

引文格式: 李迁, 毛杨坤, 朱鲲鹏. 面向LPBF铺粉异常检测的轻量化目标检测模型[J]. 航空制造技术, 2026, 69(19): 26020015.

LI Qian, MAO Yangkun, ZHU Kunpeng. Lightweight object detection model for LPBF powder spreading anomaly detection [J]. Aeronautical Manufacturing Technology, 2026, 69(19): 26020015.

面向LPBF铺粉异常检测的轻量化目标检测模型

李 迁^{1,2}, 毛杨坤^{1,2}, 朱鲲鹏^{2,3,4}

- (1. 中国科学技术大学, 合肥 230026;
2. 中国科学院合肥物质科学研究院智能机械研究所, 合肥 230031;
3. 常州先进制造技术研究所, 常州 213164;
4. 武汉科技大学, 武汉 430081)

[摘要] 在激光粉末床熔融(Laser powder bed fusion, LPBF)成形过程中, 铺粉质量是影响构件成形与工艺稳定性的关键因素。然而, 现有的检测方法在实时性、准确性和对复杂工艺场景的适应性方面仍存在局限性。为应对铺粉过程中因复杂背景与多尺度异常带来的实时检测挑战, 提出了一种基于RT-DETR(Real-time detection transformer)改进的轻量化目标检测模型PS-DETR(Powder spreading detection transformer)。PS-DETR采用高效局部-全局上下文聚合模块重构主干网络, 在降低模型复杂度的同时增强了模型的特征提取能力, 同时采用一种基于注意力的特征拼接模块, 有效提升了对多尺度异常特征的整合与聚焦能力。将上述改进在基于点阵结构铺粉过程采集的图像数据集上进行训练与验证。结果表明, PS-DETR模型的mAP@50达94.35%, 较基准模型提升3.97个百分点, 参数量降低29.6%, 验证了各模块的有效性及模型综合性能的优越。

关键词: 激光粉末床熔融(LPBF); 过程监测; 铺粉异常检测; 点阵结构; RT-DETR

中图分类号: V261.8 文献标志码: A DOI: 10.16080/j.issn1671-833x.26020015

Lightweight Object Detection Model for LPBF Powder Spreading Anomaly Detection

LI Qian^{1,2}, MAO Yangkun^{1,2}, ZHU Kunpeng^{2,3,4}

- (1. University of Science and Technology of China, Hefei 230026, China;
2. Institute of Intelligent Machines, Hefei Institutes of Physical Science, Chinese Academy of Sciences, Hefei 230031, China;
3. Changzhou Institute of Advanced Manufacturing Technology, Changzhou 213164, China;
4. Wuhan University of Science and Technology, Wuhan 430081, China)

[ABSTRACT] Powder spreading quality represents a critical factor that affects the part forming and process stability during the laser powder bed fusion (LPBF) forming process. However, existing detection methods still face limitations in real-time capability, accuracy, and adaptability to complex process scenarios. To address the real-time detection challenges posed by complex backgrounds and multi-scale anomalies during the powder spreading process, this paper proposes the powder spreading detection transformer (PS-DETR), an improved lightweight object detection model based on the real-time detection transformer (RT-DETR). PS-DETR reconstructs the network backbone with efficient local-global context aggregation, which reduces the model complexity while enhancing its feature extraction capability. Meanwhile, it incorporates an attention-based feature concatenation module, effectively enhancing its ability to integrate and focus on

收稿日期: 2026-01-13; 退修日期: 2026-01-20; 录用日期: 2026-03-11

基金项目: 国家自然科学基金(52175528)

通信作者: 朱鲲鹏, 研究员, 研究方向为金属增材制造过程监测。

multi-scale abnormal features. These improvements were trained and validated on the image dataset collected from the powder spreading process for lattice structures. Experimental results show that the proposed PS-DETR model achieves a mAP@50 of 94.35%, representing an improvement of 3.97 percentage points over the baseline model while reducing the number of parameters by 29.6%, which confirms the effectiveness of the proposed modules and the model's superior performance.

Keywords: Laser powder bed fusion (LPBF); Process monitoring; Powder spreading anomaly detection; Lattice structure; Real-time detection transformer (RT-DETR)

激光粉末床熔融 (Laser powder bed fusion, LPBF) 作为增材制造 (Additive manufacturing, AM) 领域中具有良好发展前景的技术之一^[1-3], 由于其材料利用率高、生产周期短、设计自由度高等特点被广泛应用于汽车工业、航空航天、船舶制造等领域^[4-5], 尤其在需要高性能、复杂几何形状设计的航空零件制造领域, LPBF 具有无可比拟的优势^[6-9]。LPBF 工艺首先在金属基板上均匀铺设金属粉末, 随后通过激光束熔化粉末实现成型。单层加工完成后, 构建平台下降并重复进行铺粉与熔化操作, 最终通过这种逐层累加的方式制造出完整的金属零件。在不断重复的铺粉过程中, 刮刀与粉末床之间的相互作用可能引发刮刀跳动、刮痕、碎片、超高、铺粉不均匀等异常情况, 这些异常可能会影响制造过程的稳定性, 进而影响零件的最终成形质量^[10-12]。因此, 对打印过程进行实时铺粉监测以保证铺粉质量, 对于整个 LPBF 工艺而言至关重要^[13-15]。

基于图像的视觉方法广泛应用于早期的 LPBF 成形过程监测中, 这些方法主要通过各类光学传感器实时捕获成形过程中的图像信号, 并借助先进的图像处理和图像分析技术识别成形过程中可能出现的质量问题^[16]。早期的许多研究聚焦于利用可见光成像相机对每个打印层的表面特性及铺粉质量进行视觉监测, 通过分析 AM 零件制造过程中的逐层可视化数据获取有关缺陷和零件质量的有效信息。Craeghs 等^[17]利用视觉相机建立了一套粉末床监测系统, 能够有效检测因刀片磨损或局部损坏导致的铺粉不均匀异常, 并将其视为可能导致零件缺陷的工艺故障。Zur 等^[18]利用视觉成像系统从沉积的粉末层中捕获图像, 并通过恒定阈值检测粉末床中的凸起区域。然而, 上述方法主要依赖于专家知识驱动的图像处理技术, 存在知识获取成本高、自动化程度低等问题, 难以实现高效率、智能化的铺粉质量检测。

目标检测技术以其卓越的空间定位与智能分类能力, 为铺粉异常检测问题提供了理想的模型框架, 符合 LPBF 过程监测对于自动化、高效率的需求。目前常见的

目标检测方法包括 SSD^[19]、YOLO^[20]、Fast-RCNN^[21]等。近年来, 基于 Transformer 的模型凭借其强大的全局关系建模能力以及简化的检测流程, 在目标检测领域展现出显著优势^[22]。Facebook 团队基于 Transformer 提出的 DETR (Detection transformer)^[23]模型将目标检测任务重新定义为图像到集合的问题, 借助匈牙利算法确定目标分类预测帧与实际帧的最佳匹配。然而, DETR 编码器设计的复杂性导致其收敛速度缓慢、实时性较差, 这限制了 DETR 的实际应用。为此, 百度团队提出的 RT-DETR (Real-time detection transformer)^[24]模型针对 DETR 架构中 Transformer 编码器实时性不足的缺陷, 创新性地引入了一种高效混合编码器设计。这一改进通过解耦尺度内交互和跨尺度融合来快速处理多尺度特征以提高推理速度, 减少了冗余计算, 进一步提高检测的准确性, 有效解决了原有架构在实时目标检测场景中的性能瓶颈, 并在公共数据集中表现优于 YOLO 系列网络。


本文针对 LPBF 铺粉过程中存在的各类异常情况, 在 RT-DETR 的基础框架上提出 PS-DETR (Powder spreading detection transformer), 旨在为 LPBF 铺粉质量监测提供一种轻量化、高精度的在线目标检测解决方案。

1 试验设置


1.1 铺粉数据采集系统

本研究采用的 LPBF 设备为 EOS M290, 如图 1(a) 所示。该设备搭载了 EOS PowderBed、EOS EOSTATE 等模块用于采集现场数据, 设备腔室尺寸为 250 mm×250 mm×325 mm, 粉末层厚度在 20~100 μm 之间可调, 配备 400 W 光纤激光器, 扫描速度可达 7 m/s, 光斑直径为 100~500 μm。

试验采用 EOS M290 设备搭载的 EOS PowderBed 粉末床监测系统拍摄每一层粉末的铺粉状态, 该系统使用 100 万像素可见光相机视野, 可覆盖整个 250 mm×250 mm 的粉末床, 照明由腔室右侧的白色 LED 灯提供。图 1(b) 所示为 LPBF 铺粉监测过程示意图。试验过程



(a) EOS M290设备



(b) 铺粉数据采集示意图

图1 铺粉数据采集系统

Fig.1 Powder spreading data acquisition system

使用Ti-6Al-4V4钛合金粉末材料打印点阵结构的金属构件,粉末直径为 $15\sim 53\text{ }\mu\text{m}$,粉末层厚恒定为 $30\text{ }\mu\text{m}$,激光功率、扫描速度和扫描间距范围见表1,通过变能量密度的打印模拟各类铺粉异常的出现情况。当刮刀铺设完一层粉末后移动到构建区域边缘,设备控制系统发送触发信号至相机以启动图像采集程序,从而实现粉末床图像的采集。

1.2 点阵结构设计

点阵结构是一种由单元晶胞周期性排列所构成的多孔材料结构,其在轻量化、比强度、多功能性方面都展现出显著优势^[25-27]。点阵结构凭借其内在的“镂空”特性,在可接受的强度损失下大幅提升构件的比强度与能量吸收效率,因此被广泛应用于抗冲击与振动抑制领域^[28]。然而,此类具有复杂拓扑构型的结构难以通过传统减材工艺实现。LPBF因其能够高精度地直接成形任意复杂三维几何结构,现已成为制备点阵结构功能零件的核心工艺手段^[29]。

本研究所采用的单元晶胞结构为体心立方^[30],晶胞

表1 工艺参数

Table 1 Process parameters

参数名称	参数范围
激光功率/W	110~370
扫描速度/(mm/s)	800~2000
扫描间距/ μm	100~140

的杆径设定为 1.8 mm ,其三维几何构型及关键尺寸标注如图2(a)所示。单层点阵由 4×5 的晶胞排列而成,在宏观上呈现为一个 20 mm (长) $\times 16\text{ mm}$ (宽) $\times 4\text{ mm}$ (高)的长方体结构。为满足测试需求,构件顶部还设计了厚度为 0.5 mm 的实心层。点阵构件的整体三维模型如图2(b)所示,该构件由6个单层点阵模块在垂直方向上堆叠而成,构件底部设计了一层实心基座,该设计旨在确保使用线切割技术将构件从打印基板上分离时,能有效避免对底部点阵结构造成机械损伤,保证试验样本的完整性。图2(c)展示了制造的单个点阵结构样件。本研究基于表1的试验参数制造了不同工艺下的点阵结构零件,如图2(d)所示。

1.3 数据集构建

通过上述试验可获取各层分辨率为 $1280\text{ pixel}\times 1024\text{ pixel}$ 的铺粉图像共2032张,这些图像对应的实际视场大小约为 $400\text{ mm}\times 330\text{ mm}$,如图3(a)所示。根据专业增材制造人员对铺粉图像的观察和分析,可将铺粉异常情况归为以下4类:轻度超高异常(Mild super-elevation, MSE)、重度超高异常(Severe super-elevation, SSE)、刮痕异常(Recoater streaking, RS)和铺粉不均匀(Incomplete spreading, IS),如图3(b)~(e)所示。这些铺粉异常产生的原因分别如下。

(1)轻度超高异常。过熔融会导致熔池尺寸显著增大,进而引起几何形状偏差,当凝固的熔池高度大于粉末层厚时,零件表面的凸起将影响后续的铺粉过程,并导致零件表面部分裸露在粉床上。此类零件异常区域的凸起程度较低,不易对加工过程产生严重危害。

(2)重度超高异常。与上述异常产生原因相同,然而此类零件异常区域凸起的程度较高,容易对加工过程产生不可逆的损害,并影响刮刀的正常移动,因此需要重点检测。

(3)刮痕异常。由于刮刀拖动剥落的金属颗粒在粉末床上划出沟槽状的划痕,或刀片损坏导致其在铺粉时无法均匀接触粉末床从而在粉末床上形成平行于铺粉方向的条形纹路。

(4)铺粉不均匀。零件表面粗糙度增大、粉末粒径分布异常及刮刀运动误差,都可能导致粉末床表面出现




图2 点阵结构设计与实物图

Fig.2 Lattice structure design and physical sample




图3 铺粉图像及各类异常

Fig.3 Powder spreading images with typical anomalies

铺粉不均匀的现象。对于本研究中的点阵夹层而言,该类情况常见于点阵结构与实心层部分的过渡阶段。

本研究针对 LPBF 铺粉异常检测任务,对原始分辨率图像进行了优化处理。在预处理阶段剔除了包含实心基底等非点阵区域的图像,共获得 1592 张原始图像。为避免直接输入全尺寸图像导致 RT-DETR 模型特征提

取能力下降和计算效率降低,采用中心裁剪策略对图像边缘非重点区域实施精确裁剪,保留中心 960 pixel×640 pixel 的关键铺粉区域,基于裁剪后的图像使用 labeling 工具完成了铺粉异常区域的位置标注和分类标注。同时,为了提高模型的泛化能力,采用 180° 旋转和镜像翻转的图像增强方式对数据集进行扩充。最终构建的数

数据集包含 3184 张工艺图像,共标注 63206 个异常目标,完整覆盖了轻度超高异常、重度超高异常、刮痕异常和铺粉不均匀 4 种典型异常情况。最后,按照 7:2:1 的比例将标注好的图像划分为训练集、测试集和验证集,确保模型评估的科学性。

2 面向铺粉异常检测的 PS-DETR 模型

2.1 PS-DETR 整体架构设计

RT-DETR 是第一款实时的端到端目标检测模型,在速度和精度之间实现了理想的平衡。RT-DETR 主要由主干网络(Backbone)、高效混合编码器(Efficient hybrid encoder)及带辅助预测头的 Transformer 解码器组成,其结构如图 4 所示。

RT-DETR 的主干网络主要负责提取多尺度图像特征并将最后三级特征(S3、S4、S5)分别传入高效混合编码器中,该高效混合编码器主要由两个模块组成:基于注意力的尺度内特征交互(Attention-based intra-scale feature interaction, AIFI)及基于 CNN 的跨尺度特征融合(CNN-based cross-scale feature fusion, CCFF)。AIFI 模块利用单尺度 Transformer 编码器在 S5 上执行尺度内交互并输出为 F5,而 CCFF 模块则由若干个卷积(Conv)、上采样(UpSample)、重参数化(RepC3)模块组成,CCFF 模块通过跨尺度特征融合有效整合了 S3、S4、F5 这 3 个尺度的特征并将其转换为图像特征序列,提升了模型对不同大小目标的检测能力。随后 IoU 感知查询选择依据不确定性最小化原则从 CCFF 模块输出的特征序列中选择固定数量的特征作为解码器的初始目标查询,基于 Transformer 的解码器依靠注意力机制增强全局特征交互能力,再由辅助预测头迭代优化查询目标,通过生成边界框和置信度得分逐步确定目标的位置和类别信息。

RT-DETR 这种端到端的检测模式既保持了 DETR 系列模型的结构优势,又开创性地通过特征编码和查询选择机制拓宽了实时目标检测的技术路径,实现了检测速度与精度的合理平衡,因此 RT-DETR 在面对各类复杂场景的检测问题时仍然具有良好的性能。

LPBF 逐层制造的特性对铺粉异常检测提出了高实时与高精度的双重要求,系统需在较短的层间周期内完成分析,并准确判断粉末床随机纹理中的异常区域。尽管 RT-DETR 基准模型在通用实时目标检测任务中表现优异,但其设计初衷是服务于自然图像检测任务,针对 LPBF 过程中铺粉异常检测这一特定场景,RT-DETR 在检测精度与计算轻量化方面仍存在一定的优化空间。

为突破上述局限,本文以 RT-DETR 为基础架构,围绕精度提升与轻量化部署两个核心目标,针对 RT-DETR 的高效特征编码器进行改进并提出了专用于铺粉异常检测的 PS-DETR 模型。PS-DETR 中高效混合编码器部分的结构如图 5 所示,其中 ELGCA 代表高效局部-全局上下文聚合模块,ABFCM 代表基于注意力的特征拼接模块(Attention based feature concatenate module, ABFCM)。

2.2 基于 ELGCA 模块的主干网络改进

在目标检测任务中,主干网络主要负责对输入的图像进行特征提取,RT-DETR 提供了多种型号的主干网络,如 ResNet-18、ResNet-34、ResNet-50 等,如图 6 所示。本研究参考 ResNet18 主干网络并针对铺粉异常检测这一目的对其进行结构性优化,ResNet18 主干网络的结构如图 6(a)所示。ResNet18 作为一款轻量级网络采用 3 层卷积层(ConvN)、1 层最大池化层(MaxPool)和 4 层 Block 的结构来平衡计算负担,然而这样的设计在同时处理局部和全局上下文信息时会更偏向局部效率,从




图 4 RT-DETR 模型结构图

Fig.4 Architecture diagram of the RT-DETR model

而导致全局特征被弱化。在特征图语义信息的判别过程中,单一像素点是否能被定义为“目标像素”不取决于它本身,而取决于它周围区域的统计特性。针对铺粉异常检测这一具体问题,由于粉末床本身是由无数微小颗

粒构成的随机纹理场,这种基于局部统计的判别方式极易将正常的随机纹理波动误判为异常,导致模型产生较高的误检率。而从模型构建的层面分析,缺乏全局上下文信息意味着模型无法建立判断所需的正常基准,因此




图5 PS-DETR中的高效混合编码器设计

Fig.5 Design of the efficient hybrid encoder in PS-DETR




图6 主干网络结构示意图

Fig.6 Schematic diagram of backbone

全局上下文信息的丢失可能会削弱模型的推理能力并降低判断的准确性。

为此,本研究引入高级局部-全局上下文聚合模块(Efficient local-global context aggregation, ELGCA)模块以解决全局上下文信息缺失的问题,从而增强模型在随机纹理背景下准确判别铺粉异常的能力。ELGCA^[31]是一种高效的局部-全局上下文信息聚合模块,该模块通过新颖的池化转置(Pool-transpose, PT)注意力机制和深度卷积捕获增强的全局上下文和局部空间信息,其整体结构如图6(g)所示。

输入ELGCA模块的特征图 X 可用数学公式表示为

$$X \in \mathbb{R}^{C \times H \times W} \quad (1)$$

式中, C 、 H 、 W 分别表示输入图像的通道数、高和宽。

首先对输入特征 X 按通道进行分割,得到提取局部特征和全局特征的过程量 X_{lo} 和 X_{gl} ,即

$$X_{lo}, X_{gl} = \text{Split}(X) \quad (2)$$

随后,对 X_{lo} 执行 3×3 的深度卷积(DW Conv)从而得到 $\bar{X}_{lo}$ 。在深度卷积中,每个通道都对应分配一个单独的卷积核,从而实现在每个通道上进行独立的卷积操作。上述的局部上下文聚合操作能够以较少数量的模型参数和浮点数运算有效地捕获局部上下文信息。同时,对 X_{gl} 执行 1×1 卷积以提升通道维度,再沿通道维度将其拆分为 Z 、 Q 、 K 、 V 这4个特征,其中, Z 特征用于多通道特征聚合, Q 、 K 、 V 特征被用作PT注意力机制的输入,以捕获全局上下文信息的查询(Query)、键(Key)和价值(Value)。PT注意力机制的关键步骤如下:(1)对 Q 特征执行步长为2的 3×3 平均池化以得到平均特征 $\bar{Q}$;(2)对 K 特征执行步长为2的 2×2 最大池化以得到主导特征 $\bar{K}$;(3)对所得的 $\bar{Q}$ 、 $\bar{K}$ 和 V 特征使用转置注意力操作。具体步骤如下。

$$A_{att} = V \times \left[\sigma \left(\bar{K}^T \times \bar{Q}^T \right) \right] \quad (3)$$

式中, $\times$ 代表矩阵乘法; σ 代表Softmax函数。

最后,利用通道拼接将具有不同感受野的局部特征(X_{lo})和全局上下文聚合特征($\bar{X}_{lo}$ 、 Z 、 A_{att})进行通道拼接,得到丰富的局部-全局上下文聚合特征 $\bar{X}$ 。

通常来说,自注意力机制在接收长度为 n 的输入序列后,需计算所有像素对之间的相似度,并生成 $n \times n$ 的注意力矩阵,因此计算复杂度为 $O(n^2)$ 。本文所采用的PT注意力机制的计算复杂度仅为 $O(n)$,采用池化操作进行特征提取并利用转置注意力最小化计算代价,保证全局建模能力的同时显著降低了计算成本。

本研究将ELGCA模块引入ResNet18主干网络中,设计了ELGCA-based主干网络,其结构如图6(b)所示。

ELGCA-based主干网络首先采用ELGCA代替了ResNet18主干网络中的4层残差块结构以增强主干网络提取全局上下文信息的能力,通过创新的PT注意力机制,以远低于传统自注意力的计算复杂度实现了局部细节与全局语义的高效聚合,从根本上弥补了ResNet18依赖堆叠卷积导致的全局上下文捕捉能力不足的缺陷。同时,进一步取消了卷积层中的批归一化(BN)和激活函数(ReLu),采用步长为2的 3×3 卷积进行下采样,在保证特征图尺寸压缩效率的同时,减少了下采样过程中的信息损失。

在LPBF铺粉异常检测任务中,粉末床区域通常呈现为具有随机纹理特征的复杂背景,诸如刮痕、铺粉不均匀等各类异常在视觉上往往与正常纹理局部相似,若仅依赖局部特征进行判别,容易引发误判。传统ResNet18结构侧重于局部细节的提取,在缺乏全局上下文引导的情况下,难以准确区分异常区域与背景纹理的自然波动。ELGCA模块能够强化模型对图像整体结构的理解能力,从而提升模型在复杂纹理背景下识别与定位铺粉异常的准确性,这一点主要体现在“铺粉不均匀”这类异常的检测中。“铺粉不均匀”主要是由刮刀运动误差或粉末粒径分布异常导致的局部粉末堆积,其图像特征表现为局部灰度均值持续偏离全局基准。ELGCA能够通过平均池化捕获全局层厚对应的灰度基准,并结合局部特征捕获区域灰度偏差,使模型能够更加准确地定位铺粉不均匀区域的范围。

2.3 基于注意力的特征拼接模块

RT-DETR模型在CCFF中使用特征拼接(Concat)实现跨尺度特征融合,该方法通过直接堆叠不同来源的特征图以整合不同尺度的信息。然而,该方法对不同特征图进行等权重处理,无法区分不同区域特征重要性,有可能导致关键特征容易被非关键特征响应所稀释。同时,由于缺乏对通道维度的特征筛选机制,低信噪比的通道特征与高价值特征被同等对待,致使高价值特征被无关信息淹没,制约了模型性能的进一步提升。

在针对点阵结构的铺粉异常检测中,各类异常纹理往往表现为与周期性结构不匹配的局部高亮或较暗区域,其特征容易与正常结构的边缘或反光区域混淆。在该场景下,上述等权重机制由于缺乏对特征重要性的自适应区分能力,难以有效解耦异常信息与背景纹理,易导致微弱的异常特征响应被点阵结构本身的多变几何特征所淹没。为此,本文设计了ABFCM来代替Concat操作,ABFCM通过通道对齐、通道注意力选择、空间注意力增强、多重交叉特征融合4部分实现了多尺度特征的有效融合,其结构如图7所示(其中C表示Concat)。

该模块中,输入的低层特征和高层特征分别表示为 $F_0 \in \mathbb{R}^{C_0 \times H \times W}$ 和 $F_1 \in \mathbb{R}^{C_1 \times H \times W}$ 。由于不同层级特征图在

通道维度上存在固有差异,若直接进行特征拼接或加权融合,将导致语义信息的不匹配。所以,首先对低层特征 F_0 使用 1×1 的卷积使其通道数与高层特征 F_1 对齐,并将对齐后的特征图重新命名为 X_0 和 X_1 。随后对通道数相同的两个特征进行拼接得到拼接特征 X_{cat} ,即

$$X_{cat} = \text{Concat}(X_0, X_1) \quad (4)$$

对拼接特征 X_{cat} 执行通道注意力机制,通过结构化方式学习通道间依赖关系,其处理流程如下:先由一个全局平均池化将每个通道的全局空间信息压缩为单值描述符,随后利用两个全连接层(Linear)和 Relu 构建“降维—激活—升维”的瓶颈结构,在引入非线性的同时保证模型的特征表达能力,最后利用 Sigmoid 激活函数生成 $0 \sim 1$ 范围内的通道权重,将这些权重与特征图按通道维度进行相乘,得到经过通道注意力加权的特征 $X_{ch} \in \mathbb{R}^{2C_1 \times H \times W}$ 。

$$X_{ch} = \text{Sigmoid}\left(\text{Linear}\left(\text{Relu}\left(\text{Linear}\left(\text{AvgPool}\left(X_{cat}\right)\right)\right)\right)\right) \quad (5)$$

在通道加权特征 X_{ch} 的基础上,进一步施加空间注意力机制以学习空间位置的重要性分布,其具体流程如下:首先沿通道维度分别进行最大池化和平均池化生成两个空间特征描述符,将它们拼接形成空间特征表示;随后通过一个 3×3 卷积学习空间位置间的局部关系,并实现通道数转换,再通过批归一化层稳定梯度尺度以防止梯度消失或梯度爆炸;最后通过 Sigmoid 激活函数生成空间维度的注意力权重图 $W_{sp} \in \mathbb{R}^{1 \times H \times W}$ 。

$$W_{sp} = \text{Sigmoid}\left(\text{BN}\left(\text{Conv}\left(\text{Concat}\left(\text{MaxPool}\left(X_{ch}\right), \text{AvgPool}\left(X_{ch}\right)\right)\right)\right)\right) \quad (6)$$

将空间权重 W_{sp} 与通道加权特征 X_{ch} 相乘,得到空间注意力机制的最终输出,实现对重要区域的聚焦增强和背景噪声的抑制。通过分割操作将空间注意力机制

的最终输出沿通道维度拆分为两部分,分别对应原始输入特征图 X_0 和 X_1 的注意力加权版本,为后续的交叉融合提供特征权重分配。

$$\bar{X}_0, \bar{X}_1 = \text{Split}(W_{sp} \times X_{ch}) \quad (7)$$

本文采用多重交叉特征融合机制进一步提升跨层信息的交互,多重交叉特征融合的表达式为

$$\text{output} = \text{Concat}\left(X_0 + X_1 \times \bar{X}_1, X_1 + X_0 \times \bar{X}_0\right) \quad (8)$$

该融合策略使每个特征图均接收来自另一特征图的注意力加权信息,既保留了原始特征的身份映射,又引入了跨特征的适应性增强,最终通过通道维度拼接形成具有丰富互补信息的融合输出。

ABFCM 通过其双注意力与多重交叉融合机制优化了对各类异常纹理的特征提取能力。通道注意力机制对不同特征通道进行自适应加权,增强与异常特征相关性强的通道,抑制由背景噪声和正常结构纹理引起的干扰,从而提升对异常特征的关注性。空间注意力机制和多重交叉融合机制则使得模型进一步聚焦特征图中局部异常区域,增强这些位置的特征响应,减少因点阵周期性边缘导致的误判。

3 结果与讨论

3.1 消融试验

本研究所有训练过程均遵循统一的参数配置:训练轮次为 100 个 epoch, batch 大小设置为 4, 在输入前,将图像尺寸统一调整为 640×640 。训练过程采用 AdamW 优化器,学习率恒定为 0.0001,其余参数参考 RT-DETR 模型的初始设置。本研究所使用的环境如表 2 所示。

为全面评估模型的检测性能,本文采用以下关键指标进行量化分析:准确率(Precision)、召回率(Recall)和平均精度均值(Mean Average Precision, mAP)。其中,准确率衡量模型预测结果的可靠性,定义为预测为正类




图7 基于注意力的特征拼接模块结构示意图

Fig.7 Schematic diagram of attention-based feature concatenate module

的样本中实际为正类的比例,其具体计算公式为

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (9)$$

召回率反映模型的检测覆盖能力,定义为实际为正类的样本中被正确预测的比例,其具体计算公式为

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (10)$$

mAP被广泛认为是目标检测任务中最具综合性和代表性的性能评估指标之一。它综合考虑了不同类别的检测效果,以及每个类别在不同置信度阈值下的表现。mAP的具体计算公式为

$$\text{mAP} = \frac{1}{N} \sum_{i=1}^N \text{AP}_i \quad (11)$$

式中, N 代表类别的总数; AP_i 代表第 i 类别的平均精度。在目标检测任务中,mAP的定义引入了交并比(Intersection over Union, IoU)阈值的概念作为判定预测边界框与真实标注框匹配程度的依据。本文采用“mAP@50”和“mAP@0.50: 0.95”作为评估指标,“mAP@50”表示当IoU阈值为0.5时计算的mAP值,“mAP@0.50: 0.95”表示IoU阈值在[0.50, 0.55, ... 0.95]内计算的mAP平均值。

除模型的检测精度外,本文还关注模型的计算效率,因此引入运算量(FLOPs)和参数量(Parameters)来反映模型的计算效率。运算量以十亿次浮点运算

(GFLOPs)为单位,表示模型单次前向推理所需的计算复杂度,其数值直接反映了模型的推理速度和对硬件负荷的需求。参数量则以百万(10^6)计,度量模型所有训练参数的总和,反映了模型的存储占用和内存消耗规模。

为了更好地印证各模块组合对模型性能的影响,本文设计了消融试验,在相同的配置环境、训练参数及默认损失函数GIoU下,验证各个改进步骤对检测精度和计算开销的影响。本文以RT-DETR作为基准模型,并选择ResNet18作为默认的主干网络,消融试验结果如表3所示。

从表3中可以看出,将主干网络替换为ELGCA-based主干网络之后,模型的参数量从 19.88×10^6 降低至 13.87×10^6 ,浮点运算次数减少17.9%,检测精度提高1.63个百分点,同时mAP@50达到了92.9%。试验结果表明,本文所提出的ELGCA-based主干网络通过简化模型结构有效降低计算开销,并且借助ELGCA模块特有的上下文信息聚合机制使模型的特征提取能力得到增强,从而在降低模型复杂度的同时实现了检测精度的提升,达到了精度与效率的协同优化。

在替换默认的特征拼接模块为ABFCM后,模型参数量仅有0.12 M的小幅度增大,浮点运算次数几乎没有增加,但是得益于ABFCM更为强大的跨尺度特征交互能力,模型在准确率、召回率和mAP等指标上均有提高。

在同时加入ELGCA-based主干网络和ABFCM时,mAP@50和mAP@0.50: 0.95分别达到了94.35%和82.63%,相较于原来的RT-DETR模型分别增长了3.97和3.37个百分点,模型的参数量则由 19.88×10^6 降至 13.99×10^6 。可以观察到,同时使用ELGCA-based主干网络与ABFCM的模型在准确率、mAP@50和mAP@0.50: 0.95等指标上比仅使用ELGCA-based主干网络的模型分别高出3.44、1.45和2.81个百分点,尽管后者在召回率指标上表现出1.14个百分点的微弱优势,但其优势是以牺牲精度为代价的,而前者在代表综合性能的

表2 设备配置

Table 2 Device configuration

设备名称	配置
系统	Windows 11
CPU	Intel(R) Core(TM) i9-14900HX
GPU	NVIDIA GeForce RTX 4060 Laptop GPU
内存	32 G
Python	3.12.4
CUDA	12.4
PyTorch	2.4.1

表3 消融试验结果

Table 3 Results of ablation experiments

ELGCA	ABFCM	Precision/%	Recall/%	mAP@50/%	mAP@0.50: 0.95/%	GFLOPs	Parameters/ $\times 10^6$
		85.90	90.30	90.38	79.26	57.0	19.88
√		87.53	92.80	92.90	79.82	46.8	13.87
	√	86.20	91.00	90.62	79.77	57.0	20.00
√	√	90.97	91.66	94.35	82.63	46.9	13.99

mAP指标上取得了显著领先。从整体性能和应用价值来看,本研究所构建的PS-DETR算法在集成了上述模块后,在检测性能与轻量化水平方面均优于原版RT-DETR。

3.2 对比试验

为了进一步验证PS-DETR的模型性能,本文还将PS-DETR模型与YOLO系列从YOLOv5到YOLOv10尺寸相近的模型,以及采用ResNet-18和ResNet-34为主干网络的RT-DETR模型在数据集上的训练结果进行对比,对比试验采用的参数配置及评价指标均与消融试验相同,对比结果如表4所示。

由表4可以看出,与相近尺寸的模型相比,PS-DETR在检测性能方面的表现十分优异,各项检测指标准确性均为最优。YOLO系列模型中的YOLOv8s、YOLOv9s和YOLOv10s都是较为轻量化的检测模型,其参数量分别为 11.13×10^6 、 7.17×10^6 和 8.09×10^6 ,然而有限的模型容量制约了它们构建高复杂性特征层次的能力,这一固有局限直接导致模型的多尺度检测能力较弱,难以充分捕捉与融合不同尺度的目标特征,从而最终限制了检测精度,也揭示了模型尺度与性能上限之间的内在制约关系。

相较于YOLO系列中的轻量化版本,参数量与计算复杂度更高的模型凭借更大的模型容量实现了检测精度的显著提升,其中YOLOv8m的准确率与mAP@50分别达到了90.07%和90.63%,在准确率和mAP@50的指标上较原版RT-DETR-R18模型略有优势,但其

mAP@0.50:0.95仅为75.28%,低于原版RT-DETR-R18模型的79.26%,表明模型的精确定位能力不足,同时其参数量和浮点运算次数也远大于原版RT-DETR-R18模型。因此,本文选择综合表现更好的RT-DETR-R18模型作为基准模型。

在铺粉异常检测这一特定情境下,PS-DETR模型在各项性能指标方面均高于其他对比的目标检测算法,相较于RT-DETR-R18和RT-DETR-R34模型,mAP@50分别提高了3.97和2.37个百分点,模型参数量较原版RT-DETR-R18模型减少了 5.89×10^6 。这足以证明,PS-DETR模型在LPBF铺粉异常检测的轻量化和高精度方面均达到了较为出色的效果。

3.3 可视化分析

为进一步验证PS-DETR算法相较于原版RT-DETR在铺粉异常检测中的优势,本研究选取了LPBF过程中不同阶段的实时监测图像进行可视化对比分析。图8展示了EOS M290在打印点阵结构中间层时,两种算法对同一场景的检测结果对比。可以观察到,原版RT-DETR算法在粉末床右上方区域出现明显误判,将正常的阴影区域错误识别为“刮痕”,同时,在第一张测试图像中,该算法虽成功识别出两处独立“刮痕”,却额外将其整体区域误判为“铺粉不均匀”,并且在检测打印区域第一排第一个零件的“超高”异常时,由于RT-DETR算法的多个输出查询各自独立地匹配到了目标的不同特征模式,导致该区域出现多个检测结果。相比之下,PS-DETR算法在这些场景中均表现

表4 模型对比结果
Table 4 Comparative results of models

Model	Precision/%	Recall/%	mAP@50/%	mAP@0.50:0.95/%	GFLOPs	Parameters/ $\times 10^6$
YOLOv5m	84.92	84.25	87.20	70.27	64.0	25.05
YOLOv8s	75.52	84.77	83.75	71.46	28.4	11.13
YOLOv8m	90.07	83.95	90.63	75.28	78.7	25.84
YOLOv9s	78.12	81.34	80.54	70.42	26.7	7.17
YOLOv9m	80.20	85.34	87.32	74.83	76.5	20.02
YOLOv10s	72.57	79.93	80.51	69.69	24.5	8.09
YOLOv10m	80.04	82.23	86.79	72.74	63.4	16.46
YOLOv10b	79.28	87.33	89.34	73.08	98.0	20.42
RT-DETR-R18	85.90	90.30	90.38	79.26	57.0	19.88
RT-DETR-R34	87.89	90.28	91.98	77.91	88.8	31.11
PS-DETR	90.97	91.66	94.35	82.63	46.9	13.99

出更准确的检测能力,不仅有效避免了阴影区域的误判,还实现了对异常类型的精确区分和定位,证明了其在复杂工业场景下具有更强的鲁棒性和分类准确性。

图9展示了点阵结构与实心层打印过渡阶段的检测结果。在此阶段,激光功率与扫描策略都发生了阶段性的转变,已凝固层表面的粗糙度显著增大,致使后续铺粉过程中更易出现铺粉不均匀现象。从图9中可

以观察到,RT-DETR在“铺粉不均匀”区域存在非常严重的重复检测情况,这主要是由于其骨干网络对相似纹理区域的过度响应及跨层级特征融合不充分所致,导致其无法将该区域识别为一个整体异常。相比之下,本文提出的PS-DETR通过引入ELGCA-based主干网络和ABFCM显著改善了此类问题。ELGCA模块通过增强局部和全局特征的交互,提升了网络对铺粉不




图8 点阵结构中间层异常检测结果对比

Fig.8 Comparison of anomaly detection results in the intermediate layer of lattice structure




图9 点阵-实心过渡区域异常检测结果对比

Fig.9 Comparison of anomaly detection results in the lattice-solid transition region

均匀区域整体纹理特征的感知能力,避免了基于局部相似性的重复检测,而ABFCM通过双注意力机制,在特征融合阶段强化了不同尺度特征间的互补性,确保了检测框的准确性和唯一性。试验结果表明,PS-DETR在保持高召回率的同时,有效消除了重复检测现象,证明了其在复杂纹理背景检测中的优越性。

4 结论

本文针对LPBF过程中的铺粉异常实时精准检测问题,基于RT-DETR提出了一种改进的检测模型PS-DETR。该模型基于ELGCA模块对原ResNet18主干网络进行简化,在有效降低模型参数数量的同时,借助ELGCA独特的PT注意力机制有效增强了模型对粉末床图像局部细节与全局上下文信息的聚合能力,使模型在随机颗粒背景中能够更好地区分真实异常与纹理波动。同时,设计了基于注意力的ABFCM,通过双注意力机制与多重交叉融合显著提升了模型对多尺度异常特征的整合与聚焦能力,有效抑制了复杂纹理背景的干扰。为验证模型性能,本研究选取具有复杂空间特征的点阵结构制造试验以增加检测场景的复杂度,通过试验采集了打印过程中的粉末床图像,并构建了针对4类典型铺粉异常的专用数据集,为算法训练与评估提供了可靠的数据基础。试验结果表明,PS-DETR模型在保持较高推理效率的同时,在检测精度方面也取得了显著提升。具体而言,该模型的mAP@50指标达到94.35%,较基准RT-DETR-18模型提升了3.97个百分点,同时模型参数量从 19.88×10^6 降低至 13.99×10^6 ,降幅达29.6%。消融试验验证了ELGCA模块和ABFCM模块各自的有效性,对比试验也表明PS-DETR在各项指标上均优于YOLO系列等多个主流检测模型。可视化分析进一步证实,该算法在复杂纹理区域能够有效避免误检和重复检测。

综上所述,本研究成功构建了一种适用于LPBF铺粉异常检测的目标检测模型,其优异的综合性能表明,该方法为实现增材制造过程智能化、高精度质量监测提供了一条有效路径。

参考文献

- [1] Sefene E M. State-of-the-art of selective laser melting process: A comprehensive review[J]. Journal of Manufacturing Systems, 2022, 63: 250–274.
- [2] Lu W H, He W X, Wu J M, et al. A critical review of additive manufacturing technology in rehabilitation medicine via the use of visual knowledge graph[J]. Virtual and Physical Prototyping, 2023, 18(1): e2132265.
- [3] Cai Y H, Xiong J, Chen H, et al. A review of in-situ monitoring and process control system in metal-based laser additive manufacturing[J]. Journal of Manufacturing Systems, 2023, 70: 309–326.
- [4] B A P, Lokesh N, Buradi A, et al. A comprehensive review of emerging additive manufacturing (3D printing technology): Methods, materials, applications, challenges, trends and future potential[J]. Materials Today: Proceedings, 2022, 52: 1309–1313.
- [5] 杨亮, 侯亮, 陈云, 等. 基于深度学习的定向能量沉积熔覆层尺寸测量与预测算法[J]. 航空制造技术, 2025, 68(23/24): 135–143.
- [6] Yang Liang, Hou Liang, Chen Yun, et al. Deep learning-based algorithms for measurement and prediction of cladding layers dimension in directed energy deposition[J]. Aeronautical Manufacturing Technology, 2025, 68(23/24): 135–143.
- [7] Zhang J L, Song B, Wei Q S, et al. A review of selective laser melting of aluminum alloys: Processing, microstructure, property and developing trends[J]. Journal of Materials Science & Technology, 2019, 35(2): 270–284.
- [8] Zhu K P, Fuh J Y H, Lin X. Metal-based additive manufacturing condition monitoring: A review on machine learning based approaches[J]. IEEE, 2022, 27(5): 2495–2510.
- [9] 叶冬森. 选择性激光熔化过程的状态监测方法研究[D]. 合肥: 中国科学技术大学, 2018.
- [10] Ye Dongsun. Study of in-situ monitoring methods in selective laser melting process[D]. Hefei: University of Science and Technology of China, 2018.
- [11] 骆婉婷, 王迪, 卫洋, 等. 激光选区熔化成形6061铝合金组织与热学性能研究[J]. 航空制造技术, 2025, 68(23/24): 122–134.
- [12] Luo Wanting, Wang Di, Wei Yang, et al. Investigation on microstructure and thermal properties of 6061 aluminum alloy formed by selective laser melting[J]. Aeronautical Manufacturing Technology, 2025, 68(23/24): 122–134.
- [13] Scime L, Beuth J. Anomaly detection and classification in a laser powder bed additive manufacturing process using a trained computer vision algorithm[J]. Additive Manufacturing, 2018, 19: 114–126.
- [14] Sehhat M H, Mahdianikhotbesara A. Powder spreading in laser-powder bed fusion process[J]. Granular Matter, 2021, 23(4): 89.
- [15] Miao G X, Du W C, Pei Z J, et al. A literature review on powder spreading in additive manufacturing[J]. Additive Manufacturing, 2022, 58: 103029.
- [16] Xiao L, Lu M Y, Huang H. Detection of powder bed defects in selective laser sintering using convolutional neural network[J]. The International Journal of Advanced Manufacturing Technology, 2020, 107(5–6): 2485–2496.
- [17] Chen H, Wei Q S, Zhang Y J, et al. Powder-spreading mechanisms in powder-bed-based additive manufacturing: Experiments and computational modeling[J]. Acta Materialia, 2019, 179: 158–171.
- [18] Haeri S, Wang Y, Ghita O, et al. Discrete element simulation and experimental study of powder spreading process in additive manufacturing[J]. Powder Technology, 2017, 306: 45–54.
- [19] GADE R, MOESLUND T B. Thermal cameras and

applications: a survey[J]. Machine Vision and Applications, 2014, 25(1): 245–262.

[17] Craeghs T, Clijsters S, Yasa E, et al. Online quality control of selective laser melting[C]//Proceedings of the 20th Solid Freeform Fabrication (SFF) Symposium. Austin: University of Texas at Austin, 2011: 212–226.

[18] Zur Jacobsmühlen J, Kleszczynski S, Witt G, et al. Detection of elevated regions in surface images from laser beam melting processes[C]//IECON 2015 — 41st Annual Conference of the IEEE Industrial Electronics Society. Piscataway, NJ: IEEE, 2015: 1270–1275.

[19] Chen Z C, Guo H Q, Yang J, et al. Fast vehicle detection algorithm in traffic scene based on improved SSD[J]. Measurement, 2022, 201: 111655.

[20] Jiang P Y, Ergu D J, Liu F Y, et al. A review of yolo algorithm developments[J]. Procedia Computer Science, 2022, 199: 1066–1073.

[21] Maity M, Banerjee S, Sinha Chaudhuri S. Faster R-CNN and YOLO based vehicle detection: A survey[C]//2021 5th International Conference on Computing Methodologies and Communication (ICCMC). Piscataway, NJ: IEEE, 2021: 1442–1447.

[22] Han K, Wang Y H, Chen H T, et al. A survey on vision transformer[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(1): 87–110.

[23] Carion N, Massa F, Synnaeve G, et al. End-to-end object detection with transformers[C]//Computer Vision — ECCV 2020. Cham: Springer International Publishing, 2020: 213–229.

[24] Zhao Y A, Lü W Y, Xu S L, et al. DETRs beat YOLOs on

real-time object detection[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE, 2024: 16965–16974.

[25] Maconachie T, Leary M, Lozanovski B, et al. SLM lattice structures: Properties, performance, applications and challenges[J]. Materials & Design, 2019, 183: 108137.

[26] Pan C, Han Y F, Lu J P. Design and optimization of lattice structures: A review[J]. Applied Sciences, 2020, 10(18): 6374.

[27] 吴志强, 蒋国璋, 张严, 等. 多参数点阵结构多尺度拓扑优化设计方法[J]. 航空制造技术, 2025, 68(22): 97–104.

Wu Zhiqiang, Jiang Guozhang, Zhang Yan, et al. Multi-scale topological optimization design method for multi-parameter lattice structures[J]. Aeronautical Manufacturing Technology, 2025, 68(22): 97–104.

[28] Bici M, Brischetto S, Campana F, et al. Development of a multifunctional panel for aerospace use through SLM additive manufacturing[J]. Procedia CIRP, 2018, 67: 215–220.

[29] Plocher J, Panesar A. Review on design and structural optimisation in additive manufacturing: Towards next-generation lightweight structures[J]. Materials & Design, 2019, 183: 108164.

[30] Maskery I, Aboulkhair N T, Aremu A O, et al. Compressive failure modes and energy absorption in additively manufactured double gyroid lattices[J]. Additive Manufacturing, 2017, 16: 24–29.

[31] Noman M, Fiaz M, Cholakkal H, et al. ELGC-net: Efficient local-global context aggregation for remote sensing change detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 1–11.

(责编 阳光)