

融合图像与频域特征激光切割挂渣量化预测

翟杰 芦宇 王鑫鑫 夏元钦

Quantitative prediction of laser-cut slag adhesion by integrating image and frequency-domain features

ZHAI Jie, LU Yu, WANG Xin-xin, XIA Yuan-qin

引用本文:

翟杰, 芦宇, 王鑫鑫, 夏元钦. 融合图像与频域特征激光切割挂渣量化预测[J]. *中国光学*, 2026, 19(2): 288-298. doi: 10.37188/CO.2025-0125

ZHAI Jie, LU Yu, WANG Xin-xin, XIA Yuan-qin. Quantitative prediction of laser-cut slag adhesion by integrating image and frequency-domain features[J]. *Chinese Optics*, 2026, 19(2): 288-298. doi: 10.37188/CO.2025-0125

在线阅读 View online: <https://doi.org/10.37188/CO.2025-0125>

您可能感兴趣的其他文章

Articles you may be interested in

基于异构光子神经网络的多模态特征融合

Multimodal feature fusion based on heterogeneous optical neural networks

中国光学 (中英文). 2023, 16(6): 1343 <https://doi.org/10.37188/CO.2023-0036>

基于深度降噪卷积神经网络的宽波段共相检测研究

Broad-band co-phase detection based on denoising convolutional neural network

中国光学 (中英文). 2024, 17(6): 1329 <https://doi.org/10.37188/CO.2024-0079>

光电混合的光学卷积神经网络的片上训练及其抗噪性

On-chip training and its noise immunity for hybrid optical-electronic optical convolutional neural networks

中国光学 (中英文). 2025, 18(5): 1124 <https://doi.org/10.37188/CO.2025-0016>

多尺度注意力融合的图像超分辨率重建

Image super-resolution reconstruction with multi-scale attention fusion

中国光学 (中英文). 2023, 16(5): 1034 <https://doi.org/10.37188/CO.2023-0020>

基于光照模型的细胞内镜图像不均匀光照校正算法

Non-uniform illumination correction algorithm for cytoendoscopy images based on illumination model

中国光学 (中英文). 2024, 17(1): 160 <https://doi.org/10.37188/CO.2023-0059>

融合遗传算法和BP神经网络的光斑定位方法

Positioning algorithm for laser spot center based on BP neural network and genetic algorithm

中国光学 (中英文). 2023, 16(2): 407 <https://doi.org/10.37188/CO.2022-0084>

文章编号 2097-1842(2026)02-0288-11

融合图像与频域特征激光切割挂渣量化预测

翟杰¹, 芦宇^{1*}, 王鑫鑫¹, 夏元钦²

(1. 天津职业技术师范大学 电子工程学院, 天津 300222;

2. 河北工业大学 河北省先进激光技术与装备重点实验室, 天津 300401)

摘要:为实现激光切割熔渣附着精准量化与工艺优化,本研究探索一种基于图像与频域特征的卷积神经网络(CNN)预测方法。构建包含2160张1 mm厚304不锈钢切割端面图像数据集。基于该数据集,采用高斯模糊、自适应阈值及形态学闭运算等图像处理算法,精确提取了挂渣的面积、高度及周长,将它们作为量化特征。为评估不同特征预测潜力,采用RGB图像及其经二值化处理小波包分解(WPD)频域图像作为输入,并系统对比了VGG16、ResNet50和DenseNet121三种CNN架构回归性能。结果表明,在RGB图像输入路径下,VGG16网络对挂渣面积和高度预测最为精准,其平均绝对误差(MAE)分别达到0.019 mm²和0.044 mm。而对于更能反映动态过程状态的轮廓周长特征,WPD频域输入路径的预测效果显著提升,MAE降至0.094 mm,归一化平均误差(nMAE)为5.25%,且其预测值与真实值间拟合斜率与决定系数 R^2 分别为0.83与0.86,呈现强线性关系。本研究证实,VGG16网络在熔渣特征预测中具备良好适用性,且WPD频域特征能更有效地捕捉激光切割过程瞬态信息,所提出方法可作为工艺智能评估与闭环优化的可靠量化工具。

关键词:挂渣特征;卷积神经网络;小波包分解;激光切割工艺

中图分类号: TG485

文献标志码: A

doi: 10.37188/CO.2025-0125

CSTR: 32171.14.CO.2025-0125

Quantitative prediction of laser-cut slag adhesion by integrating image and frequency-domain features

ZHAI Jie¹, LU Yu^{1*}, WANG Xin-xin¹, XIA Yuan-qin²

(1. School of Electronic Engineering, Tianjin University of Technology and Education, Tianjin 300222, China;

2. Hebei Key Laboratory of Advanced Laser Technology and Equipment, Hebei University of Technology, Tianjin 300401, China)

* Corresponding author, E-mail: luyu@tute.edu.cn

Abstract: To achieve precise quantification of laser cutting slag adhesion and process optimization, this study investigates a convolutional neural network (CNN)-based prediction method that integrates both image and frequency-domain features. A dataset of 2160 cross-sectional images of 1 mm thick 304 stainless steel was constructed. From these images, key cross characteristics—area, height, and perimeter were accurately ex-

收稿日期: 2025-09-29; 修订日期: 2025-10-27

基金项目: 天津市科技计划项目(No. 24YDTPJC00510); 河北省先进激光技术与装备重点实验室基金(No. HBKL-ALTE2025003)

Supported by Tianjin Science and Technology Program Project (No.24YDTPJC00510); Hebei Key Laboratory of Advanced Laser Technology and Equipment (No. HBKL-ALTE2025003)

tracted using a combination of image processing techniques including Gaussian blur, adaptive thresholding, and morphological closing operations. To evaluate the predictive potential of different input representations, both RGB images and binarized images transformed via wavelet packet decomposition (WPD) were used as model inputs. The regression performance of three CNN architectures-VGG16, ResNet50, and DenseNet121 was systematically compared. Experimental results demonstrate that VGG16 achieved the highest prediction accuracy for dross area and height using RGB images, with mean absolute errors (MAE) of 0.019 mm² and 0.044 mm, respectively. For predicting the perimeter, which better reflects dynamic process behavior, the WPD frequency-domain input path yielded a significantly improved MAE of 0.094 mm and a normalized MAE (nMAE) of 5.25%. The regression fit between predicted and actual values showed a slope of 0.83 and a coefficient of determination (R^2) of 0.86, indicating a strong linear correlation. This study confirms the effectiveness of VGG16 in predicting dross-related features and demonstrates the capability of WPD-derived frequency-domain features in capturing transient process information during laser cutting. The proposed methodology offers a reliable quantitative tool for intelligent process evaluation and closed-loop optimization.

Key words: dross features; convolutional neural networks; wavelet packet decomposition; laser cutting process

1 引言

激光切割技术在工业化领域快速发展,主要研究方向为提高切割质量,优化切割参数以减少切口粗糙度、切缝宽度、热影响区宽度和挂渣现象。早期, Gabzdy 通过观察切割边缘颜色变化和挂渣评估切割质量,他发现氮气作为辅助气体能提供更好的切割质量,但效率较低^[1]。Shariff 等人分析了钛与低碳钢在氧气与氩气辅助下的切割质量,发现优化后氩气更适合钛金属切割,但挂渣问题明显^[2]。陈宇翔等人结合切缝宽度和挂渣高度,提出综合评价方法。他们通过优化 GH3128 高温合金钢的切割参数,显著降低了挂渣厚度,将其降至 60 μm ,综合评价值提升至 96.8^[3]。Parthiban 等人利用热影响区宽度进行切口质量评估,并用响应面法优化奥氏体不锈钢的切割参数^[4]。王勇等人通过定量分析切口挂渣量,并采用共焦显微镜和响应面法与遗传算法优化 304 不锈钢的切割工艺^[5]。Shin J S 等人通过熔渣质量分析,采用分段切割速度优化 304L 不锈钢的挂渣量^[6-9]。

随着神经网络的发展,卷积神经网络(CNN)与实验设计方法相结合,被应用于高质量激光加工工艺参数优化^[10-14],并成为激光切割检测与质量评估的重要工具^[15-20]。Tatzel 和 Leon 采用 VGG16 网络架构与 RGB 图像方法,成功估计激光切割金

属边缘的粗糙度。其粗糙度预测误差为 2.7 μm ~5.7 μm ,可靠性高于传统设备,同时应用 LRP 技术可视化 CNN 决策过程,揭示切割边缘特征与工艺参数的复杂关系^[21-22]。残差神经网络(ResNet50)通过残差学习机制解决了深层网络的梯度消失问题,显著提升了性能,并在 ImageNet 竞赛中获胜^[23-24]。ResNet50 在医学及农业领域的图像处理中具有优势,通过独特的残差学习机制有效解决了深层网络训练中的关键问题,使其在图像特征学习和复杂任务中表现出显著优势,准确率高^[25-28]。

本文旨在通过构建一种神经网络深度学习方法,对激光切割端面挂渣进行精准量化评估与预测,为工艺参数优化提供依据。本研究以 1 mm 厚 304 不锈钢为实验对象,通过全因子实验获取了 2160 张切割端面图像,构成样本数据集。采用高斯模糊、自适应阈值与形态学闭运算相结合的策略,精确分割并提取出挂渣轮廓,量化其面积、高度与周长三个关键特征。在此基础上,进一步对比 VGG16、ResNet50 及 DenseNet121 三种卷积神经网络架构的预测性能。为提升特征表征能力,除原始 RGB 图像输入外,还引入经二值化处理小波包分解图像作为另一输入路径,重点探讨频域特征对挂渣轮廓描述能力的增强作用。模型评估综合采用平均绝对误差与归一化平均绝对误差两项指标,旨在全面比较不同网络在不同挂渣

特征预测任务中的精度与稳定性。通过上述实验设计与分析,本文不仅明确了各网络模型在挂渣量化任务中的适用性,还验证了以挂渣周长作为核心评判指标的有效性及其与工艺状态的内在关联,并为实现激光切割质量智能评估与工艺优化提供了新思路与方法支撑。

2 实验方案与图像采集

2.1 激光切割实验

采用锐科 RFL-C1000 输出功率为 1000 W 精密光纤激光切割机,喷嘴与金属板距离为 2 mm,使用 1 MPa 压缩空气,切割速度设计范围为 5 mm/s~20 mm/s,离焦量设计范围为 -0.5 mm~1 mm,获得 60 个不锈钢(304)切边,厚度均为 1 mm,从而得到不同切口边缘的挂渣特征样品。通过全因子实验法,组合出 20 组不同的工艺参数,从而获得 60 个有效样本(排除误切情况)。每个样本均为长 60 mm、宽 6 mm 的矩形块。为确保分析区域内工艺参数的稳定性,仅选取每个样本边缘中间 54 mm 的区段进行后续处理。本研究共收集到 60 件符合标准的样本,确保数据具有代表性与可靠性。这些样本将为后续的分析与研究提供基础数据支持。

2.2 图像处理与挂渣轮廓提取

由于光照不均匀会导致金相显微镜对激光切割端面成像对比度差,采用融合算法来精确提取激光切割边缘的挂渣特征,具体流程如图 1 所示。



图 1 激光切割挂渣轮廓算法流程图

Fig. 1 Algorithm flowchart for extracting cross contours in laser cutting

图 2(彩图见期刊电子版)给出了挂渣轮廓提取过程图。图 2(a)给出激光切割原始图像,用 9×9 卷积核,标准差为 2 的高斯模糊核,有效去除切割端面高频噪声,保留边缘的挂渣轮廓,如图 2(b)所示。采用偏移量为 4 的自适应阈值分割增强了图像对比度,使挂渣区域与背景分离更加清晰。高斯模糊和自适应阈值分割处理后图

像,如图 2(c)所示。再通过形态学闭运算进行轮廓提取,将图像中检测到边缘蓝色线条拟合为红色线条,即为挂渣轮廓,如图 2(d)所示。考虑到在工作状态下进行检测会出现不同切割功率对工业相机成像不同曝光的情况,将金相显微镜成像图片进行模拟曝光处理,仍可以提取挂渣轮廓,如图 3(彩图见期刊电子版)所示。




图 2 挂渣轮廓提取过程。(a) 原始图像;(b) 高斯模糊;(c) 自适应阈值分割;(d) 形态学闭运算;(e) 二值化轮廓图

Fig. 2 Slag adhesion contour extraction process. (a) Original image; (b) Gaussian blur; (c) adaptive threshold segmentation; (d) morphological closing operation; (e) binary contour map




图 3 不同曝光情况下的挂渣轮廓提取过程。(a) 原始图像;(b) 高斯模糊;(c) 自适应阈值分割;(d) 形态学闭运算;(e) 二值化轮廓图

Fig. 3 Slag adhesion contour extraction process under varying exposure conditions. (a) Original image; (b) Gaussian blur; (c) adaptive threshold segmentation; (d) morphological closing operation; (e) binary contour map

2.3 挂渣图像预处理

在图像采集过程中,图像尺寸一致性不好,且背景中含有一定的非挂渣信息区域,会对后续挂渣分析造成干扰。为提升分析结果的精确度,对每幅图像实施规范化预处理。将所有图像通过裁剪和缩放操作,统一调整至 $224 \text{ pixel} \times 224 \text{ pixel}$ 标准尺寸,如图 4(彩图见期刊电子版)所示。为确保分析精确性和结果可比性,需对在不同激光切割参数下获取的切口样本原始图像进行标准化处理。将所有 RGB 图像分辨率调整至 1000 像素宽和 1800 像素高,每个像素大小为 $1 \mu\text{m} \times 1 \mu\text{m}$,实现图像尺寸一致性。



图 4 调整后切口挂渣图

Fig. 4 Adjusted image of slag adhesion at cut edge

2.4 小波包能量图谱生成

RGB 挂渣原始图像如图 5(a) (彩图见期刊电子版) 所示, 随后对二值化图像图 5(b) (彩图见期刊电子版) 信号进行 3 层小波包分解, 共得到 8 个频域子带, 分别编号为 1-8, 其中低频子带 1~3, 高频子带 6~8, 如图 5(c) (彩图见期刊电子版) 所

示。采用双线性插值将其统一缩放至 224 pixel×224 pixel, 通过计算各子带内能量值来反映对应频域挂渣特征强度。图 5(c) 横坐标代表缩放后的轮廓像素所在位置, 纵坐标代表各频带能量值, 可直观呈现挂渣边缘不同频域的能量分布。其中, 低频子带高能量对应图 5(a) 中挂渣轮廓波动大的区域, 低频子带低能量对应轮廓平缓位置。高频子带高能量表明挂渣边缘存在毛刺, 低能量说明轮廓相对平滑。通过 WPD 频带能量捕捉挂渣波动与细微毛刺, 为切割状态与工艺优化提供直接频谱判据。

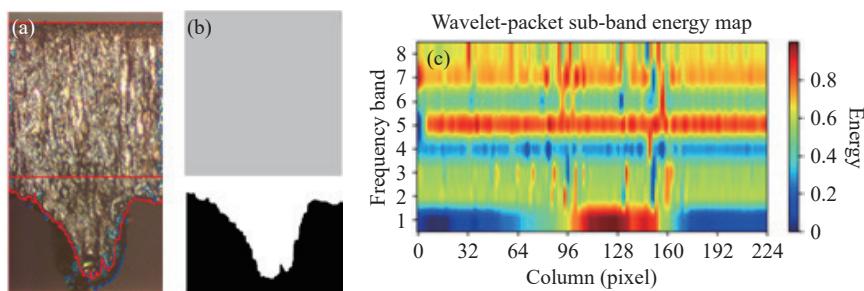


图 5 (a) 原始 RGB 轮廓; (b) 二值轮廓; (c) 能量图

Fig. 5 (a) Original RGB profile; (b) binary contour; (c) WPD energy map

3 模型和方法

3.1 卷积神经网络

VGG16 架构能够从挂渣图像中提取更详细

的多层次特征, 更准确地捕捉挂渣边缘的细微变化, 从而实现对激光切割挂渣面积、高度与周长的精准预测。评估三种模型在回归任务中的性能, 设计双路径 VGG16 神经网络架构, 如图 6 (彩图见期刊电子版) 所示。

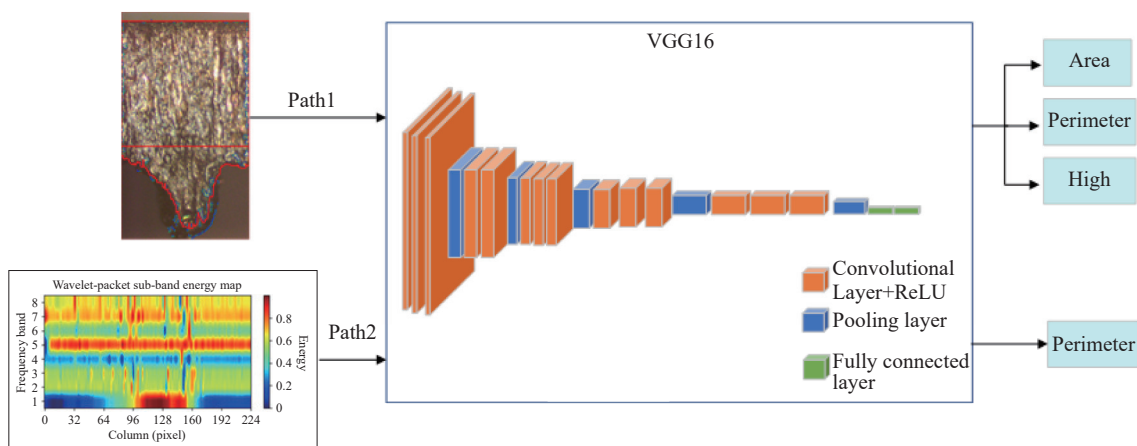


图 6 VGG16 模型进行激光切割挂渣识别与特征分析结构图

Fig. 6 Architecture of the VGG16 model used for slag identification and feature analysis

第一路径为将 RGB 原始三通道图像做为输入, 由三个独立回归神经元分别预测面积、高度与周长。第二路径为将 WPD 频带能量图做为输

入, 通过单一回归神经元预测周长。RGB 路径采用 ImageNet 预训练权重并微调全连接层, WPD 路径采用随机初始化的网络权重, 并完全基于挂

渣子带数据集进行训练。网络均使用均方误差 (MSE) 作为损失函数, 通过 Adam 优化器进行端到端训练, 实现几何参数的精准回归。

VGG16 网络结构包括 13 个卷积层和 2 个全连接层, 共 15 层 (不包括池化和 dropout 层)。这种结构的主要特点是使用了多个连续的 3×3 小卷积核。通过堆叠多个卷积层, 网络可以学习到更复杂的特征, 从而提高模型对挂渣特征的评估性能。为系统评估深度学习模型在激光切割挂渣形态回归任务中的性能, 引入 ResNet50 与 DenseNet121 两种经典网络架构进行对比分析。ResNet50 通过残差连接结构有效缓解了深层网络的梯度消失问题, 具备从局部细节到全局轮廓的多层次特征聚合能力。DenseNet121 则采用密集连接机制, 通过特征复用与梯度增强, 在保持参数效率的同时提升特征传递效能。

3.2 数据集划分

数据库由 60 个样本组成, 对应 60 条边和 2160 张图像。它被分成三部分, 其中训练集占比 70%、验证集占比 20%、测试集占比 10%。训练集用于学习模型参数, 验证集是超参数优化的必要条件。当划分数据时, 必须保证特定参数组合, 一个样本所有图片只存在于两个集合中的其中一个而不是随机分割图片。否则可能会高估 CNN 表现, 导致模型过拟合。

3.3 评价

在训练过程中, 使用均值平方误差 (MSE) 作为损失函数, 为评估回归质量, 分别计算了挂渣面积、挂渣高、挂渣周长均值平方误差, 评估指标选用 MAE, 由公式 (1) 给出。考虑到挂渣面积、挂

渣高度和挂渣周长间的量纲差异会导致其 MAE 无法对比。依据公式 (2) 采用归一化平均绝对误差 nMAE 进行评价。决定系数 R^2 用于衡量模型预测值与真实值之间的线性拟合优度, 其计算公式如式 (3) 所示:

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{Y}_i - Y_i|, \quad (1)$$

$$nMAE = \frac{\sum_{i=1}^N |\hat{Y}_i - Y_i|}{\sum_{i=1}^N |Y_i|}, \quad (2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2}, \quad (3)$$

其中 N 为测试图像数量, Y_i 为第 i 个样本的真实值, \hat{Y}_i 为第 i 个样本的预测值, \bar{Y} 为样本平均值。

4 结果与分析

4.1 基于 RGB 轮廓图的挂渣特征预测结果

首先利用轮廓提取技术获得挂渣区域二值轮廓图, 再分别用 VGG16、ResNet50 和 DenseNet121 对挂渣面积、挂渣高度、挂渣周长 3 个特征进行回归。表 1 给出了 3 种模型在测试集上对挂渣面积、挂渣高度与挂渣周长特征预测 MAE 与 nMAE 对比。

表 1 三种 CNN 模型基于 RGB 图像挂渣特征预测 MAE 与 nMAE 结果对比

Tab. 1 Comparison of MAE and nMAE for slag feature prediction using three CNN models on RGB images

网络架构	挂渣面积 MAE (mm ²)	挂渣高度 MAE (mm)	挂渣周长 MAE (mm)	挂渣面积 nMAE (%)	挂渣高度 nMAE (%)	挂渣周长 nMAE (%)
ResNet50	0.023	0.046	0.106	8.48	9.72	5.91
VGG16	0.019	0.044	0.117	7	9.38	6.49
DenseNet121	0.029	0.054	0.106	10.6	11.4	5.91

由表 1 可知, 3 种 CNN 架构在挂渣特征预测任务中均表现出稳定收敛能力, 可作为深度学习模型对挂渣形态进行预测。VGG16 通过小卷积核堆叠, 对挂渣面积、挂渣高度特征训练预测上具有显著优势, ResNet50 与 DenseNet121 更适合

对挂渣周长进行预测。VGG16 在挂渣面积预测中 MAE 最低, 较 ResNet50 和 DenseNet121 分别降低 17.47% 和 36.46%, 而 ResNet50 与 DenseNet121 在挂渣周长预测中误差相近且并未显著优于 VGG16 预测结果。

图 7(彩图见期刊电子版)展示了 3 种挂渣特征预测值与真实值的线性拟合结果, 并通过斜率与 R^2 进行了量化评估。分析指出, 挂渣面积的预测在整个区间内误差小、相关度高。然而, 挂渣高度预测在中间值区间出现被高估的情况, 且整体 R^2 较低。此外, 挂渣周长预测在小范围区间表

现出高估, 其整体 R^2 值同样偏低。

由图 7(a)与 7(d)可见, ResNet50 与 VGG16 在挂渣面积预测中拟合曲线与真值线吻合得较好, 尤其是 VGG16 拟合斜率达到 0.825, 同时 R^2 均达到 0.94, 表明 VGG16 模型对挂渣面积的预测效果最好。

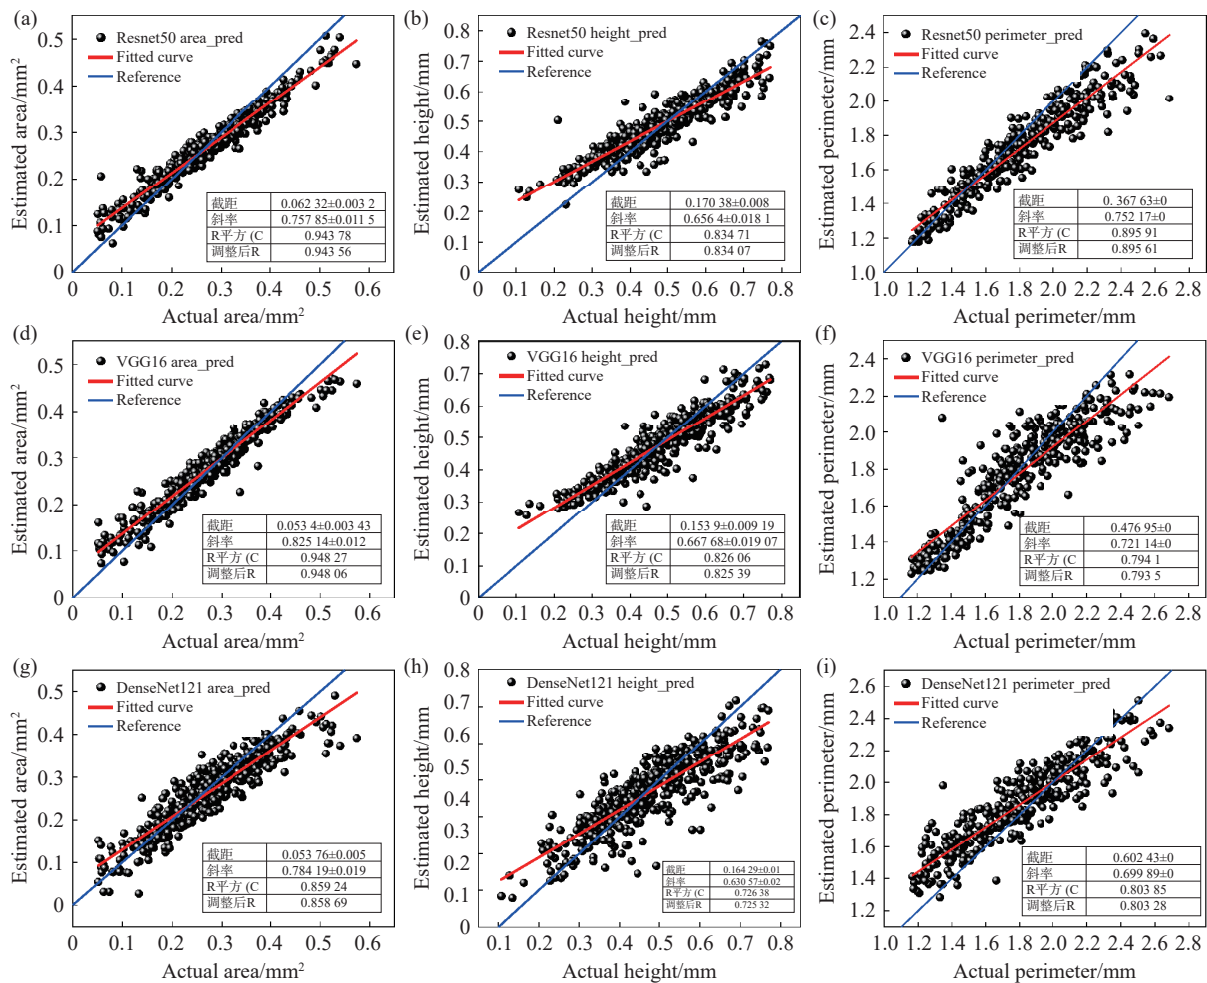


图 7 三种网络架构 RGB 模型预测-真实散点对比。(a)、(b)、(c) 分别为面积、高度、周长 ResNet50 预测结果; (d)、(e)、(f) 分别为面积、高度、周长 VGG16 预测结果; (g)、(h)、(i) 分别为面积、高度、周长 DenseNet121 预测结果

Fig. 7 Comparison of predicted vs. actual scatter plots for three CNN architectures with RGB image input. (a), (b), (c) Scatter plots of predicted vs. actual values for area, height, and perimeter using ResNet50; (d), (e), (f) scatter plots of predicted vs. actual values for area, height, and perimeter using VGG16; (g), (h), (i) scatter plots of predicted vs. actual values for area, height, and perimeter using DenseNet12

由图 7(b)与 7(e)可见, Resnet50 与 VGG16 在挂渣高度预测中, 其拟合曲线与参考线的吻合度均较差, 拟合线斜率均未达到 0.7, 决定系数 R^2 均未达到 0.85, 表明模型对挂渣高度预测精度较差。挂渣高度主要表征挂渣瞬时残余金属垂直堆积状态, 反映了切割过程中气压状态不稳定。RGB 图像成像畸变会导致挂渣高度特征提取存

在误差, 同时低频轮廓池化丢失特征也将导致高度预测不准确。

由图 7(c)与 7(f)可见, Resnet50 在预测挂渣周长方面表现更优, 其拟合斜率为 0.75, 决定系数 R^2 为 0.89, 两者均高于 VGG16, 说明 ResNet50 对挂渣边缘整体捕捉能力更优。由图 7(g)、7(h)、7(i)可知, DenseNet121 的拟合斜率与决定系数 R^2

较 ResNet50、VGG16 整体偏低, 尤其图 7(h) 中拟合线斜率仅 0.631, 表明 DenseNet121 对挂渣高度预测均处于弱勢。

挂渣周长可用于表征切割边缘轮廓复杂度与不规则性, 可实时反映切割过程中受外部环境变化或设备工艺参数漂移导致挂渣波动, 其可作为评估切割系统工作状态稳定性的关键指标。针对 RGB 挂渣图像周长预测, 3 种网络架构预测结果的拟合斜率均小于 0.75, 决定系数 R^2 为 0.79~0.89, 表明该模型虽能捕捉宏观轮廓, 但 RGB 图像进行挂渣特征回归训练存在局限性, 低频轮廓特征池化丢失会导致周长预测不准确。可通过 WPD 进一步提取挂渣轮廓细节特征, 有利于提高训练准确性。

4.2 基于 WPD 特征的挂渣预测结果

本研究从频域分析角度, 利用 WPD 将轮廓信号分解为不同频带子带, 分析高、低频能量分布与挂渣轮廓周长相关机制, 如图 8, 图 9(彩图见期刊电子版) 所示。

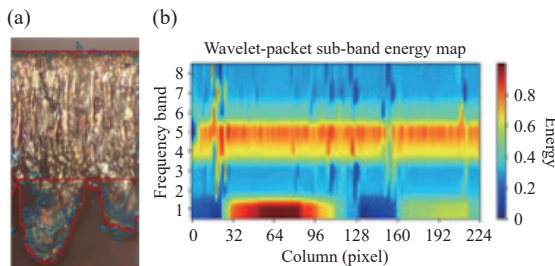


图 8 高挂渣轮廓表征。(a) RGB 图; (b) WPD 图

Fig. 8 Characterization of the high-hanging slag contour.

(a) RGB image; (b) WPD diagram

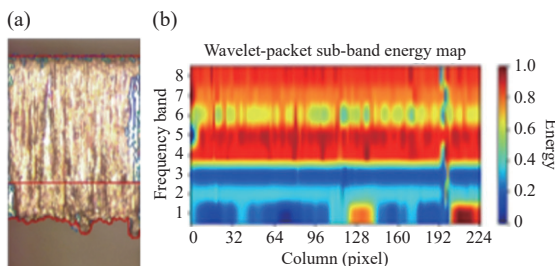


图 9 低挂渣轮廓表征。(a) RGB 图; (b) WPD 图

Fig. 9 Characterization of the low-hanging slag contour.

(a) RGB image; (b) WPD diagram

如图 8 所示, 图 8(a) RGB 图中挂渣轮廓特征与小波包子带能量图 8(b) 呈现出明确的对应关系。RGB 挂渣轮廓平缓区域对应低频子带低能量区, 轮廓波动突出区域则与低频子带高能量区吻合。图 8 中挂渣周长计算值达 2.58 mm,

表明低频子带高能量可作为预测挂渣周长的有效特征。图 8(b) 中高频子带能量整体偏低, 表明该区域毛刺等细节特征不明显, 挂渣边缘相对平滑。

图 9 呈现了与图 8 完全不同的挂渣轮廓特征, RGB 挂渣轮廓图形态平缓、波动区域少、周长计算值为 1.32 mm, 对应低频子带低能量区, 轮廓波动受低频能量主导, 进一步验证了小波包能量特征可表征挂渣周长这一结论。图 9(b) 中高频子带能量显著较高, 揭示了该区域挂渣边缘存在大量细密毛刺与微小起伏, 形成了复杂的局部纹理。

表 2 给出了频域训练下挂渣周长预测的 MAE 与 nMAE 值。从表 2 可知, WPD 在 VGG16 训练下挂渣周长预测精度相对于 RGB 在 VGG16、Resnet50 与 DenseNet121 网络架构的 MAE 分别提升 19.3%、11.5%、11.4%。VGG16 是三种模型中表现最优的架构。这表明 VGG16 网络结构与 WPD 提取的频域特征适配性更强, 能借助频域信息补充 RGB 轮廓图缺失细节, 提升周长预测精度。图 10(彩图见期刊电子版) 给出 VGG16 在 WPD 频域路径训练下挂渣周长预测散点分布及拟合曲线。

表 2 WPD 频域训练下挂渣周长预测 MAE 与 nMAE
Tab. 2 MAE and nMAE for slag perimeter in frequency-domain training

模型	WPD 频域 MAE(mm)	WPD 频域 nMAE(%)
ResNet50	0.145	8.11
VGG16	0.094	5.25
DenseNet121	0.131	7.31

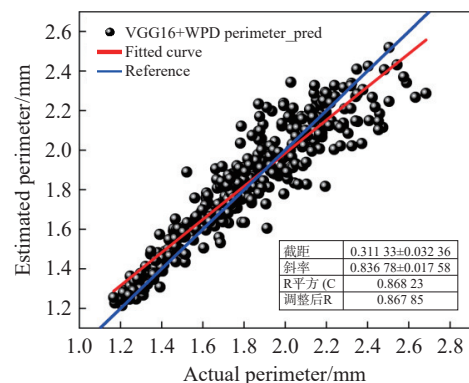


图 10 VGG16-WPD 周长预测散点图

Fig. 10 Scatter plot of perimeter predictions using VGG16 trained on WPD features

由图 10 可知, 在挂渣周长预测任务中, VGG16 网络架构与 WPD 方法相结合可显著优化测量结果。相较于 RGB 训练路径, VGG16 在 WPD 频

域训练下, 周长预测拟合斜率从 0.72 提升至 0.83, 决定系数 R^2 从 0.79 升至 0.86, 解决了系统性低估问题、增强预测值与真实值的线性相关性。借助 WPD 提取频域信息, 可精准捕捉挂渣边缘毛刺、局部凸起等高频细节。VGG16 与 WPD 训练路径能更清晰地关联挂渣细节特征与激光切割工艺状态, 从而提升了挂渣周长预测精度, 为后续挂渣类型分类、激光切割工艺精准优化提供可靠支撑。

4.3 CNN 模型对挂渣特征预测机制的可视化分析

通过对比分析 CAM 热图与预测熵, 研究 VGG16、ResNet50 与 DenseNet121 模型从 RGB 空间与 WPD 频域中学习挂渣鉴别性预测机制。表 3 给出了 3 种模型在双支路 CAM 熵值。图 11 与图 12(彩图见期刊电子版)分别展示了 RGB 空间域和 WPD 频域下不同模型的可视化结果, 直观呈现了模型对目标特征的关注差异。

表 3 三种模型 RGB 与 WPD 支路熵对比
Tab. 3 Comparison of entropy between RGB and WPD branches in three models

模型	RGB 支路熵	WPD 支路熵
VGG16	2.62	2.41
ResNet50	3.12	3.68
DenseNet121	2.80	2.96




图 11 不同 CNN 模型的特征可视化对比。(a) 样本; (b) VGG16 可视化图; (c) Resnet50 可视化图; (d) RGB DenseNet121 可视化图

Fig. 11 A comparison of feature activation maps from different CNN models. (a) Input; (b) feature maps from VGG16; (c) feature maps from ResNet50; (d) feature maps from DenseNet121

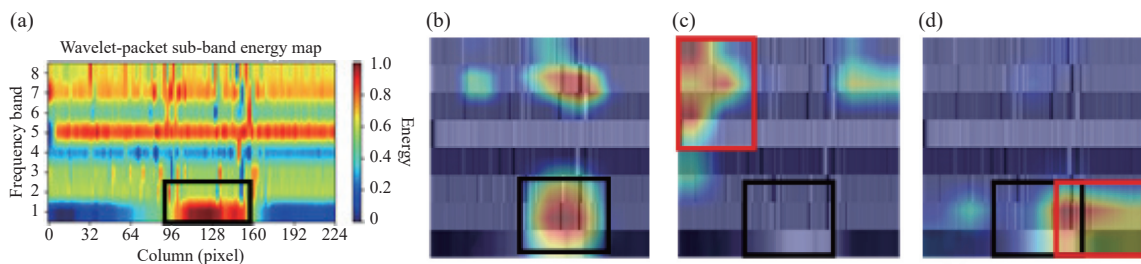


图 12 不同 CNN 模型在 WPD 表征上的特征可视化对比。(a) 样本; (b) VGG16 可视化图; (c) Resnet50 可视化图; (d) DenseNet121 可视化图

Fig. 12 Comparative analysis of CNN feature visualizations on a WPD representation. (a) Input; (b) feature maps from VGG16; (c) feature maps from ResNet50, and (d) feature maps from DenseNet121

如表 3 所示, VGG16 模型在 RGB 图像与 WPD 频域中均呈现出最低的预测熵值。图 11(b) CAM 热图对挂渣轮廓聚焦最为准确, 表明 VGG16 模型密集卷积层结构有利于提取 RGB 空间细节以及特征形成决策机制。图 11(c) 中, ResNet50 模型热图因残差全局融合偏离真实轮廓并向背景大面积扩散, 熵值最高; 图 11(d) 中, DenseNet121 模型虽无严重扩散, 却出现轻微边缘偏移, 熵值居中。在 WPD 频域分析中, 图 12(b) 通过热图中黑框标注清晰呈现了 VGG16 模型能够稳定锁定 WPD 所揭示低频、高能量区域, 实现低熵决策机制。由图 12(c) 可知, ResNet50 模型残差连接机制在挂渣检测中产生了负面作用, 其强制全局特

征融合导致模型注意力误聚焦于高频区域, 从而引发热图扩散与高预测熵。图 12(d) DenseNet121 模型密集连接机制引发了特征整合冲突, 导致热图定位发生偏移与预测熵升高, 体现其决策焦点分散局限性。

4.4 挂渣特征与工艺参数相关性

采用随机森林回归算法, 分别建立切割速度与离焦量对挂渣面积、挂渣周长和挂渣高度的预测模型。通过网格搜索优化超参数, 即 4 种树数量, 4 种叶节点, 5 种特征采样比例, 通过 80% 训练集和 20% 测试集进行模型训练与验证。3 个模型预测性能由表 4 给出。

从表 4 可以看出, 挂渣面积的预测效果最佳,

这表明优化切割工艺对控制挂渣面积最为有效。根据经验,将挂渣面积阈值设定为 0.2 mm^2 。在所有切割工艺参数中,挂渣特征超过该阈值的样本占总样本的 86%,该比例被定义为挂渣超标率。以挂渣超标率作为质量评分目标,计算得到挂渣指标。设定离焦量范围为 $-1 \sim 0 \text{ mm}$,间隔为 0.2 mm ;切割速度为 $10 \sim 20 \text{ m/s}$,间隔为 2 m/s 。通过随机森林模型优化后的激光切割工艺参数预测结果如表 5 所示。

表 4 随机森林模型三种挂渣特征预测性能

Tab. 4 Prediction performance of three slag adhesion features in the random forest model

挂渣特征	RMSE	MAE	R^2
面积	0.029	0.022	0.901
高度	0.055	0.040	0.810
周长	0.215	0.157	0.629

表 5 激光切割工艺参数优化结果

Tab. 5 Optimization results for laser cutting process parameters

离焦量 (mm)	速度 (m/s)	预测挂渣面积平均值 (mm^2)	超标率 (%)
-0.8	10	0.18	0
-1	10	0.18	0
-0.6	10	0.19	20
-0.8	12	0.19	20
-1	12	0.20	30

表 5 给出了 5 组工艺参数优化结果,并进行切割实验,采集 50 张切割端面图片,部分图片挂渣效果如图 13 所示。




图 13 不同离焦量与速度下切割端面挂渣轮廓。(a) -0.8 mm 、 10 m/s , (b) -1 mm 、 10 m/s , (c) -0.6 mm 、 10 m/s , (d) -1 mm 、 12 m/s , (e) -0.8 、 12

Fig. 13 Slag profiles under different defocus distances and cutting speeds. (a) -0.8 mm , 10 m/s ; (b) -1 mm , 10 m/s ; (c) -0.6 mm , 10 m/s ; (d) -1 mm , 12 m/s ; (e) -0.8 mm , 12 m/s

参考文献:

- [1] GABZDY J T. Effects of gases on laser cutting of stainless steels[C]. *Proceedings of the Laser Materials Processing*

用 MSE 方法计算挂渣面积与预测结果误差率,分别为 2.1%、3.5%、1.5%、3.9%、4.6%,均小于 5%。

5 结 论

本研究构建了一套融合高斯模糊、自适应阈值分割与形态学闭运算图像处理方法,以实现挂渣轮廓稳定提取与图像二值化。在此基础上,采用 VGG16、ResNet50 与 DenseNet121 三种卷积神经网络架构对提取轮廓特征进行训练与综合对比。结果表明,在 RGB 图像输入条件下,VGG16 在挂渣面积预测方面表现最优,MAE 最小,为 0.019,但在挂渣周长预测方面,ResNet50 与 DenseNet121 MAE 略优于 VGG16。

WPD 能量图特征被证明可有效表征挂渣轮廓周长。通过将 RGB 轮廓图像转换至小波包频域进行特征提取与训练,实现了对挂渣周长的精准预测。结果表明,频域信息特征显著提升了 VGG16 对挂渣周长的预测能力,nMAE 由 6.49% 降至 5.25%,回归拟合斜率由 0.72 提升至 0.84, R^2 由 0.79 提高至 0.87。然而,ResNet50 与 DenseNet121 在频域中的预测性能反而有所下降。通过 CAM 热图与预测熵进行模型行为分析,探究 3 种网络架构性能差异机理。分析显示,VGG16 凭借其密集卷积结构,在 RGB 与频域中均能实现低熵、高定位精度特征学习。在频域分析中,ResNet50 与 DenseNet121 采用残差或密集连接机制,引发特征过度融合,削弱了热图对关键频域分量的聚焦能力。表现为模型注意力机制从决定挂渣轮廓的 WPD 低频、高能量核心分量上发生扩散与偏移。

通过随机森林模型量化了工艺参数与挂渣面积关联关系,完成参数优化。结果表明,当离焦量优化为 -1 mm 、 -0.8 mm 、 -0.6 mm ,切割速度设定为 10 m/s 与 12 m/s 参数组合时,挂渣超标率从 86% 显著降低至 30%,且模型预测误差小于 5%。本文研究为激光切割质量精准控制与工艺优化提供了有效技术途径。

- Conference, Laser Institute of America, 1996: 39-44.
- [2] SHARIFF S M, SUNDARARAJAN G, JOSHI S V. Parametric influence on cut quality attributes and generation of processing maps for laser cutting[J]. *Journal of Laser Applications*, 1999, 11(2): 54-63.
- [3] 陈宇翔, 高亮. 正交法分析激光切割高温合金钢工艺参数[J]. *激光与光电子学进展*, 2016, 53(11): 111403.
CHEN Y X, GAO L. Analysis of processing parameters for laser cutting high-temperature alloy steel by orthogonal method[J]. *Laser & Optoelectronics Progress*, 2016, 53(11): 111403. (in Chinese).
- [4] PARTHIBAN A, DHANASEKARAN C, SIVAGANESAN S, et al.. Modeling on surface cut quality of CO₂ laser cutting for Austenitic Stainless steel sheet[J]. *Materials Today: Proceedings*, 2020, 21: 823-827.
- [5] 王勇, 陈娇娇, 张鹏, 等. 基于响应面-遗传算法的不锈钢激光切割工艺参数优化与试验研究[J]. *应用激光*, 2023, 43(11): 85-94.
WANG Y, CHEN J J, ZHANG P, et al.. Process parameter optimization and experimental research on stainless steel laser cutting based on response surface-genetic method[J]. *Applied Laser*, 2023, 43(11): 85-94. (in Chinese).
- [6] SHIN J S, OH S Y, PARK H, et al.. High-speed fiber laser cutting of thick stainless steel for dismantling tasks[J]. *Optics & Laser Technology*, 2017, 94: 244-247.
- [7] OH S Y, SHIN J S, KIM T S, et al.. Effect of nozzle types on the laser cutting performance for 60-mm-thick stainless steel[J]. *Optics & Laser Technology*, 2019, 119: 105607.
- [8] SHIN J S, SONG K H, OH S Y, et al.. Laser cutting studies on 10-60 mm thick stainless steels with a short focus head for nuclear decommissioning[J]. *Optics & Laser Technology*, 2024, 169: 110121.
- [9] SHIN J S. Laser cutting study on 30 mm thick stainless steel for application in decommissioning of calandria shells in heavy-water reactors[J]. *Nuclear Engineering and Technology*, 2025, 57(3): 103242.
- [10] 陈达, 章轩, 赵圣斌, 等. 基于深度学习的激光熔覆层表面缺陷识别研究[J]. *光学学报*, 2025, 45(9): 0915001.
CHEN D, ZHANG X, ZHAO SH B, et al.. Surface defect recognition of laser cladding layer based on deep learning[J]. *Acta Optica Sinica*, 2025, 45(9): 0915001. (in Chinese).
- [11] 王颖, 高胜, 戴哲. 基于 CNN-Transformer 混合网络的焊缝激光条纹分割[J]. *中国激光*, 2024, 51(24): 2402110.
WANG Y, GAO SH, DAI ZH. Laser stripe segmentation of weld seam based on CNN-Transformer hybrid networks[J]. *Chinese Journal of Lasers*, 2024, 51(24): 2402110. (in Chinese).
- [12] 张臣, 胡佩佩, 朱新旺, 等. 基于高密度点云的激光焊接缺陷智能在线检测(特邀)[J]. *中国激光*, 2024, 51(4): 0402105.
ZHANG CH, HU P P, ZHU X W, et al.. Intelligent online detection of laser welding defects based on high density point clouds (invited)[J]. *Chinese Journal of Lasers*, 2024, 51(4): 0402105. (in Chinese).
- [13] 马炜鑫, 谢冠明, 林杰凯, 等. 基于机器视觉的激光焊接气孔缺陷智能检测方法[J]. *激光与光电子学进展*, 2026, 63(1): 0114012.
MA W X, XIE G M, LIN J K, et al.. Laser welding porosity defect detection method based on machine vision[J]. *Laser & Optoelectronics Progress*, 2026, 63(1): 0114012. (in Chinese).
- [14] 姚宇超, 周锐, 严星, 等. 基于卷积神经网络判定方法的激光微透镜阵列微米级加工工艺[J]. *光学精密工程*, 2024, 32(1): 43-52.
YAO Y C, ZHOU R, YAN X, et al.. Micron-level processing technology of microlens array (MLA) photolithography based on convolutional neural network[J]. *Optics and Precision Engineering*, 2024, 32(1): 43-52. (in Chinese).
- [15] REN X F, FAN J W, PAN R, et al.. Modeling and process parameter optimization of laser cutting based on artificial neural network and intelligent optimization algorithm[J]. *The International Journal of Advanced Manufacturing Technology*, 2023, 127(3): 1177-1188.
- [16] CHAKI S, BOSE D, BATHE R N. Multi-objective optimization of pulsed Nd: YAG laser cutting process using entropy-based ANN-PSO model[J]. *Lasers in Manufacturing and Materials Processing*, 2020, 7(1): 88-110.
- [17] 何鹏, 孙帆, 胡小方, 等. 小样本激光切割工艺参数预测模型优化[J]. *激光杂志*, 2021, 42(12): 170-175.
HE P, SUN F, HU X F, et al.. Optimization of prediction system for small sample laser cutting process parameters[J]. *Laser Journal*, 2021, 42(12): 170-175. (in Chinese).
- [18] 钟毅, 栾显晔, 李晓宇, 等. 碳钢板激光切割工艺分析及优化[J]. *制造技术与机床*, 2024(2): 38-45.
ZHONG Y, LUAN X Y, LI X Y, et al.. Analysis and optimization of laser cutting process of carbon steel plate[J]. *Manufacturing Technology & Machine Tool*, 2024(2): 38-45. (in Chinese).

- [19] FRANCESCHETTI L, PACHER M, TANELLI M, *et al.*. Dross attachment estimation in the laser-cutting process via Convolutional Neural Networks (CNN)[C]. *Proceedings of the 28th Mediterranean Conference on Control and Automation*, IEEE, 2020: 850-855.
- [20] ADELMANN B, SCHLEIER M, HELLMANN R. Laser cut interruption detection from small images by using convolutional neural network[J]. *Sensors*, 2021, 21(2): 655.
- [21] TATZEL L, LEÓN F P. Image-based roughness estimation of laser cut edges with a convolutional neural network[J]. *Procedia CIRP*, 2020, 94: 469-473.
- [22] TATZEL L, TAMIMI O A, HAUEISE T, *et al.*. Image-based modelling and visualisation of the relationship between laser-cut edge and process parameters[J]. *Optics & Laser Technology*, 2021, 141: 107028.
- [23] HE K M, ZHANG X Y, REN S Q, *et al.*. Deep residual learning for image recognition[C]. *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE, 2016: 770-778.
- [24] HE K M, ZHANG X Y, REN S Q, *et al.*. Identity mappings in deep residual networks[C]. *Proceedings of the 14th European Conference on Computer Vision*, Springer, 2016: 630-645.
- [25] AL-HAJJA Q A, ADEBANJO A. Breast cancer diagnosis in histopathological images using ResNet-50 convolutional neural network[C]. *Proceedings of the IEEE International IOT, Electronics and Mechatronics Conference*, IEEE, 2020: 1-7.
- [26] MUKTI I Z, BISWAS D. Transfer learning based plant diseases detection using ResNet50[C]. *Proceedings of the 4th International Conference on Electrical Information and Communication Technology*, IEEE, 2019: 1-6.
- [27] LIU Y, ZHANG Z L, LIU X, *et al.*. Deep learning-based image classification for online multi-coal and multi-class sorting[J]. *Computers & Geosciences*, 2021, 157: 104922.
- [28] MASCARENHAS S, AGARWAL M. A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification[C]. *Proceedings of 2021 International Conference on Disruptive Technologies for Multi-Disciplinary Research and Applications*, IEEE, 2021, 1: 96-99.

作者简介:



芦宇(1982—),男,黑龙江齐齐哈尔人,博士,讲师,硕士生导师,2007年哈尔滨工业大学获得硕士学位,2013年哈尔滨工业大学获得博士学位。主要从事激光加工技术、激光检测技术、非成像光学系统设计等方面的研究。E-mail: luyu@tute.edu.cn