

文章编号:1001-5078(2023)05-0685-08

· 激光应用技术 ·

基于 MCL-UNet 网络的激光熔覆层表面平整度识别

郭士锐, 刘银银, 崔陆军, 陈永骞, 郑博
(中原工学院机电学院, 河南 郑州 450007)

摘要:表面平整度是衡量多道搭接熔覆层表面质量的重要指标之一,为改进人工标注获取表面平整度耗时费力的问题,本文利用图像识别和语义分割神经网络方法提出了自动识别熔覆层表面平整度。针对搭接熔覆层特征,基于改进的 U-Net 与注意力机制(CBAM)提出一种用于熔覆层形貌的自动分割网络 MCL-UNet,优化改进 U-Net 模型,依据 CBAM 模块从通道维度和空间维度调整特征图层的权重信息,将 CBAM 模块以优化输入和输出的原则部署在网络上。在搭接熔覆层数据集上对改进的网络进行评估对比,实验结果表明,本文提出的 MCL-UNet 网络模型,其熔覆层分割效果在验证集上的平均 IoU 准确率为 93.76%,相比原始 U-Net 的 IoU 准确率提高了 5.81%,在测试集上 MCL-UNet 模型输出的表面平整度的平均相对误差为 3.2%,说明该模型可有效提高搭接熔覆层横截面形貌的分割精度,并能较准确输出表面平整度。

关键词:图像处理;表面平整度;语义分割;MCL-UNet 网络

中图分类号:TP302.1;TN249 **文献标识码:**A **DOI:**10.3969/j.issn.1001-5078.2023.05.007

Surface smoothness identification of laser cladding layer morphology based on MCL-UNet network

GUO Shi-rui, LIU Yin-yin, CUI Lu-jun, CHEN Yong-qian, ZHENG Bo

(School of Mechanical and Electrical Engineering, Zhongyuan University of Technology, Zhengzhou 450007, China)

Abstract: Surface smoothness is one of the most important indicators of the surface quality of multi-pass clad layer. In order to improve the time-consuming and laborious problem of manual annotation to obtain surface smoothness, an automatic identification method of surface smoothness of clad layer using image recognition and semantic segmentation neural network is proposed in this paper. An automatic segmentation network MCL-UNet for multi-pass clad layer morphology based on convolutional neural network U-Net and CBAM is presented. The weight information of the feature layer from channel dimension and spatial dimension is adjusted based on the CBAM module, the CBAM is deployed on the U-Net network with the principle of optimizing the input and output, and the evaluation of improved networks compared on a clad layer dataset is performed. The experimental results show that the MCL-UNet network achieves the average IoU accuracy of 93.76% on the validation dataset, which is 5.81% higher than the original U-Net. The aver-

基金项目:河南省研究生教育改革与质量提升工程项目(No. YJS2022AL057);中原工学院优势学科实力提升计划资助“学科骨干教师支持计划”项目(No. GG202220)与“骨干学科发展计划”项目(No. FZ202204);中原工学院研究生校企联合课程专项经费资助建设项目(No. LH202301);河南省重点研发与推广专项(科技攻关)项目(No. 232102220051)资助。

作者简介:郭士锐(1986-),男,汉,博士,副教授,主要研究方向为激光制造方面的研究。E-mail:laser@zut.edu.cn
收稿日期:2022-06-13

age relative error of the surface smoothness by the MCL-UNet model on the test dataset is 3.2 % , indicating that the model can effectively improve the segmentation accuracy of the cross-sectional morphology of the multi-pass clad layer, and can accurately output the surface smoothness.

Keywords: image processing; surface smoothness; semantic segmentation; MCL-UNet

1 引言

激光熔覆是一种先进的融合了多学科的表面改性技术,它通过高能量激光束与合金粉末同步作用在基体表面以熔凝成高质量冶金涂层,从而提升零件的综性能^[1-3]。在大面积零件损伤修复和涂层制备等实际工业应用中需要用到多道搭接激光熔覆,相比较单道激光熔覆,多道搭接激光熔覆因各层熔覆层间的复杂影响,搭接熔覆层横截面形貌的形成趋势与表面质量等更复杂于单道熔覆,而获取高质量的熔覆层是保证工业应用的先决条件,并且大面积激光熔覆涂层需要良好的表面质量以便有效减少后处理。

表面平整度是衡量搭接熔覆层表面质量的重要指标之一^[1,4],而激光熔覆工艺参数对熔覆层形貌成形起决定作用^[5],表面平整度可反映出熔覆层形貌信息进而对熔覆层质量优化具有重要影响。Guo-fu Lian^[6]等以 45 钢为基体, W6Mo5Cr4V2 为粉末,利用响应灰色关联分析(GRA)建立工艺参数与表面平整度的数学预测模型,结果表明表面平整度与搭接率成反比。Charles 等^[7]研究分析不同加工参数对激光选取熔化表面粗糙度的影响,结果发现,参数之间的相互作用及相互依赖性对获得的表面平整度具有巨大意义。Peng Wen 等^[8]采用 ER410NiMo 粉末在 FV520B 不锈钢基体上进行多道搭接熔覆,利用响应面法优化工艺参数预测多道熔覆层质量,结果表明,通过适当降低送粉速率、增加激光功率和扫描速度可获得表面平整质量良好的熔覆层。杜彦斌^[9]以 45 钢为基体多道搭接激光熔覆 M2 合金粉末,利用灰色关联分析与响应面法建立熔覆层质量评价模型,结果表明,采用自适应混沌差分进化(ACDE)算法优化出的工艺参数可获得理想的表面平整度。通过熔覆层横截面形貌的熔覆层宽度、高度及面积信息可获得表面平整度,目前研究人员对熔覆层横截面形貌的观察通常通过光学图像分析仪,按比例尺提取熔覆层图像,再通过图像处理软件如 CAD、ImageJ 等^[10-12]对所需参数形貌尺寸进行人工提取标注,但该种图像软件人工标注的方式受

标注者专业性及图像质量的影响较大,并且人工标注计算表面平整度耗时且效率较低。在现代制造业中,通过机器学习算法分析大量数据以及计算机辅助生产中利用机器学习已成为一种趋势,本文针对多道搭接熔覆层表面平整度的计算问题,利用图像分割深度学习算法快速提取覆层横截面形貌参数信息,促进熔覆层形貌对搭接熔覆层性能影响的研究。

基于深度学习的语义分割方法可以更好的应用于背景不同和复杂的形态逻辑特征,并且随着深度学习算法的发展衍生出了许多基于全卷积网络的语义分割模型^[13-15]。2015 年, O. Ronneberger 等^[15]提出 U-Net 网络,起初主要用于医疗图像分割领域,因其融合多尺度特征信息实现准确分割的特点,这种图像分割网络逐渐被用于各种图像像素分类任务。U-Net 模型在小数据集上表现良好,这使得该网络能够快速的应用于熔覆层形貌分割的领域。

本文的研究目的是通过构建搭接熔覆层形貌图像数据集,在 U-Net 结构基础上,对模型其中的相关参数进行改进优化,利用注意力机制模块的通道注意与空间注意特性,将注意力机制模块串联在 U-Net 网络结构中,以构建出高效分割熔覆层横截面形貌的方法,进而自动输出表面平整度,为后续工艺优化制备出高质量熔覆层提供反馈。

2 MCL-UNet 网络模型理论基础

本文提出的搭接熔覆层形貌的自动分割网络(Morphology of Cladding Layer segmentation based on U-Net and CBAM, MCL-UNet)是基于 U-Net 模型结构参数优化和注意力机制模块的优势所提出的改进网络,其中使用到了卷积块、注意力块、特征融合块。

2.1 MCL-UNet 模型原理

MCL-UNet 网络结构如图 1 所示,该模型结构中输入为 128 像素 × 128 像素 × 3 通道的多道搭接熔覆层形貌图像,输出为 128 像素 × 128 像素 × 1 通道的分割特征图。

MCL-UNet 模型左半部分是用以多道搭接熔覆层形貌图像特征提取的编码器路径,具体包括四个降采样过程:每个降采样过程(图 1 中 Down 模块)

由一层 2×2 的池化运算和两层 3×3 的卷积运算组成。编码器部分卷积中的滤波器数量变化为 $\{16, 32, 64, 128, 256\}$ 。模型右边部分是用以图像语义扩展的解码器路径,包括四个上采样过程:每个上采样过程(图 1 中 Up 模块)由一层 2×2 的转置卷积运算和两层 3×3 卷积运算组成。另外,模型中引入跳跃连接,编码器每层下采样之前卷积层的输出会传送到解码器,然后这些输入的特征图与上采样操作输出连接起来,通过特征融合后的传递至下一层。每层上采样后,卷积中的滤波器数量变化为 $\{256, 128, 64, 32, 16\}$,最后使用 1×1 的卷积操作,由 Sigmoid 函数激活输出单通道的灰度图像分割图。MCL-UNet 相对原 U-Net 的参数设置减小卷积核的通道个数,并且选择“ELU”激活函数代替原网络中的“ReLU”,权重初始方式使用 Kaiming^[16] 正态分布初始化权重,另外为加快网络收敛速度及提升泛化精度,每层卷积层和激活函数之间都添加了批标准化操作^[17] (Batch Normalization),从优化图像输入及标签输出为出发点,本文的模型在图 1 中 MCL-UNet 网络结构的第 4 模块和第 6 模块处串联加入了注意力机制模块,通过通道注意和空间注意去除空间维度与空间维度上的冗余信息,增加关于多道搭接熔覆层形貌的权重信息。

2.2 注意力机制模块

卷积神经网络中的注意力机制 (CBAM) 模块由通道注意子模型和空间注意子模型串联组成^[18],通道注意力模块对卷积生成的搭接熔覆层形貌特征图通过全局最大池化和全局平均池化得到的结果输入

到多层感知机 (MLP) 中,再经过 Sigmoid 激活函数得到尺寸为 $C \times 1 \times 1$ 的通道特征权重 (C 为通道数),完成在通道维度的特征向量提取。空间注意力模块首先将经通道注意模块后的特征图最大池化和平均池化操作,然后经由卷积和特征融合操作生成二维空间注意信息,最后经 Sigmoid 激活后生成空间注意处理后的搭接熔覆层特征图。本文改进的网络模型中引入注意力机制核心思想是通过通道维度和空间维度增加卷积网络中特征图权重信息以优化训练性能,进而提升网络模型对搭接熔覆层横截面形貌特征分割能力,并增强模型稳定性。嵌入模型中的 CBAM 模块如图 2 所示。

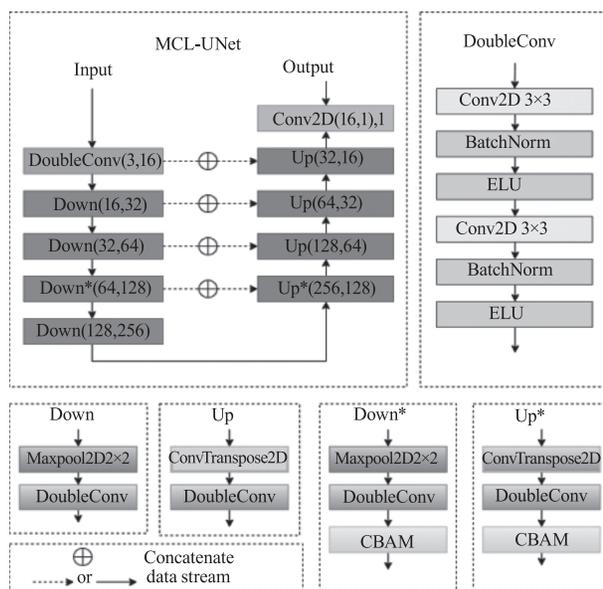


图 1 MCL-UNet 网络结构图

Fig. 1 The network structure of MCL-UNet model

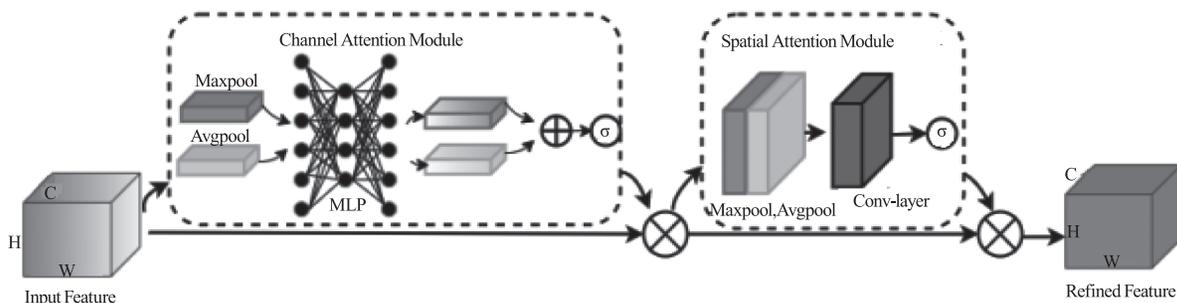


图 2 注意力机制模块结构示意图

Fig. 2 The overview of convolutional block attention module

2.3 改进 U-Net 网络的结构优化

本文对图 1 中 MCL-UNet 网络结构的改进优化主要包括激活函数及其初始化权重方式、损失函数和优化器及其学习率衰减。

2.3.1 激活函数及其初始化权重

改进后的网络结构中,激活函数选择用“ELU” (Exponential Linear Unit) 代替原模型中的“ReLU” (Rectified Linear Unit)。激活函数 ELU 的计算公式

如式(1),两种激活函数曲线如图3所示,ELU 激活函数弥补了 ReLU 激活函数在负值部分梯度为 0 导致损失梯度消失的问题,由于具有负值部分模型输出均值接近零,训练收敛速度更快,对输入变化或噪声鲁棒性更好^[19]。

$$ELU(x, \alpha) = \begin{cases} x & x \geq 0 \\ \alpha(\exp(x) - 1) & \text{else} \end{cases} \quad (1)$$

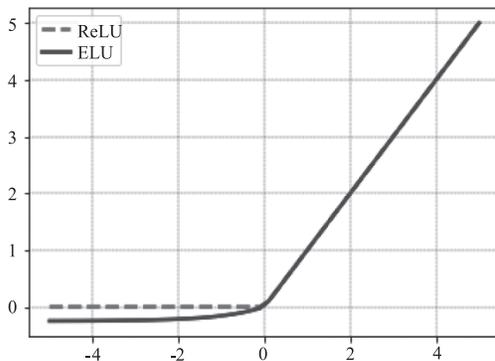


图3 激活函数 ReLU 和 ELU 曲线

Fig. 3 The curve of the activation functions ReLU and ELU

权重初始化在神经网络模型优化中扮演着重要的作用,本文模型选择 Kaiming 正态化初始化“he normal”作为权重初始化方式,在 ELU 激活函数中 Kaiming 正态分布对加快模型的收敛速度有较好的效果^[16]。

2.3.2 损失函数

本文关于多道搭接熔覆层横截面形貌的分割任务是二分类任务,预测图像中各个像素是属于感兴趣点还是背景点,选用二进制交叉熵^[20] (Binary Cross Entropy) 作为损失函数,该函数通过表征预测样本和实际样本中每个样本的差异性来计算梯度。假定 n 代表 n 个样本数量, y_i 代表样本的期望输出, \hat{y}_i 为样本的真实输出,损失函数表达式如式:

$$Loss = -\frac{1}{n} \sum_{i=1}^n [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (2)$$

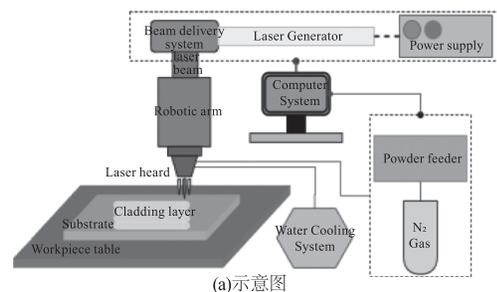
2.3.3 优化器及学习率衰减

学习率恒定的训练方式方便且易于实现,但大多数情况下无法保证网络训练效果,因此大多数收敛性训练学习过程是以递减学习方式进行的。本文采用 Adam 算法^[21] 自适应学习率,该算法下的学习率依据多维不同参数动态调整,指数衰退率 β_1 、 β_2 依据经验分别设定为 0.9 和 0.999,除零误差 ε 为 10^{-8} ,该方法实现简单、计算效率高、占用内存小。

3 实验与结果分析

3.1 熔覆层横截面形貌图像的获取与预处理

深度学习网络能自动捕获更深层次特征,前提是需要足够的数据集。本文以多道搭接熔覆层横截面几何形貌为研究对象,目前没有大规模公开的熔覆层横截面形貌数据库,本文数据集的构建基于作者所在激光增材制造课题组激光熔覆实验数据,实验中使用到的激光熔覆系统由大功率半导体光纤耦合激光器 (LDF6000-60)、负压式送粉器 (RC-PGF-D-2)、水冷机和保护气系统等组成,熔覆粉末有 Fe 基粉末、Ni 基粉末、Co 基粉末、316L 粉末等,基体材料有 316L 不锈钢、45 钢、灰铸铁 HT250 等,图 4 是实验中采用的激光熔覆系统,采集的搭接熔覆层样本也是通过不同的工艺参数获取,后续搭接熔覆样块经过切割、镶块、磨抛等制样操作后使用莱卡显微镜 (OM) 对熔覆层横截面形貌进行不同倍镜拍摄,最终收集搭接熔覆横截面形貌图像 415 张。再采取图像旋转、缩放的数据增广方式把原有图片扩展到 750 张,以增强数据泛化性。使用 Lableme 工具对多道搭接熔覆层熔覆面区域进行标注,制作成闭合的熔覆面特征 mask 标签,构成多道搭接熔覆层横截面图像数据集。



(a)示意图



(b)实物图

图4 激光熔覆系统

Fig. 4 Schematic of the laser cladding system

本文训练样本在输入网络模型前,采用 Tensorflow 框架^[22]对多道搭接熔覆层数据集图像进行张量和归一化预处理,其中张量处理是将熔覆层横截面图像输入模型时转为张量格式,具体是将样本由单通道颜色像素点值[0,255]转换成[0,1],由于计算限制对数据集样本归一化处理为统一的像素分辨率(128 像素×128 像素×3 通道),相较于原网络输入的图像像素,处理后的图像可以优化网络训练性能、加快训练速度。

3.2 实验流程

为了验证 MCL-UNet 网络的有效性,使用原 UNet 模型、不加 CBAM 模块的 MCL-UNet 模型(BN-UNet)、MCL-UNet 模型作为实验对比,为了使参数数量与 MCL-UNet 相当,原始的 U-Net 的滤波器数量改为{16,32,64,128,256},输入图片的预处理方式相同。在制作的搭接熔覆层形貌数据集上,选取 20 张图像作为表面平整度识别测试样本不参与训练,余下的按 9:1 作为训练集和验证集语义分割样本,对每种网络进行 3 次的独立重复实验。训练过程中采用二进制交叉熵进行语义分割,训练期间更新训练参数批次大小定为 16(即 batch size = 16),使用 Adam 优化器自适应学习率来动态调整每次迭代次数的学习率,迭代次数设置为 50 次(epochs = 50)。为保证实验结果具有泛化性以及网络的性能充分得到验证,数据集每次实验固定不同的随机种子进行实验(seed = 40/42/50)。同时,避免网络过拟合采用提前终止(Early Stopping)技术,耐心值设置为 15,即损失函数在 15 步内无下降趋势则模型终止训练。取每种网络 3 次在验证集上的分割效果(IoU 准确值和方差)数据作为该网络的最终性能指标。在 20 张未经过预处理的测试集图片上分别由 3 种网络预测的分割图输出表面平整度,3 种网络得出的表面平整度数据再与专业人工标注准确值做定量分析。本文中模型训练的实验环境如表 1。

3.3 评价指标

本文模型分割任务的性能评价指标选用图像分割评价中常用到的一个重要参数交并比(IoU),在评价图像分割结果时,IoU 衡量的是真实标签与预测输出的重叠百分比,取值范围是[0,1],设 y 为真实的分割掩膜, \hat{y} 为预测的分割掩膜,将本文图像分割的二分类任务视为像素点分类任务,其真实掩膜标签与预

测掩膜标签以像素点的集合组合划分为分类问题,用 TP(true positive)、FP(false positive)、TN(true negative)、FN(false negative)代表像素点级别预测值与专家标记组成的混淆矩阵,量化指标公式如下:

$$IoU = \frac{y \cap \hat{y}}{y \cup \hat{y}} = \frac{TP}{TP + FP + FN} \quad (3)$$

搭接熔覆层横截面形貌如图 5 所示,表面平整度公式^[3,5,8]由式(4)定义:

$$\theta = \frac{S_f}{W \times H} \quad (4)$$

式中 W 和 H 分别为熔覆层宽度和高度, S_f 为熔覆层面积。将未参与训练、不经过图像预处理的 20 张测试集样本进行表面平整度识别对比,由从事激光熔覆研究的专业人员使用金相图像分析软件(Profound Iron & Steel)对搭接图像熔覆层形貌进行人工标注,对测试集 20 张样本每张进行 3 次独立重复标注,分别标注其熔高、熔宽及熔覆层区域,3 次标注数据人工计算得到的平均表面平整度作为准确值,使用 3 种网络分割搭接熔覆层输出的表面平整度数据与准确值之间的平均相对误差定量比较 MCL-UNet 的有效性。

表 1 实验环境

Tab. 1 Experimental environment

配置	参数
操作系统	Windows10 家庭中文版
处理器	Intel(R) Core(TM) i5-11260H
内存	8 GB
显卡	RTX 3050
实验框架	Tensorflow
语言	Python
编译器	Jupyter Notebook

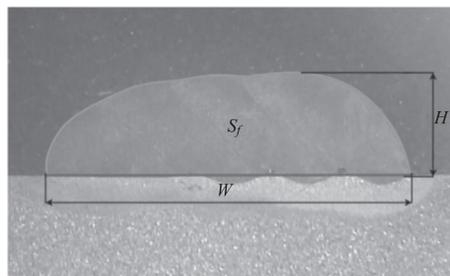


图 5 搭接熔覆层横截面形貌图

Fig. 5 Cross-sectional structure of multi-pass cladding layer

3.4 实验结果

以多道搭接熔覆层数据集上验证集 IoU 准确率

为评定指标, MCL-UNet 等 3 类网络模型的 IoU 准确率如表 2 所示。

由表 2 可以看出, BN-UNet 模型在 3 次独立实验中其 IoU 准确率相对于原 U-Net 模型均有提升,

表 2 不同网络的 IoU (方差/ 10^{-2}) 结果对比

Tab. 2 IoU (variance/ 10^{-2}) result of three networks

模型	第一次实验	第二次实验	第三次实验	平均值
U-Net	0.8753(4.03)	0.8800(4.22)	0.8832(5.13)	0.8795(4.46)
BN-UNet	0.9194(4.53)	0.9123(7.05)	0.9157(4.38)	0.9158(5.32)
MCL-UNet	0.9383(3.40)	0.9381(3.26)	0.9364(3.73)	0.9376(3.46)

为了说明 CBAM 模块不同部署位置对搭接熔覆层形貌分割具有不同的贡献, 设计了对比实验, 表 3 所示即为其他对称放置 CBAM 模块后的训练参数总量 (total params) 及 IoU 值对比, 结果表明, 在本文的训练任务中加入注意力机制会提高网络的训练准确率, 优化参数后的网络网络训练总参

表 3 CBAM 部署不同位置时网络训练总参数及 IoU 值

Tab. 3 Influence of CBAM on the total params and IoU

Position	U-Net	BN-UNet	1,9	2,8	3,7	4,6
Total params	2,311,265	1,946,933	1,947,519	1,948,359	1,951,575	1,964,151
IoU	87.95 %	91.58 %	92.63 %	92.76 %	92.11 %	93.76 %

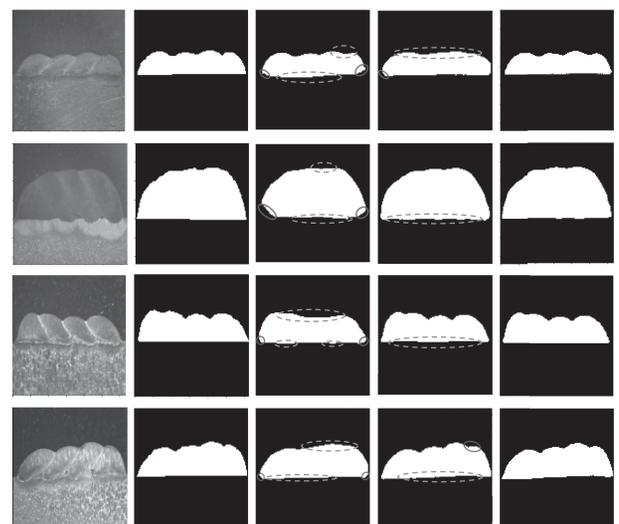
图 6 展示了验证集样本真实标签及 3 种网络的分割效果图。原 U-Net 网络分割的效果存在边缘区域漏分割和误分割的现象, 漏分区域主要出现在熔覆层与基体结合处 (图中实线框线处), 误分区域主要出现在多道搭接熔覆层波峰处 (图中虚线框线处)。BN-UNet 网络的分割效果相比原 UNet 网络降低了漏分割区域的面积, 波峰波谷处也明显分割出其纹理。MCL-UNet 网络分割效果中熔覆层与基体结合处和波峰波谷边缘区域进一步优于 BN-UNet 网络的分割效果, 分割结果更接近真实分割标签。

由表 2 中 IoU 准确值及图 6 网络分割效果可知, MCL-UNet 网络在多道搭接数据集上的熔覆层区域分割中表现出了较高的水平, 为准确识别表面平整度提供有利条件。从图 1 可看出在本文改进的 MCL-UNet 网络结构图第 4 模块和第 6 模块加入注意力机制, 从输入和输出维度增强通道注意和空间注意效果, 去除错误冗余信息, 使注意力区域更加集中, 其位置处于深层网络, 此处多道搭接熔覆层横截面几何形貌特征图的特征增多, 包含更多复杂信息, 说明此处加入注意力机制层

针对多道搭接熔覆层数据集改进的 MCL-UNet 模型在 3 次实验中分割效果最好, 其 IoU 准确率均是最高值, 平均值最高达到了 0.9376, 高出原 U-Net 网络 5.81 %, 且平均方差最低。

数相较于原 U-Net 网络有明显减少, 说明优化后模型对加快训练收敛速度有一定的改善。对称部署加入 CBAM 层网络训练总参数都增量不大, 对训练速度造成的影响极小, 其中模型第四和第六层部署 CBAM 后网络性能更好, 单张搭接熔覆层形貌标记时间为 86 ms。

可增加网络对熔覆层横截面形貌区域分割的训练权重, 使熔覆层形貌边缘区域和与基体结合处分割效果更好, 并且由表 2 可知 MCL-UNet 的训练方差最小、变化最稳定, 说明加入注意力机制模块能够使网络更加稳定。



(a)测试样本 (b)真实标签 (c)U-Net (d)BN-UNet (e)MCL-UNet

图 6 样本真实标签及 3 种网络分割结果

Fig. 6 Ground truth and segmentation results of three experimental network on validation dataset

3.5 表面平整度识别分析

3 种网络对表面平整度的识别根据分割出的标签图,具体算法是将 MCL-UNet 等三种网络在训练集和验证集上训练出的权值加载到测试集中,由网络训练权重进行语义分割得到测试集图片熔覆层分割标签图,由熔覆层分割标签图中各个像素点识别

表面平整度信息,熔高、熔深数据分别通过迭代分割标签图上最高点和最低点及最左点和最右像素点个数得到,熔覆层面积通过迭代搭接熔覆面区域标签像素点的总个数得到,将式(4)编程到网络中自动输出搭接熔覆层表面平整度,表 4 为人工标注准确值和不同网络输出的表面平整度数值。

表 4 表面平整度数据

Tab.4 Surface smoothness dataset

序号	U-Net	BN-UNet	MCL-UNet	Accuracy	序号	U-Net	BN-UNet	MCL-UNet	Accuracy
1	0.811156	0.788435	0.791131	0.809321	11	0.787727	0.804172	0.805482	0.808854
2	0.897164	0.846054	0.842912	0.824507	12	0.904125	0.845238	0.884873	0.859972
3	0.818846	0.84829	0.855442	0.848299	13	0.854947	0.841739	0.819284	0.827329
4	0.868637	0.865546	0.845451	0.840217	14	0.862755	0.850889	0.852381	0.783900
5	0.866903	0.849955	0.848687	0.830056	15	0.823314	0.776417	0.810367	0.807424
6	0.896462	0.858813	0.890592	0.825196	16	0.922615	0.813602	0.872348	0.879008
7	0.826446	0.794545	0.803928	0.777059	17	0.787037	0.812045	0.786195	0.800063
8	0.842893	0.881060	0.884297	0.748151	18	0.822222	0.779381	0.803818	0.809812
9	0.843796	0.799291	0.809524	0.827049	19	0.813565	0.819923	0.788682	0.841880
10	0.874853	0.831518	0.835928	0.843564	20	0.853333	0.842515	0.860472	0.865246

依据 20 组样本实验表面平整度数据,图 7 是以 3 种网络模型识别出的表面平整度与人工标注准确值的相对误差箱型图,箱型图中方框代表各种网络 20 组相对误差数据四分位间距,方框中间的横线代表数据的中位数,“X”处代表数据平均值,离散的点代表异常数据。由图 7 可看出,在 20 组数据中,MCL-UNet 模型识别出的表面平整度的相对误差最小,平均相对误差值为 3.2%,说明 MCL-UNet 网络模型在测试集上可以将搭接熔覆层的区域较完整地分割出,并且对于表面平整度的识别准确率也较接近于人工标注准确率。

力机制 CBAM 模块提出了用于多道搭接熔覆层横截面数据集熔覆面自动分割的 MCL-UNet 网络,并对比分析了原 UNet 模型、优化参数后 BN-UNet 模型和 MCL-UNet 模型在搭接数据集熔覆层的自动分割效果,结果表明 MCL-UNet 网络能够较准确的分割出搭接熔覆层横截面熔覆面形貌,其分割 IoU 准确值达到了 93.76%,与原始 U-Net 的 IoU 准确率相比提高了 5.81%。在测试集样本中该模型自动标注输出的搭接层表面平整度的相对误差为 3.2%,能够实现对搭接熔覆层表面平整度的精确识别。表面平整度与激光功率等工艺参数密切相关,后续研究可通过该模型训练不同工艺参数下搭接熔覆层的形貌参数,使用神经网络回归模型方式探究工艺参数与表面平整度的数学关系,为后续多目标优化研究熔覆层表面质量提供参考。

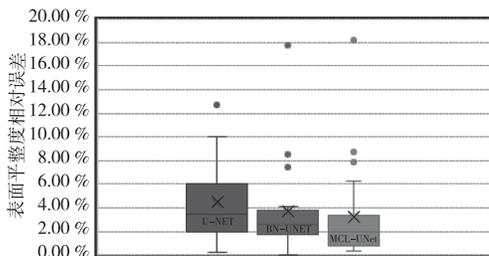


图 7 实验网络平整度计算的定量比较

Fig.6 The quantitative comparison of surface smoothness on three experimental networks

4 结论

本文基于卷积神经网络 U-Net,结合串联注意

参考文献:

[1] Lian G,Liu Z,Zhang Y,et al. The forming control method of multi-track laser cladding on curved surface[J]. Metals,2020,10(8):1109.
 [2] Zhang Qunli,Wang Liang, Mei Xuesong, et al. Development of laser surface modification technology[J]. Strategic Study of CAE,2020,22(3):71-77. (in Chinese)

- 张群莉,王梁,梅雪松,等. 激光表面改性技术发展研究[J]. 中国工程科学,2020,22(3):71-77.
- [3] Cui Jing,Lu Mengke,Zhai Wei, et al. Microstructure and properties of laser clad 316 L stainless steel repair coating on 300M steel[J]. *Laser & Infrared*,2021,51(6):710-719. (in Chinese)
崔静,路梦珂,翟巍,等. 300M 钢激光熔覆 316L 不锈钢修复层组织及性能研究[J]. *激光与红外*,2021,51(6):710-719.
- [4] Zhu Gangxian,Zhang Anfeng,Li Dichen, et al. Effect of process parameters on surface smoothness in laser cladding[J]. *Chinese Journal of Lasers*,2010,(1):296-301. (in Chinese)
朱刚贤,张安峰,李涤尘. 激光熔覆工艺参数对熔覆层表面平整度的影响[J]. *中国激光*,2010,(1):296-301.
- [5] Wang Yueliang,Zhong Yonghua,Li Fuhai, et al. Influence of laser remanufacturing process parameters on single-pass forming characteristics of H13 steel powder[J]. *Laser & Infrared*,2021,51(7):871-876. (in Chinese)
王岳亮,钟永华,李福海,等. 激光工艺参数对 H13 钢粉末单道成形特性的影响[J]. *激光与红外*,2021,51(7):871-876.
- [6] Lian G,Zhang H,Zhang Y, et al. Optimizing processing parameters for multi-track laser cladding utilizing multi-response grey relational analysis[J]. *Coatings*,2019,9(6):356.
- [7] Charles A,Elkaseer A,Thijs L, et al. Effect of process parameters on the generated surface roughness of down-facing surfaces in selective laser melting[J]. *Applied Sciences*,2019,9(6):1256.
- [8] Wen P,Feng Z,Zheng S. Formation quality optimization of laser hot wire cladding for repairing martensite precipitation hardening stainless steel[J]. *Optics & Laser Technology*,2015,65:180-188.
- [9] Du Yanbin,Zhou Zhijie,Xu Lei, et al. Laser cladding process parameter optimization method based on grey relational analysis and ACDE algorithm[J]. *Computer Integrated Manufacturing Systems*,2022,28(1):149-160. (in Chinese)
杜彦斌,周志杰,许磊,等. 基于灰色关联分析与自适应混沌差分进化算法的激光熔覆工艺参数优化方法[J]. *计算机集成制造系统*,2022,28(1):149-160.
- [10] Tao Xide,Liu Hongxi,Zhang Xiaowei, et al. Cladding angle model and variation law of Fe-based coating fabricated by mechanical vibration assisted laser cladding[J]. *Chinese Journal of Lasers*,2015,42(3):133-139. (in Chinese)
陶喜德,刘洪喜,张晓伟,等. 机械振动作用下铁基涂
层熔覆角的模型构建及其变化规律研究[J]. *中国激光*,2015,42(3):133-139.
- [11] Li Qi,Li Tao,Wu Zhupeng, et al. Prediction of laser cladding layer area and porosity based on neural network[J]. *Applied Laser*,2020,40(1):29-34. (in Chinese)
李琦,李涛,吴祖鹏,等. 基于神经网络的激光熔覆层面积及气孔率预测[J]. *应用激光*,2020,40(1):29-34.
- [12] Corbin D J,Nassar A R,Reutzel E W, et al. Effect of directed energy deposition processing parameters on laser deposited Inconel[®] 718: External morphology[J]. *Journal of Laser Applications*,2017,29(2):022001.
- [13] Long J,Shelhamer E,Darrell T. Fully convolutional networks for semantic segmentation[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2015:3431-3440.
- [14] Badrinarayanan V,Kendall A,SegNet R C. A deep convolutional encoder-decoder architecture for image segmentation[J]. *arXiv preprint arXiv:1511.00561*,2015,5.
- [15] Ronneberger O,Fischer P,Brox T. U-net: convolutional networks for biomedical image segmentation[C]//*International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, Cham, 2015:234-241.
- [16] He K,Zhang X,Ren S, et al. Delving deep into rectifiers: surpassing human-level performance on imagenet classification[C]//*Proceedings of the IEEE International Conference on Computer Vision*. 2015:1026-1034.
- [17] Ioffe S,Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//*International Conference on Machine Learning*. PMLR, 2015:448-456.
- [18] Woo S,Park J,Lee J Y, et al. Cbam: convolutional block attention module[C]//*Proceedings of the European Conference on Computer Vision(ECCV)*. 2018:3-19.
- [19] Clevert D A,Unterthiner T,Hochreiter S. Fast and accurate deep network learning by exponential linear units (ELUs)[J]. *arXiv preprint arXiv:1511.07289*,2015.
- [20] Shore J,Johnson R. Axiomatic derivation of the principle of maximum entropy and the principle of minimum cross-entropy[J]. *IEEE Transactions on Information Theory*,1980,26(1):26-37.
- [21] Kingma D P,Ba J. Adam: a method for stochastic optimization[J]. *arXiv preprint arXiv:1412.6980*,2014.
- [22] Abadi M,Agarwal A,Barham P, et al. Tensorflow: large-scale machine learning on heterogeneous distributed systems[J]. *arXiv preprint arXiv:1603.04467*,2016.