

# 基于通道加权 FPN 的熔池检测与特征提取方法

凌旭<sup>1,2</sup>, 谢非<sup>1,2,3</sup>, 杨继全<sup>1,2</sup>, 杜军<sup>4</sup>, 苗立国<sup>3,5</sup>, 锁红波<sup>3</sup>

(1.南京师范大学电气与自动化工程学院,江苏南京 210023)

(2.南京师范大学江苏省三维打印装备与制造重点实验室,江苏南京 210023)

(3.南京中科煜宸激光技术有限公司,江苏南京 210023)

(4.西安交通大学机械制造系统工程国家重点实验室,陕西西安 710049)

(5.沈阳工业大学机械工程学院,辽宁沈阳 110870)

**[摘要]** 为了获取使用熔池特征参数对增材制造进行反馈控制的输入参数,提出了一种基于通道加权 FPN 的激光增材制造熔池语义分割算法和基于图像像素阈值的熔池方向、面积和宽度特征参数提取算法。语义分割算法主要包含轻量级的主干神经网络、通道加权特征 FPN 网络。实验结果表明,熔池图像的分割速度可达 79.76 张/s, mIoU 和 mAP 分别可达 90.53% 和 95.79%,且模型大小仅为 90MB。与其他相同类型的深度学习模型相比,该算法在保证精度的同时,提高了检测速度,减少了模型参数数量和大小。熔池图像特征参数提取算法则结合了相机拍摄的原始图像与分割完成的图像的像素阈值分布情况,能够准确分析并计算出熔池的方向、宽度与面积特征参数。

**[关键词]** 熔池检测,增材制造,语义分割,特征融合,神经网络

**[中图分类号]** TG441.7 **[文献标志码]** A **[文章编号]** 1672-1292(2023)02-0016-09

## High Speed Molten Pool Image Detection Based on Weighted Fusion and Parameter Extraction

Ling Xu<sup>1,2</sup>, Xie Fei<sup>1,2,3</sup>, Yang Jiquan<sup>1,2</sup>, Du Jun<sup>4</sup>, Miao Ligu<sup>3,5</sup>, Suo Hongbo<sup>3</sup>

(1.School of Electrical and Automation Engineering, Nanjing Normal University, Nanjing 210023, China)

(2.Jiangsu Key Laboratory of 3D Printing Equipment and Manufacturing, Nanjing Normal University, Nanjing 210023, China)

(3.Nanjing Zhongke Raycham Laser Technology Co., Ltd., Nanjing 210023, China)

(4.The State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

(5.School of Mechanical Engineering, Shenyang University of Technology, Shenyang 110870, China)

**Abstract:** In order to obtain the input parameters for feedback control of additive manufacturing using molten pool feature parameters, we propose a laser additive manufacturing molten pool semantic segmentation algorithm based on channel-weighted FPN, and a molten pool orientation, area and width feature parameter extraction algorithm based on image pixel threshold. The semantic segmentation algorithm mainly consists of a lightweight backbone neural network and a channel-weighted feature FPN network. The experimental results show that the segmentation speed of the molten pool image can reach 79.76 frames/s, and the mIoU and mAP can reach 90.53% and 95.79%, respectively, and the model size is only 90MB. Compared with other similar types of deep learning models, this algorithm improves the detection speed and reduces the model parameter size and size while ensuring accuracy. The molten pool image feature parameter extraction algorithm combines the pixel threshold distribution of the original image captured by the camera and the segmented image, and can accurately analyze and calculate the orientation, width and area feature parameters of the molten pool.

**Key words:** molten pool detection, additive manufacturing, semantic segmentation, feature fusion, neural network

激光送粉增材制造技术是以激光为热源,以金属粉末、颗粒为原材料的叠层制造技术,成形物品具有结构紧密、强度高、耐腐蚀性强等优点,且制造成本低、制造周期短<sup>[1]</sup>。以数字化制造和设计为基础的激光增材制造技术在航空航天、工业生产、生物医疗和军工等领域获得了广泛的应用。日益增长的制造需求对激光增

收稿日期:2022-07-05.

基金项目:国家重点研发计划项目(2017YFB1103200)、江苏省科技成果转化项目(BA2020004)、2020年江苏省省级工业和信息产业转型升级专项资金项目(JITC-2000AX0676-71)、江苏省研究生科研与实践创新计划项目(SJCX21\_0582)。

通讯作者:谢非,博士,副教授,研究方向:金属增材制造、机器视觉与深度学习、数据融合与处理、嵌入式系统开发等。E-mail: xiefei@njnu.edu.cn

材制造的成形质量和精度提出了更高的要求. 提高制造过程的自动化水平、逐步走向智能化是大势所趋<sup>[2]</sup>.

当前,激光送粉增材制造在熔池的轮廓提取、形貌识别、监测、建模等方面的研究都有长足进步<sup>[3-6]</sup>,但对熔池的宽度、面积、中心点、变化趋势等参数的研究较少. 熔池的热能分布、粉末吸收及冷凝快慢等参数的分析更依靠熔池的实时高精度检测<sup>[7-8]</sup>. 刘晓刚等<sup>[9]</sup>采用多尺度多结构的形态学算子对熔池图像进行处理,提取了完整的边缘,实现了边缘精准定位和去噪能力的最佳融合,但其改进的传统算法检测速度慢,且仅提取轮廓信息. 杨启等<sup>[10]</sup>建立了基于能量、动量、质量守恒的热传递与流体流动模型分析熔池形状的变化,搭建了基于激光位移传感器离焦量控制系统,提高了熔覆件成形尺寸精度及粉末利用效率. Li 等<sup>[11]</sup>采用正交实验法采集数据样本,并建立数学模型预测熔覆层的宽度与高度等几何参数,模型的预测结果与实际结果有较高相似性. 许多学者通过深度学习的方法在增材制造方面做了大量工作. 顾振杰等<sup>[12]</sup>建立了一套激光熔池光谱实时检测系统,利用汞灯进行光谱标定,分析光谱特征,研究在不同工艺参数下熔池光谱的辐射强度分布,但光谱检测熔池的方法获取的特征较少,且易受烟雾、粉末颗粒干扰. 雷凯云等<sup>[13]</sup>建立了 CCD 视觉检测系统,使用 BP 神经网络预测熔池的特征参数,并使用遗传算法优化 BP 神经网络的初值,研究了熔池宽度、长度、面积与工艺参数的变化规律,获得了较高的预测精度. Yang 等<sup>[14]</sup>使用深度学习的方法进行熔池分类,使用经典的卷积神经网络模型训练了 2 763 张熔池图像,并对熔池图像进行了分类. Lu 等<sup>[15]</sup>设计了一个基于残差结构的网络以定量预测熔覆层的焊缝增强,实验结果表明熔池的形状和温度分布是影响弧焊增材制造焊缝加固定量预测准确度的主要因素. 王仁杰等<sup>[16]</sup>以计算机视觉和高速摄像的在线原位检测方法实时获取熔池的边缘形貌,并通过熔池参数与工艺情况、激光加工路径、熔池缺陷等的关系探索了有效的工艺过程实时反馈机制. 还有许多学者通过深度学习的方法在熔池图像分割方面做了大量工作<sup>[17-21]</sup>,但多数研究均未实现熔池的实时高精度检测,且识别完成后少有对熔池的参数进行提取或应用到实际制造中.

本文使用工业相机采集了熔池数据集,针对神经网络 FPN<sup>[22]</sup>结构,设计了神经网络的通道加权 FPN 网络、熔池的方向判断算法、熔池的宽度与面积计算方法,实现了熔池的高精度实时分割与参数提取. 针对熔池的特征图需使用深层特征图进行整体检测,及利用浅层特征图强化边缘信息的特点,提出了通道加权 FPN 网络,能够自适应地调整权重并有侧重地分析图像中所需的特征,提取更为充分的语义信息,实现高效率冗余特征的熔池图像语义分割. 为了分析熔池的特征参数,获取熔池的方向、宽度和面积等特征,根据熔池图像的像素阈值分布特点,结合熔池图像的语义分割结果,设计了基于图像像素的熔池方向、宽度和面积特征参数提取算法,能够快速提取相关特征参数.

## 1 基于通道加权 FPN 的增材制造熔池检测系统

### 1.1 熔池图像检测系统

系统由激光增材制造和熔池图像检测两部分组成. 在制造过程中,摄像头通过激光反射通道采集熔池图像,而后将图像实时发送到上位机,上位机使用深度学习神经网络对熔池进行检测分割,并提取熔池特征参数,分析熔池特征.

基于通道加权 FPN 的激光增材制造熔池图像检测框架如图 1 所示. 算法基于改进的 MobileNet\_v3<sup>[23]</sup>主干神经网络,采用深度可分离卷积与瓶颈结构进行优化,结合通道加权 FPN 特征提取方法,进行熔池图像的分割. 将拍摄到的熔池图像送入主干神经网络进行卷积、池化、标准化等操作,使得特征图尺寸不断减小,每个像素的感受野逐渐增大,特征图的通道数增多. 由于不同尺寸的特征图所包含的语义信息不同,在进行分割前,从主干特征网络输出多张特征图,在通道上对其进行加权的特征融合,使得最后输出的结果能够根据熔池的特征自适应地调节特征图的权重,从而实现更高精度的语义分割.

### 1.2 基于通道加权 FPN 的神经网络结构

神经网络的主干网络主要由瓶颈结构组成. 瓶颈结构取自于 MobileNet\_v3,具有轻量化、参数量小的特点. 输入的图像首先经一个  $1 \times 1$  的卷积升维,再经一次  $3 \times 3$  的深度可分离卷积提取特征,并对特征图添加一个通道注意力机制,最后通过一次  $1 \times 1$  的卷积降维输出. 若输入和输出的长( $H$ )、宽( $W$ )、通道数( $C$ )不变,则会添加一个残差边. 瓶颈结构采用的  $1 \times 1$  卷积、h\_swish 激活函数和深度可分离卷积参数量均非常小,因而可保证检测速度. 整个主干神经网络由 11 个瓶颈结构组成,输出第 3、第 6、第 9、第 11 个瓶颈结构的特征图,这

些特征图的尺寸不同,可体现不同的特征. 将这些特征图作为特征融合网络的输入,再进一步提取特征.

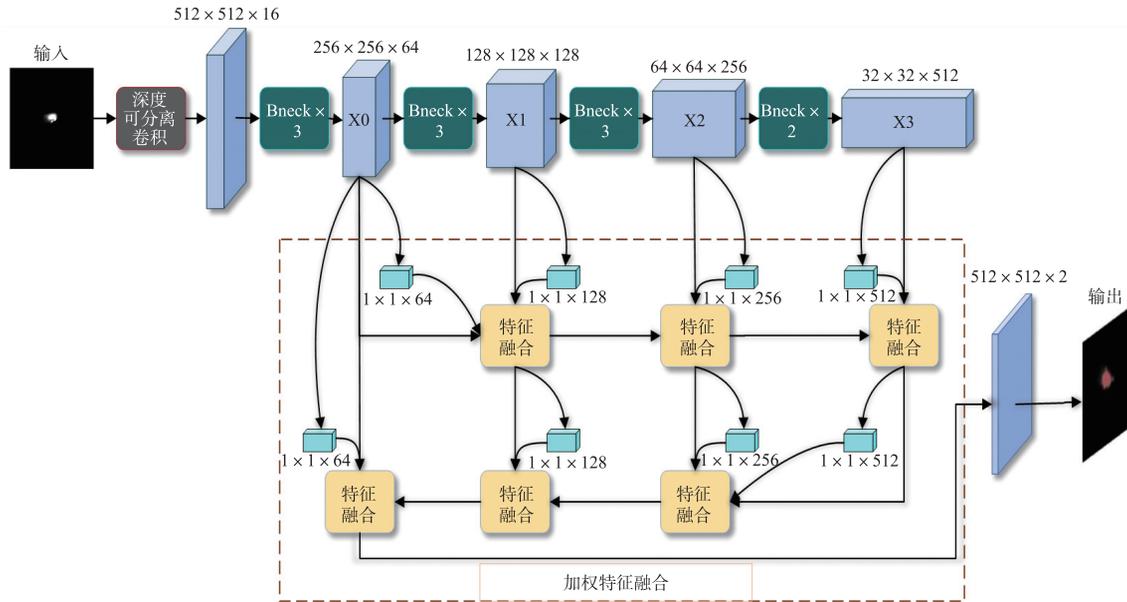


图 1 基于通道加权 FPN 的激光增材制造熔池图像检测框架

Fig. 1 Laser additive manufacturing molten pool image detection framework based on channel weighted FPN

特征融合能够使网络获取不同层次的特征图语义信息<sup>[24]</sup>. 为了使特征融合网络更为全面地获取熔池的语义信息,本文提出一种通道加权 FPN 网络,通过权重强化特征图的语义信息提取.

如图 2 所示,通道加权 FPN 网络包括自顶向下与自底向上两部分. 自顶向下部分将深层的特征图经上采样与卷积调整特征图的尺寸与通道数,使其可与浅层的特征图融合. 自底向上部分将浅层的特征图经池化和卷积与深层的特征图融合.

自底向上特征融合的过程为:首先将 X0 特征图经一次下采样调整为 128x128 像素 128 通道数,再与经 1x1 卷积调整通道数的 X1 特征图使用 add 加权特征融合,得到特征图 P0;而后再进行一次下采样将

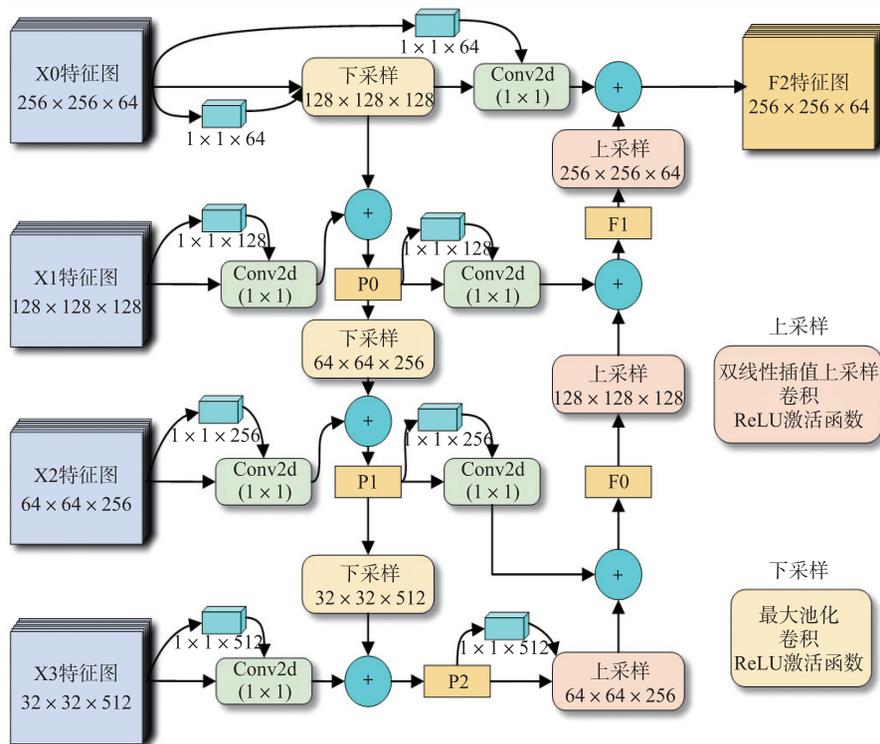


图 2 通道加权 FPN 网络

Fig. 2 Channel weighted FPN network

P0 调整为  $64 \times 64$  像素 256 通道数,与卷积后的 X2 特征图进行 add 加权特征融合,得到特征图 P1;P1 特征图同样经下采样调整为  $32 \times 32$  像素 512 通道数与卷积后的 X3 特征图进行 add 加权特征融合,得到特征图 P2. 至此,自底向上的特征融合完成.

自顶向下特征融合的过程为:首先将 P2 特征图经一次上采样操作调整为  $64 \times 64$  像素 256 通道数,与进行  $1 \times 1$  卷积后的 P1 特征图进行 add 加权特征融合,得到 F0 特征图;而后再进行类似操作,得到  $128 \times 128$  像素 128 通道数的 F1 特征图、 $256 \times 256$  像素 64 通道数的 F0 特征图;最后将 F0 特征图输出用于分割.

上采样操作包括  $2 \times 2$  像素的双线性插值上采样、 $1 \times 1$  像素的卷积和 ReLU 激活函数. 下采样操作包括  $2 \times 2$  像素的最大池化、 $1 \times 1$  像素的卷积和 ReLU 激活函数. 对从主干网络获取的特征图进行一次全局平均池化,各自得到一个  $1 \times 1$  像素的特征图,将 4 个  $1 \times 1$  尺寸的特征图在通道上结合,进行一次卷积、全连接与 ReLU 激活函数,再分为 4 个独立的  $1 \times 1$  特征图进行一次全连接与 ReLU 激活函数,各自与其原来的特征图相乘之后再投入运算. 对自底向上特征融合获取的特征图也在进行同样的操作后再进行自顶向下的特征融合.

$1 \times 1$  特征图包含了每层特征图所需的权重信息,其与原始特征图相乘的过程即为通道加权. 通过加权操作,即可对每张特征图在通道上赋予一定的侧重,使得特征融合时更关注包含目标特征多的特征图. 特征融合结束后,神经网络已学习到输入图像的特征,最后输出一个  $512 \times 512$  像素 2 通道数的特征图,即可用于熔池区域的分割.

### 1.3 熔池方向判断算法设计

熔池的方向即熔池的运动方向,也是加工头的扫描方向. 如图 3(a)所示,加工头与 CMOS 相机已在图中标出. 相机固定在加工头上与加工头同轴运动,熔池的反射光从激光通道进入镜头成像,内部光路如图 3(b)所示. 图像中熔池的运动方向并不固定,因此需设计熔池图像的方向判断算法.

观察拍摄的熔池图像,熔池部分有明暗之分. 大部分熔池的分布规律为:明暗区域分布在熔池两边;明亮部分热量较大,是熔池的头部;较暗部分即将冷却,是熔池尾部. 不规则的则是整个熔池全部呈明亮状态,无明显的明暗之分.

对于符合正常规则的熔池,首先以灰度图读取图像,对图像建立如图 4 所示的坐标系,以此坐标系表示图中像素点的坐标. 使用腐蚀与膨胀运算,滤除图像中飞溅的粉末. 分别提取熔池部分较亮与较暗的像素区域,计算两个区域的中心点坐标  $A$  和  $B$ ,使用明亮部分中心点坐标  $A$  减去较暗部分中心点坐标  $B$ ,即可获得熔池的方向向量. 计算公式为:

$$D_{\text{pool\_rad}} = \arctan((B_y - A_y) / (B_x - A_x)); \quad (1)$$

$$D_{\text{pool}} = \begin{cases} D_{\text{pool\_rad}} \times (180/2\pi), & B_x - A_x < 0; \\ D_{\text{pool\_rad}} \times (180/2\pi) + 180, & B_x - A_x > 0. \end{cases} \quad (2)$$

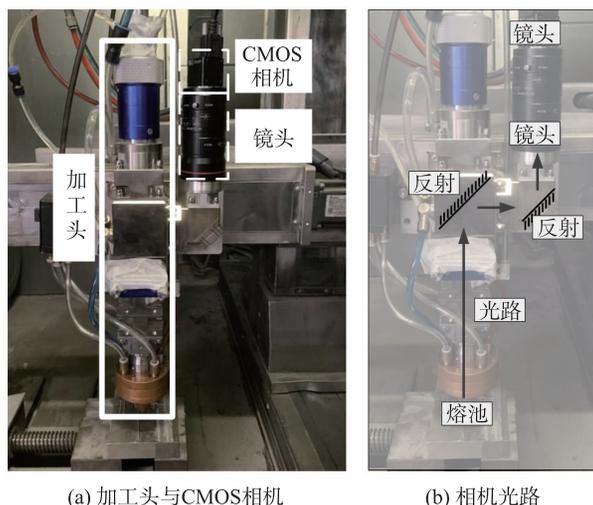


图 3 CMOS 相机装设

Fig. 3 CMOS camera installation

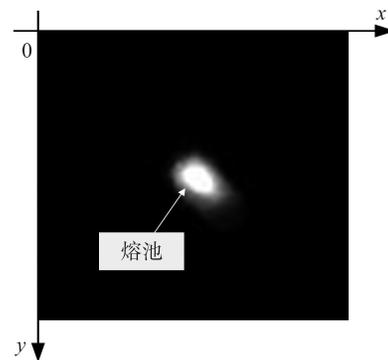


图 4 图像坐标系建立

Fig. 4 Image coordinate system

式(1)中,  $D_{\text{pool\_rad}}$  为熔池方向的弧度制表示;  $B_x, B_y$  表示  $B$  点的坐标;  $A_x, A_y$  表示  $A$  点的坐标. 式(2)中  $D_{\text{pool}}$  表示熔池方向的角度, 当出现分母为 0 的情况时, 直接根据纵坐标判断角度为  $90^\circ$  还是  $180^\circ$ .

对于不规则熔池, 由于实际工作中连续拍摄的熔池方向不会发生较大变化, 因此不规则熔池的方向向量可根据之前熔池的方向向量与变化梯度确定. 此外, 规则熔池的方向根据之前熔池的方向和变化梯度进行调节后, 能进一步降低误判的影响.

### 1.4 熔池面积与宽度计算

熔池的面积计算较为容易, 熔池的分割结果图像中非熔池区域像素值为 0(黑色), 只需统计图像中像素值不为 0 的个数即可. 熔池的宽度计算需结合熔池的方向进行, 宽度方向直线与熔池方向垂直, 由于  $A$  为熔池明亮区中心点, 此点即可作为宽度方向直线的基准点. 熔池的宽度方向直线计算如式(3)所示, 熔池的宽度计算如式(4)所示:

$$y_{\text{width}} = \frac{A_y - B_y}{A_x - B_x} (x_{\text{width}} - A_x) + A_y, \quad (3)$$

$$W = \sum_{i=0}^n f_{\text{judge}}(x_i, y_i), \quad (4)$$

式中,  $x_{\text{width}}, y_{\text{width}}$  为判断像素点的横纵坐标;  $W$  为熔池的宽度值;  $n$  为图像的宽度像素值;  $x_i, y_i$  为当前判断像素的横纵坐标;  $f_{\text{judge}}$  判断当前像素的值是否为 0, 不为 0 则结果为 1, 为 0 则结果为 0. 使用式(4)分别以横坐标和纵坐标为基准进行计算, 用勾股定理计算斜边长度, 即熔池宽度.

## 2 实验与分析

### 2.1 数据集的制作

由于目前没有公开的熔池数据集, 本实验自行使用 XIMEA 的 CMOS 相机采集激光增材制造的熔池图像, 搭配透光率为 0.5% 的滤光片, 采集帧率设置为 25 张/s. 激光增材制造设备为 LDM4030, 以不锈钢 316L 球粉为成形原料, 颗粒直径为  $45 \sim 106 \mu\text{m}$ , 激光光斑直径为 1 mm, 实验激光功率为 500 W, 加工头移动速度为 5 mm/s. 共采集清晰的熔池图像 10 000 张, 由于激光光斑直径仅为 1 mm, 并为检测实时性考虑, 尺寸设置为  $512 \times 512$  像素即可, 图像分配方式为: 8 000 张用作训练集, 1 000 张用作验证集, 1 000 张用作测试集. 在训练时采用数据增强, 以提高模型的泛化性能. 对训练集和验证集图像使用 labelme 图像标注软件进行标注, 标签为“pool”.

### 2.2 网络参数设定与主干网络搭建

本文神经网络的实验环境为: 1 块 RTX TITAN 显卡, CPU 为 i9 9900K, 操作系统为 Ubuntu16.04. 为了保证对比实验的准确性, 体现各网络之间的性能差异, 神经网络的参数设定如表 1 所示.

首先对自主设计的主干网络、特征融合网络进行实验测试. 以检测速度、检测精度 (mIoU 和 mAP) 为主要标准, IoU 是网络分割的区域与真实区域的交集与并集相除得出的一个标准量, mIoU 则是背景和熔池 IoU 的平均值; AP 值是在不同置信度取值的情况下召回率和准确率曲线与坐标轴围成的面积, mAP 则是背景和熔池样本的平均 AP 值. 本文对 ResNet101<sup>[25]</sup>、MobileNet\_v3、VGG16<sup>[26]</sup>、CSPDarknet<sup>[27]</sup> 等主流网络与本文所设计的主干网络进行了对比分析, 对训练集图像进行训练, 保存训练完成的模型, 使用测试集对模型进行测试, 实验对比的结果如表 2 所示.

表 1 网络参数设定

Table 1 Network parameter setting

参数名称	参数设定
基础学习率	0.000 1
学习率衰减	0.02 倍
迭代次数	300
批量大小	8
输入图像尺寸	$512 \times 512$
输入图像格式	RGB

从表 2 可以看出, ResNet101 和 VGG16 的精度相近, 但 ResNet101 的参数量是所有主干网络中最多的, 检测速度最低, 只有 70 张/s. VGG16 的检测精度较高, 相对 ResNet101 参数量小很多, 检测速度也有一定提升, 但所需训练时间最多. MobileNet\_v3 训练时间最短, 检测速度最快, 达到了 105 张/s, 参数量也比其他主干网络少很多, 但其 mIoU 和 mAP 最低, 且实际检测误差较大, 经常有缺损和误检测, 无法运用在实际工程中. CSPDarkNet53 的检测精度基本满足要求, 但其参数量过多, 检测速度较慢. 本文所搭建的主干

网络 mIoU 和 mAP 均达到最高,速度仅比 MobileNet\_v3 慢,参数量只有  $1.6 \times 10^7$ ,每轮训练时间仅需 7.15 min,可满足工程实际需求.

表 2 不同主干网络性能对比

Table 2 Performance comparison of different backbone networks

主干网络	每轮训练时间/min	检测速度/(张/s)	参数量	mIoU/%	mAP/%
ResNet101	8.17	70.72	116 243 522	90.32	95.02
MobileNet_v3	4.18	105.32	3 405 426	81.64	91.94
VGG16	10.67	73.81	26 466 114	89.21	93.22
CSPDarkNet53	8.51	72.56	64 040 001	89.71	94.98
Our backbone	7.15	79.76	16 084 746	90.53	95.79

### 2.3 通道加权 FPN 网络消融实验

为了验证特征融合对检测效果的影响,进行如下对比实验:

实验 1:不使用特征融合,将从主干神经网络中提取的特征图直接处理和分割;

实验 2:只使用上采样,将深层特征图上采样后与浅层特征图进行特征融合,每张特征图参与一次融合;

实验 3:结合下采样与上采样,先将浅层特征图一步步下采样后与深层特征图融合,再将获得的特征图由深到浅进行上采样融合.

实验的结果如表 3 所示.可以看出,实验 2 mIoU 和 mAP 值均最低;实验 3 相对于实验 1,mAP 的提升不明显,但 mIoU 提升了 3.33%,证明了通道加权 FPN 网络的有效性.

表 3 不同特征融合网络性能对比

Table 3 Performance comparison of different feature fusion networks

实验名称	mIoU/%	mAP/%
实验 1	87.20	94.98
实验 2	86.77	91.45
实验 3	90.53	95.79

### 2.4 总体对比实验

本文使用当前主流的一些神经网络模型训练本文的数据集,并切换不同的主干网络与本文的主干网络进行对比,综合性能比较结果如表 4 所示.

表 4 主流卷积神经网络表现性能对比

Table 4 Performance comparison of mainstream convolutional neural networks

神经网络模型名称	主干网络	检测速度/(张/s)	mIoU/%	mAP/%
DeeplabV3+	ResNet101	51.96	90.25	94.62
	VGG16	63.91	88.33	92.75
	CSPDarkNet53	61.05	90.35	94.25
	Xception	40.32	89.22	94.45
	Our backbone	47.04	90.30	95.04
PSPNet	ResNet50	51.41	89.39	93.74
	ResNet101	73.08	90.47	94.94
	MobileNet_V2	166.67	87.54	93.50
	VGG16	87.01	90.05	94.07
	CSPDarkNet53	80.34	89.69	93.99
Unet	Our backbone	80.35	90.38	94.88
	ResNet50	53.35	89.90	94.70
	ResNet101	42.44	90.05	95.07
	MobileNet_V3	35.72	89.34	94.42
	VGG16	34.12	89.81	95.11
Ours	CSPDarkNet53	29.94	89.49	94.18
	Our backbone	37.28	90.29	95.15
	ResNet101	70.72	90.32	95.02
	MobileNet_V3	105.32	81.64	91.94
	VGG16	73.81	89.21	93.22
Ours	CSPDarkNet53	72.56	89.71	94.98
	Our backbone	79.76	90.53	95.79

DeeplabV3+<sup>[28]</sup>、PSPNet<sup>[29]</sup>、Unet<sup>[30]</sup>是近些年来在分割任务上表现优异的一阶段网络,与本文所搭建的神经网络模型实现的任务类型相同.由于每个网络的结构不同,对比实验保留部分网络在发布时使用的主干网络并更换适应其网络结构的主干网络,因此不同网络使用的主干网络不尽相同.从表 4 可以看出,在 DeeplabV3+网络中,本文搭建的主干网络的 mIoU 和 mAP 均达到了较高的水平,但检测速度仅比 DeeplabV3+的原主干网络快;PSPNet 中,本文搭建的主干网络检测速度较快,mIoU 达到 90.38%,只比最高的低 0.09%,mAP 达到 94.88%,只比最高的低 0.06%;在 Unet 中,本文搭建的主干网络 mIoU 与 mAP 均达到了最高值,检测速度也较快.

图 5 所示为主流神经网络的 mAP 折线图,可以看出,本文所搭建的主干网络应用在其他主流神经网络模型中时表现优异,搭配本文的神经网络时效果达到最优.

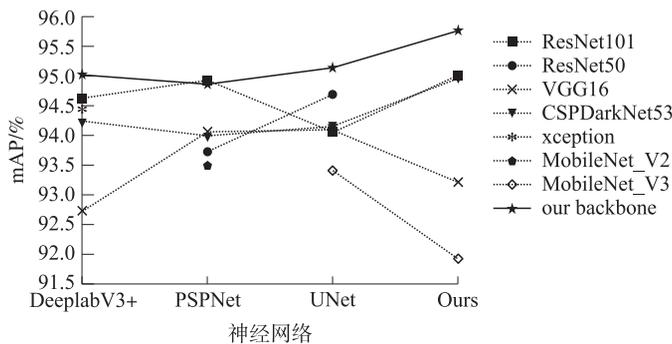


图 5 主流神经网络测试效果

Fig. 5 Mainstream neural network test results

### 2.5 测试集图像检测结果对比与分析

传统基于 OpenCV 的图像处理具有检测速度快、内存占用小、程序设计简单的优点,是早期图像处理常用的方法.典型的如张亚红等<sup>[31]</sup>设计的一种形态学与 Canny 算子融合的焊接熔池边缘检测算法,对 CMOS 相机拍摄到的熔池使用 Canny 算子检测边缘,并对检测算子进行改进,从而达成不错的检测效果.

由于制造过程中常有强光干扰,对强光干扰的图像方法使用传统的图像处理并不能准确得到熔池边缘.神经网络模型能够排除这种干扰,得到准确的熔池区域.对划分的 1 000 张连续测试集图像使用本文模型进行分割和稳定性分析,部分分割的结果如图 6 所示,熔池方向判断的结果如图 7 所示.

图 7 中,极角为熔池的方向角,极径为熔池图片的序数,按照图像的采集顺序依次绘制熔池的方向,所得点的分布能够直观表现出加工头的运动规律.熔池方向分布结果呈现螺旋状,表明熔池运动方向从 0° 到 360° 做圆周运动,加工头路径为圆,制造的零件为圆环.

所有图像分割的面积像素值分布曲线和宽度分布曲线及其平均值如图 8 所示.从图 8 可以看出,熔池面积分布集中在 250 像素到 400 像素之间,像素宽度分布在 12 到 22 像素之间较为集中.

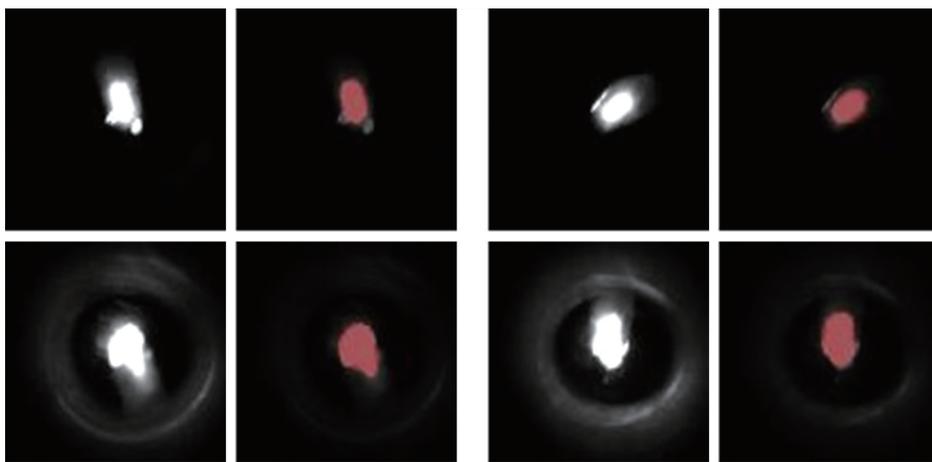


图 6 熔池及分割结果图像

Fig. 6 Molten pool images and segmentation result images

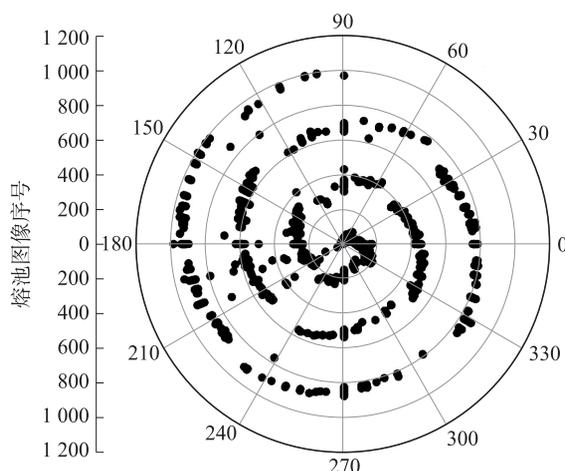


图 7 熔池方向分布图

Fig.7 Distribution of molten pool direction

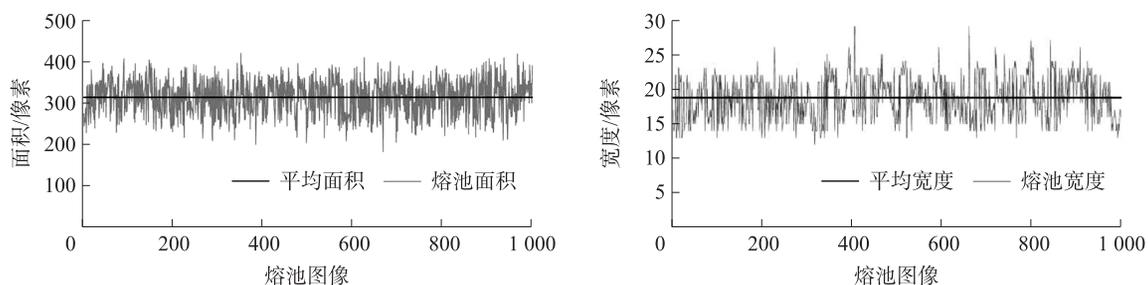


图 8 熔池像素面积与宽度变化曲线图

Fig.8 The change curve of molten pool pixel area and width

### 3 结论

本文针对激光送粉增材制造熔池图像分割的工程需求,搭建了低参数量、轻量化的主干神经网络,采用上采样与下采样相结合的方式搭建了通道加权 FPN 网络,训练自适应的权重参数进行特征融合,熔池的检测速度达到 79.76 张/s,检测的 mIoU 值达到 90.53%,mAP 值达到 95.79%,实现了实时高精度检测;设计了熔池的方向判断、熔池面积与宽度计算方法,能够直接分析熔池特征参数. 本文算法减少了制造过程中的人工参与,对于降低工程的次品率、减少成本、增加工程的安全性具有重要意义,可为后续实现熔池的闭环控制提供研究基础.

#### [参考文献] (References)

- [1] 吴陈铭,戴澄恺,王昌凌,等. 多自由度 3D 打印技术研究进展综述[J]. 计算机学报,2019,42(9):1918-1938.
- [2] 叶福兴,王永辉,娄智. 激光增材制造过程中激光与粉末的相互作用研究现状[J]. 中国表面工程,2021,34(2):1-12.
- [3] WU D, CHEN H B, HUANG Y M, et al. Monitoring of weld joint penetration during variable polarity plasma arc welding based on the keyhole characteristics and PSO-ANFIS[J]. Journal of Materials Processing Technology, 2017, 239:113-124.
- [4] CHEN Y H, CHEN B, YAO Y Z, et al. A spectroscopic method based on support vector machine and artificial neural network for fiber laser welding defects detection and classification[J]. NDT & E International, 2019, 108:102176.
- [5] VANDONE A, BARALDO S, VALENTE A, et al. Vision-based melt pool monitoring system setup for additive manufacturing[J]. Procedia CIRP, 2019, 81:747-752.
- [6] ZHANG Z F, WEN G R, CHEN S B. Audible sound-based intelligent evaluation for aluminum alloy in robotic pulsed GTAW: Mechanism, feature selection, and defect detection [J]. IEEE Transactions on Industrial Informatics, 2017, 14(7):2973-2983.
- [7] 李子哈,忻建文,肖笑,等. 热导型等离子弧焊电弧物理特性和熔池动态行为[J]. 金属学报,2021,57(5):693-702.

- [ 8 ] MAZZOLENI L, DEMIR A G, CAPRIO L, et al. Real-time observation of melt pool in selective laser melting: Spatial, temporal, and wavelength resolution criteria[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1179–1190.
- [ 9 ] 刘晓刚, 闫红方, 张荣. 基于形态学多尺度多结构的熔池图像边缘检测[J]. 热加工工艺, 2019, 48(5): 216–219.
- [ 10 ] 杨启, 田虎成, 闫昭华, 等. 激光近净成形中熔池宽度实时监控系统的研究[J]. 激光与红外, 2019, 49(9): 1060–1067.
- [ 11 ] LI X B, LI T, SHI B W, et al. The influence of substrate tilt angle on the morphology of laser cladding layer[J]. Surface and Coatings Technology, 2020, 391: 125706.
- [ 12 ] 顾振杰, 雷剑波, 张传鹏, 等. 镍硅硼合金粉末激光熔覆中熔池光谱检测分析[J]. 中国激光, 2014, 41(11): 95–102.
- [ 13 ] 雷凯云, 秦训鹏, 刘华明, 等. 基于神经网络的宽带激光熔覆熔池特征参数预测[J]. 光电子·激光, 2018, 29(11): 1212–1220.
- [ 14 ] YANG Z, LU Y, YEUNG H, et al. Investigation of deep learning for real-time melt pool classification in additive manufacturing [C]//Proceedings of the 2019 IEEE 15th International Conference on Automation Science and Engineering (CASE). Vancouver, Canada: IEEE, 2019.
- [ 15 ] LU J, HE H Y, SHI Y M, et al. Quantitative prediction for weld reinforcement in arc welding additive manufacturing based on molten pool image and deep residual network[J]. Additive Manufacturing, 2021, 41: 101980.
- [ 16 ] 王仁杰, 史圣泰. 基于机器视觉的增材制造激光熔覆熔池边缘检测和行为参数分析[J]. 中国金属通报, 2021(13): 209–210.
- [ 17 ] CAI W, JIANG P, SHU L S, 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.
- [ 18 ] JIAO W H, WANG Q Y, CHENG Y C, et al. End-to-end prediction of weld penetration: A deep learning and transfer learning based method[J]. Journal of Manufacturing Processes, 2021, 63(2): 191–197.
- [ 19 ] ZHANG Z H, LI B, ZHANG W F, et al. Real-time penetration state monitoring using convolutional neural network for laser welding of tailor rolled blanks[J]. Journal of Manufacturing Systems, 2020, 54: 348–360.
- [ 20 ] ZHANG Y X, YOU D Y, GAO X D. Welding defects detection based on deep learning with multiple optical sensors during disk laser welding of thick plates[J]. Journal of Manufacturing Systems, 2019, 51: 87–94.
- [ 21 ] XU Y L, FANG G, LV N. Computer vision technology for seam tracking in robotic GTAW and GMAW[J]. Robotics and Computer-Integrated Manufacturing, 2015, 32: 25–36.
- [ 22 ] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Honolulu, USA: IEEE, 2017.
- [ 23 ] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3 [C]//Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision(ICCV). Seoul, Korea: IEEE, 2020.
- [ 24 ] ZHANG M X, WANG Z J, SUN T Z, et al. Salient object detection by pyramid networks with gating[C]//Proceedings of the 2019 IEEE International Conference on Robotics and Biomimetics(ROBIO). Dali, China: IEEE, 2019.
- [ 25 ] 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(CVPR). Las Vegas, USA: IEEE, 2016.
- [ 26 ] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J/OL]. arXiv Preprint arXiv: 1409.1556, 2014.
- [ 27 ] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection[J/OL]. arXiv Preprint arXiv: 2004.10934, 2020.
- [ 28 ] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//Proceedings of the 15th European Conference on Computer Vision(ECCV). Munich, Germany: Springer, 2018.
- [ 29 ] ZHAO H S, SHI J P, QI X J, et al. Pyramid Scene Parsing Network [C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Honolulu, USA: IEEE, 2017.
- [ 30 ] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation [C]//Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI). Munich, Germany: MICCAI, 2015.
- [ 31 ] 张亚红, 覃科. 一种形态学与 Canny 算子融合的焊接熔池边缘检测算法[J]. 桂林航天工业学院学报, 2017, 22(1): 9–13.

[ 责任编辑: 严海琳 ]