核2	卷积核3	卷积核4	全连接层
CNN-1	360 × 360	16	32	64	128	[23 × 23 × 128,3]
CNN-2	224 × 224	16	32	64	128	[14 × 14 × 128,3]
CNN-3	224 × 224	32	64	128	256	[14 × 14 × 256,3]
CNN-4	128 × 128	32	64	128	256	[8 × 8 × 256,3]

3　试验结果与分析

3.1　熔池图像分割结果

在焊接过程中, 通过视觉传感获得了 5 463 张熔池图像. 将 512 × 512 像素熔池图像裁剪为 360 × 360 像素, 只保留熔池区域, 有效地去除冗余信息并降低了计算成本. 将数据集按 7∶3 分成训练集和测试集, 并使用标注软件 Labelme 对训练数据集进行标注. DeepLabv3 + 模型训练完成后, 输入图像中的像素将被划分为熔池区域和背景. 为验证模型的有效性, 采用联合平均交集 (mean intersection over union, MIoU) 和平均像素精度 (mean pixel accuracy, MPA) 评估语义分割模型的性能, 即

$$M_{\mathrm{MIoU}}=\frac{1}{k+1}\sum_{\mathrm{i}=0}^{k}\frac{p_{ij}}{\sum_{j=0}^{k}p_{ij}+\sum_{j=0}^{k}p_{ji}-p_{ii}} \tag{5}$$

$$M_{\mathrm{MPA}}=\frac{1}{k+1}\sum_{i=0}^{k}\frac{p_{ii}}{\sum j=0^{k}p_{ij}} \tag{6}$$

式中: $k+1$表示目标类别; p_{ij}表示属于类别 i 但被预测为类别 j 的像素的总数. 具体为p_{ii}, p_{ij}和p_{ji}表示真阳性、假阳性和假阴性.

为了验证所提出 DeepLabv3 + 模型优越性, 对比了 FCN, SegNet 和 U-Net 三种分割网络, 性能指标见表 3. 由于 DeepLabv3 + 以 MobileNetv2 网络作为主干特征提取器, 训练时间比 FCN, SegNet 和 U-net 短, 模型具有较高效率. 熔池区域分割平均交并比达 81.2%, 平均像素精度 83.6%, 在处理速度方面达到 19 帧/s, 均优于其他三种网络. 将 DeepLabv3 + 与其他模型熔池动态分割的结果对比, 如图 7 所示, DeepLabv3 + 因其引入空间金字塔结构并且缩小了空洞卷积膨胀率, 可以关注到轮廓边缘细节信息, 有效提高分割准确率.

表 3　不同分割网络性能对比
Table 3　Quantifying the performance of different segmented networks

方法	平均交并比	平均像素精度	检测速度 v/(帧·s^{-1})
FNC	0.722	0.791	22
SegNet	0.754	0.786	25
U-Net	0.783	0.824	24
DeepLabv3 +	0.812	0.836	19

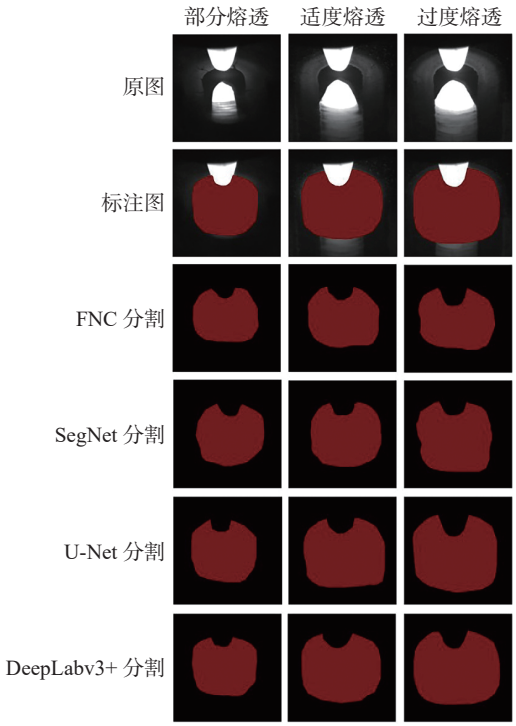


图 7　不同语义分割模型在熔池分割任务中的效果对比
Fig. 7　Comparison of the molten pool segmentation results among different semantic segmentation models

3.2　多帧熔池轮廓图像融合结果

如图 8 所示, 对熔池轮廓图像序列进行加权平均融合, 可以看出, 在三种熔透状态下, 熔池轮廓在时间和空间上的动态变化. 对于部分熔透状态, 熔池尺寸较小且轮廓变化剧烈, 对于适度熔透状态, 熔池轮廓逐渐增大并且趋于稳定, 整体变化不明显, 对于过度熔透状态, 熔池轮廓变化明显, 在空间上轮廓逐渐变大, 在时间上轮廓边缘变化剧烈.

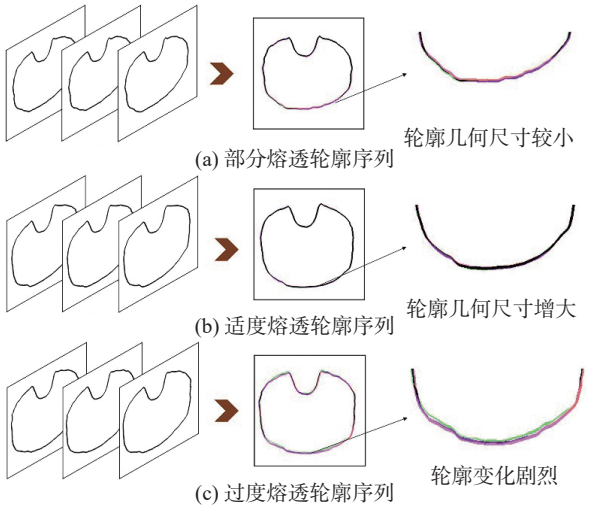


图 8 不同熔透状态下熔池轮廓融合

Fig. 8 Molten pool counter fusion in different penetration states. (a) partial penetration;(b) full penetration; (c) excessive penetration

通过观察融合后的熔池轮廓图像，可以发现熔池轮廓形态变化不仅具有时间连续性，还在空间的各个局部区域表现出差异性，可以有效表征动态焊接信息. 因此，设计融合后的轮廓图像序列数据集丰富了熔池图像的信息，并且在视觉上突出不同轮廓的变化，为深度学习模型提供更稳定和更丰富先验知识的输入.

3.3 基于知识增强的 CNN 熔透状态预测结果

为了评估模型的性能，将数据分为训练集和测试集，为了保留焊接的时序性，使用每个熔透状态下数据的前 70% 作为训练集，剩下的 30% 作为测试集，训练集和测试集的数量分别为 1 274 和 547，见表 4. 此外，采用 Adam 优化器降低计算成本，提高收敛速度，批次大小设置为 32，学习率设置 0.001，训练轮次设为 10(epoch = 10). 所有训练运行在英特尔酷睿 i5-11400U CPU，2.70 GHz 和 16 GB RAM. 该模型在 pytorch 框架下使用 python 构建，并在 GPU (RTX3050) 上进行训练. 采用准确率 (A)、精度 (P)、召回率 (R)、F1 指数值 ($F1$)4 个评价指标，进一步定量评价模型在熔透状态预测中的分类性能.

表 4 数据集分布 (个)

Table 4 Distribution of dataset

数据集	部分熔透	适度熔透	过度熔透	总计
训练集	301	623	350	1 274
测试集	129	268	150	547
总计	430	891	500	1 821

如图 9 所示，显示 4 个 CNN 模型的训练损失和训练准确率，随着训练开始，训练损失函数逐渐减小，利用合成图像序列数据对模型的训练精度在前 4 个训练轮次期间波动较大，然后缓慢稳定，在第 9 个轮次达到最佳值，训练准确率达到 99.9%，训练损失小于 0.01，此时对模型进行测试. CNN-2 收敛速度最快，说明该模型学习效果最好，CNN-4 收敛速度最慢，可能是由于输入图像尺寸最小，导致模型学习有效特征的速度较慢.

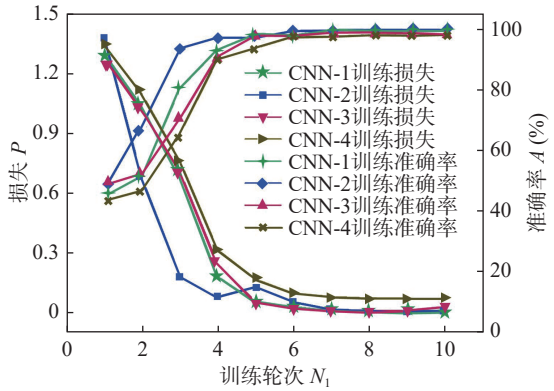


图 9 CNN 网络训练结果

Fig. 9 CNN network training results

为了深入分析文中提出的 CNN 模型的性能，对训练模型的预测精度和预测时间 (单个样本在 CNN 模型上的运行时间) 进行了详细的比较. 图 10 为四种 CNN 模型的性能对比结果，模型预测时间随着模型参数和输入图像尺寸的减小而减小. 模型的单帧预测时间范围为 0.72 ~ 0.97 ms，表明所构建的 4 个 CNN 模型满足实时监控的要求. 其中，CNN-2 的预测准确率最高，达到 97.1%；CNN-3 的预测时间最短，达到 0.81 ms. 尽管 CNN-3 的预测时间(0.81 ms)略快于 CNN-2 的预测时间(0.86 ms)，但 CNN-2 的预测准确率(97.1%)高于 CNN-

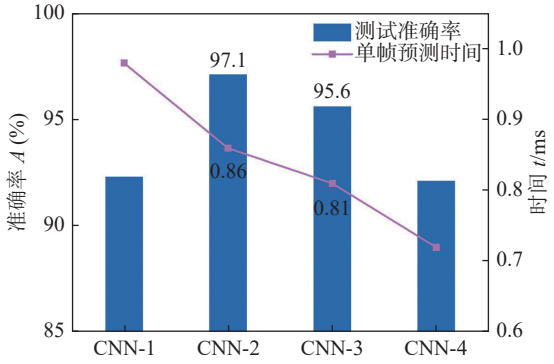


图 10 CNN 模型预测准确率和预测时间

Fig. 10 CNN model prediction accuracy and prediction time

3(95.6%)，考虑到应用场景对准确率要求较高，故选择 CNN-2 作为熔透状态预测模型.

训练完成后将测试集的合成图像按时序输入到训练好模型中 (CNN-2). 为了更直观的得出焊接状态的预测结果，将熔透状态预测结果与真实标签进行对比，如图 11 所示，所提出的基于知识增强的 CNN 预测模型能够可靠地识别出三种熔透状态，预测误差主要发生在状态转换时，可以看出在部分熔透中，预测错误的样本非常少且分布分散，在过度熔透时预测误差主要集中在由适度熔透到过度熔透转变时.

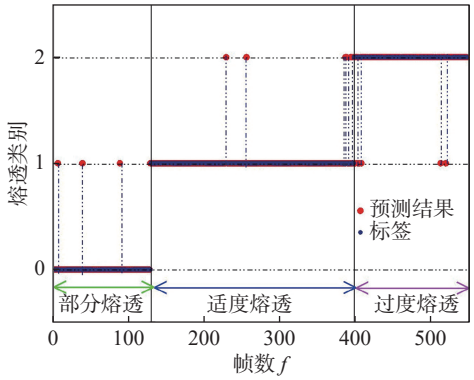


图 11　熔透状态预测结果和真实标签 (0-部分熔透，1-适度熔透，2-过度熔透)

Fig. 11　Penetration prediction results and truth label(0-partial penetration, 1-full penetration, 2-excessive penetration)

3.4　不同输入图像预测结果对比

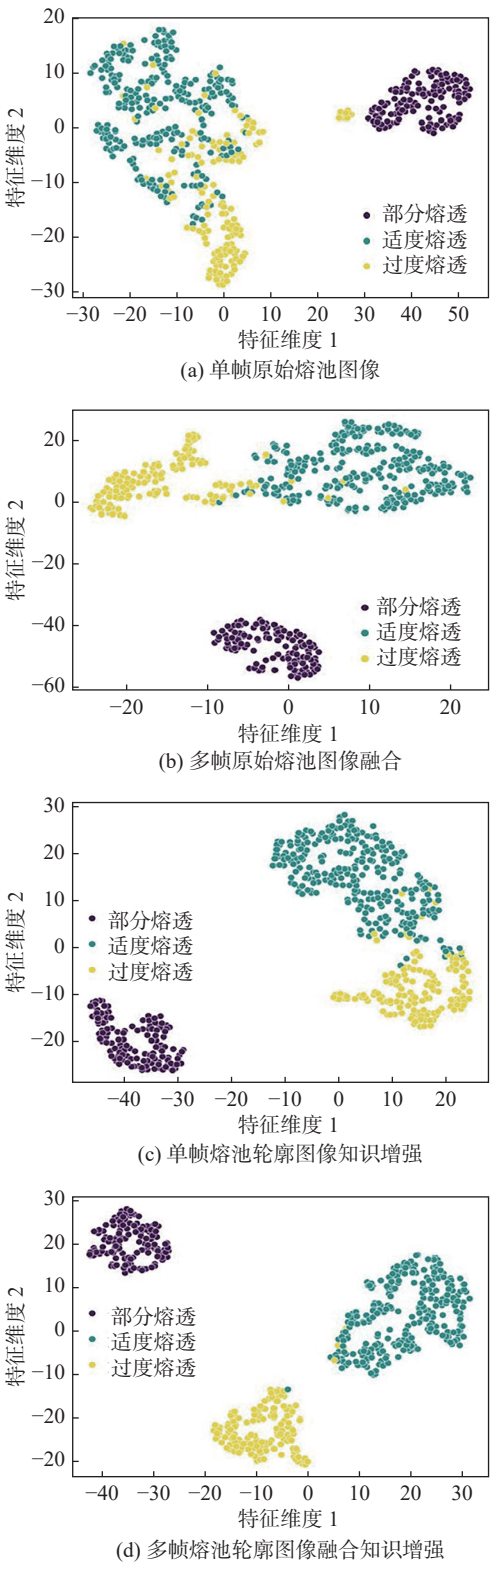
为了探索 CNN 熔透状态预测效果，分析了熔透预测过程. 首先，对不同输入图像熔透预测结果进行分析见表 5，基于多帧熔池轮廓图像融合知识增强输入下，分类准确率和 F1 指标最高，分别达到 97.1% 和 97.3%，相较于单帧原始熔池图像、多帧原始熔池图像融合和单帧熔池轮廓图像知识增强输入情况下，各项评价指标均有所提升，可见文中方法能更好预测不同熔透状态.

表 5　CNN 测试结果

Table 5　CNN test results

输入图像	准确率 A(%)	精度 P(%)	召回率 R(%)	F1值 $F1$(%)
单帧原始熔池图像	83.5	81.4	83.3	83.8
多帧原始熔池图像融合	90.4	91.5	90.4	90.5
单帧熔池轮廓图像知识增强	93.2	93.4	93.2	93.2
多帧熔池轮廓图像融合知识增强	97.1	98.5	97.4	97.3

为了验证 CNN 在不同输入图像下熔透状态预测过程，文中采用 t-SNE 降维算法对最后一层测试集的特征进行可视化处理，如图 12 所示. 将高维特



(a) 单帧原始熔池图像

(b) 多帧原始熔池图像融合

(c) 单帧熔池轮廓图像知识增强

(d) 多帧熔池轮廓图像融合知识增强

图 12　不同输入下 t-SNE 可视化

Fig. 12　Visualization of t-SNE with different inputs. (a) single-frame raw molten pool image; (b) multi-frame raw molten pool image fusion; (c) knowledge enhancement for single-frame molten pool contour image; (d) knowledge enhancement for multi-frame molten pool contour image fusion

征简化为二维空间,可以更直观地了解这些特征在高维空间中是否可分,其中不同颜色的散点代表不同的熔透状态,可以清晰地观察到三种熔透状态的区别. 其中,四种不同图像输入下部分熔透状态类型很容易从散点图中区分出来. 在单帧原始熔池图像和多帧原始熔池图像融合输入下,很多适度熔透和过度熔透状态样本混合在一起,在单帧熔池轮廓图像知识增强和多帧熔池轮廓图像融合知识增强输入情况下,可以有效的辨识适度熔透和过度熔透焊接状态,其中,多帧熔池轮廓图像融合知识增强聚类中心分开更加明显,可见融合熔池动态形变时序信息和专家知识使焊接熔透状态识别准确率和泛化性得到有效提高.

4 结论

(1) 提出一种基于知识增强深度学习的 GTAW 熔透状态预测方法,有效缓解了经典卷积神经网络对训练数据的高要求,在提高识别精度的同时增强了模型的可解释性.结果表明,对部分熔透、适度熔透和过度熔透三种典型焊接状态的分类准确率达 97.1%,单帧预测时间 0.86 ms.

(2) 提出一种基于熔池动态形变知识增强 CNN 的焊接熔透状态预测框架. 可视化结果表明,熔池动态形变有效为预测过程提供时序特征信息和专家先验知识.与未融合熔池动态形变特征专家知识的深度学习方法相比,有效提高了少样本数据输入下模型预测性能.

(3) 结合熔池语义分割和多帧图像融合算法,能够一定程度上描述焊接过程中的熔池动态变化.

参考文献

[1] 周政, 王国庆, 宋建岭, 等. 2219 铝合金不同气氛下 TIG 焊焊接接头组织性能 [J]. 焊接学报, 2018, 39(7): 47 − 50.
ZHOU Zheng, WANG Guoqing, SONG Jianlin, *et al*. Microstructure and mechanical properties of 2219aluminum alloys TIG welding welded joints in differentshielding gases[J]. Transactions of the China Welding Institution, 2018, 39(7): 47 − 50.

[2] 张志芬, 杨哲, 任文静, 等. 电弧光谱深度挖掘下的铝合金焊接过程状态检测 [J]. 焊接学报, 2019, 40(1): 19 − 25.
ZHANG Zhifen, YANG Zhe, REN Wenjing, *et al*. Condition detection in Al alloy welding process based on deep mining of arc spectrum[J]. Transactions of the China Welding Institution, 2019, 40(1): 19 − 25.

[3] 岳建锋, 龙新宇, 黄云龙, 等. 基于电弧声信号的窄间隙脉冲熔化极气体保护焊侧壁熔合状态在线识别 [J]. 中国机械工程, 2024, 35(2): 244 − 250, 259.
YUE Jianfeng, LONG Xinyu, HUANG Yunlong, *et al*. On-line identification of narrow gap P-GMAW sidewall fusion state based on arc acoustic signa[J]. China Mechanical Engineering, 2024, 35(2): 244 − 250, 259.

[4] PENG G, CHANG B, WANG G, *et al*. Vision sensing and feedback control of weld penetration in helium arc welding process[J]. Journal of Manufacturing Processes, 2021, 72: 168 − 178.

[5] 肖宏, 宋建岭, 刘宪力, 等. 基于形态学算法的 2219 铝合金钨极氦弧焊熔池图像特征提取 [J]. 宇航材料工艺, 2019, 49(1): 78 − 81.
XIAO Hong, SONG Jianling, LIU Xianli, *et al*. Image feature extraction of helium gas tungsten arc welding pool of 2219 aluminum alloy based on morphological algorithm[J]. Aerospace Materials & Technology, 2019, 49(1): 78 − 81.

[6] HONG Y, YANG M, CHANG B, *et al*. Filter-PCA-based process monitoring and defect identification during climbing helium arc welding process using DE-SVM[J]. IEEE Transactions on Industrial Electronics, 2023, 70(7): 7353 − 7362.

[7] CHEN C, LYU N, CHEN S. Welding penetration monitoring for pulsed GTAW using visual sensor based on AAM and random forests[J]. Journal of Manufacturing Processes, 2021, 63: 152 − 162.

[8] 洪宇翔, 杨明轩, 都东, 等. 铝合金爬坡 TIG 焊熔池失稳状态的视觉检测 [J]. 焊接学报, 2021, 42(10): 8 − 13.
HONG Yuxiang, YANG Mingxuan, DU Dong, *et al*. Unstable state vision detection of molten pool during aluminum alloy climbing-TIG welding[J]. Transactions of the China Welding Institution, 2021, 42(10): 8 − 13.

[9] 马晓锋, 夏攀, 刘海生, 等. 全位置焊接熔池的深度学习检测方法 [J]. 机械工程学报, 2023, 59(12): 272 − 283.
MA Xiaofeng, XIA Pan, LIU Haisheng, *et al*. Deep learning detection method of all-position welding pool[J]. Journal of Mechanical Engineering, 2023, 59(12): 272 − 283.

[10] CAI W, JIANG P, SHU L, *et al*. Real-time identification of molten pool and keyhole using a deep learning-based semantic segmentation approach in penetration status monitoring[J]. Journal of Manufacturing Processes, 2022, 76: 695 − 707.

[11] 李春凯, 王嘉昕, 石玗, 等. GTAW 熔池激光条纹动态行为与熔透预测方法研究 [J]. 机械工程学报, 2024, 60(6): 236 − 249.
LI Chunkai, WANG Jiaxin, SHI Yu, *et al*. Study on the dynamic behavior of GTAW melt pool laser streak and penetration prediction method[J]. Journal of Mechanical Engineering, 2024, 60(6): 236 − 249.

（下转第 41 页）

7(5): 726 − 733.

[13] LI G, FENG J, TIAN Yanhong, *et al*. Finite element analysis of underfill effect on the CBGA package reliability under thermal cycling[C]//International Conference on Electronic Packaging Technology (ICEPT), 2022.

[14] 撒子成, 王尚, 冯佳运, 等. SiP 器件组装焊点形态预测及其随机振动可靠性仿真研究 [J]. 机械工程学报, 2022, 58(2): 276 − 283.
SA Zicheng, WANG Shang, FENG Jiayun, *et al*. Simulation of SiP solder joint geometry and random vibration reliability prediction[J]. Chinese Journal of Mechanical Engineering, 2022, 58(2): 276 − 283.

[15] LI G, WANG S, TIAN Y, *et al*. Solder joint shape optimization and thermal-mechanical reliability improvement for microwave RF coaxial connectors[J]. Microelectronics Reliability, 2024, 154: 115345.

[16] 杨雪霞, 孙勤润, 张伟伟. 基于响应曲面法的 BGA 焊点结构参数优化设计 [J]. 焊接学报, 2023, 44(11): 36 − 41.
YANG Xuexia, SUN Qinrun, ZHANG Weiwei. Optimization design of BGA solder joint structure parameters based on response surface methodology[J]. Transactions of the China Welding Institution, 2023, 44(11): 36 − 41.

[17] WU W, LI G, WANG S, *et al*. Study on the solder joint reliability of new diamond chip resistors for power devices[J]. Coatings, 2023, 13(4): 748.

[18] PECHT M. Creep fatigue models of solder joints: A critical review[J]. Microelectronics and Reliability, 2016, 59: 1 − 12.

[19] LEE W W, NGUYEN L T, SELVADURAY G S. Solder joint fatigue models: review and applicability to chip scale packages[J]. Microelectronics Reliability, 2000, 40(2): 231 − 244.

第一作者: 李庚，博士研究生；主要研究方向为电子封装可靠性与印刷电子；Email: li-geng@hit.edu.cn.
通信作者: 田艳红，博士，教授；Email: tianyh@hit.edu.cn.

（编辑：　刘启明）

（上接第 34 页）

[12] WANG Q, JIAO W, WANG P, *et al*. A tutorial on deep learning-based data analytics in manufacturing through a welding case study[J]. Journal of Manufacturing Processes, 2021, 63: 2 − 13.

[13] CHENG Y, WANG Q, JIAO W, *et al*. Detecting dynamic development of weld pool using machine learning from innovative composite images for adaptive welding[J]. Journal of Manufacturing Processes, 2020, 56: 908 − 915.

[14] 刘秀航, 叶广文, 黄宇辉, 等. 激光-MIG 复合焊根部驼峰缺陷预测 [J]. 焊接学报, 2022, 43(12): 47 − 52,99.
LIU Xiuhang, YE Guangwen, HUANG Yuhui, *et al*. Root hump defect prediction for laser-MIG hybrid welding[J]. Transactions of the China Welding Institution, 2022, 43(12): 47 − 52,99.

[15] JIAO W, WANG Q, CHENG Y, *et al*. Prediction of weld penetration using dynamic weld pool arc images[J]. Welduing Journal, 2020, 99(11): 295S − 302S.

[16] GAO P, WU Z, WANG Y, *et al*. Method for monitoring and controlling penetration of complex groove welding based on online multi-modal data[J]. Journal of Intelligent Manufacturing, 2024, 35(3): 1247 − 1265.

[17] WU D, HU M, HUANG Y, *et al*. In situ monitoring and penetration prediction of plasma arc welding based on welder intelligence-enhanced deep random forest fusion[J]. Journal of Manufacturing Processes, 2021, 66: 153 − 165.

[18] LIU T, BAO J, ZHENG H, *et al*. Learning semantic-specific visual representation for laser welding penetration status recognition[J]. Science China Technological Sciences, 2022, 65(2): 347 − 360.

第一作者: 洪宇翔，博士，副教授；主要从事机器人与智能化焊接方面的科研和教学工作；Email: hongyuxiang@cjlu.edu.cn.

（编辑：　郑红）