

基于同轴视觉传感的激光熔丝直接能量沉积过程稳定性监测



蔡玉华¹,程新玉¹,陈勇²,熊俊¹,陈辉¹

1.西南交通大学,四川成都 610031

2.中航工业成都飞机工业(集团)有限责任公司,四川成都 610092

摘要:激光熔丝直接能量沉积(DED)技术兼顾成形精度和沉积效率,在航空航天及国防领域复杂金属构件的快速制造方面展现出广阔的应用前景。然而,激光熔丝DED过程稳定性监测手段不成熟及成形质量实时控制困难等问题严重限制了该方法的自动化程度和成形构件的可靠性。本文提出了一种基于同轴视觉传感和深度学习的激光束与金属丝交点到沉积层表面距离(IPTD)表征方法,以实现激光熔丝DED沉积过程稳定性的实时检测。通过IPTD分类任务研究了三种不同卷积神经网络(CNN)模型从熔池图像中提取IPTD特征的能力。基于具有最佳分类性能的CNN模型设计了IPTD回归模型,研究并讨论了IPTD回归模型的拟合性能。与其他CNN模型相比,ResNet18模型具有最高的训练收敛速度和最佳的性能,分类精度达到0.996。IPTD回归模型在验证数据集上的平均绝对误差小于0.318mm。IPTD回归模型处理单帧熔池图像的耗时在4ms以内。研究结果表明,本文提出的沉积高度稳定性检测方法具有较高的检测精度,为复杂金属构件激光熔丝DED的高度稳定性控制提供了理论及技术基础。

关键词:激光直接能量沉积;增材制造;在线监测;深度学习;成形质量

中图分类号:TG439.4

文献标识码:A

DOI: 10.19452/j.issn1007-5453.2025.05.008

航空装备正向大型化、一体化的方向迅速发展,致使其关键金属构件尺寸日益增大、结构日益复杂,金属增材制造是突破传统加工方式存在的材料利用率低、成本高、制造周期长等难题的重要途径。其中,激光熔丝直接能量沉积(DED)以激光束为热源,基于三维模型逐层熔化并堆积金属材料直接实现构件的制造^[1],兼顾制造成本及效率,被认为是航空装备关键金属构件制备的理想增材制造技术之一。

激光熔丝DED涉及连续多层沉积过程,在先前层沉积完成后,沉积头将被提升到预定的高度进行下一层沉积。然而,先前层的成形质量、工艺参数波动及热累积效应均会影响沉积层高度的稳定性,导致实际沉积层高度偏离预设值^[2]。沉积层高度偏差会导致激光束和金属丝尖端的交点到前一沉积层表面的距离(IPTD)显著波动。激光熔丝

DED过程中由沉积高度偏差引起的沉积层高度不稳定问题如图1所示。当IPTD为负时,激光束和金属丝之间的交点位于沉积层表面下方,金属丝尖端与沉积层表面发生接触。当IPTD为负且过低时,金属丝不能被激光束熔化,而是与沉积层表面碰撞导致沉积过程中止^[3]。当IPTD为正时,激光束和金属丝之间的交点位于前一沉积层表面上方,金属丝尖端和熔池之间的液桥被拉长。当IPTD为正且过高时,熔融金属的转移模式将从液桥过渡转变为液滴过渡,导致材料转移过程稳定性降低。因此,开发原位监测和闭环控制系统来确保沉积高度稳定性,对提高激光熔丝DED的自动化水平具有重要意义。

目前,激光DED过程传感使用的信号主要分为声信号、光谱信号、热信号和视觉信号^[4]。与其他传感方式相比,视觉传感的设备成本低、信息丰富,是获取沉积层形态

收稿日期:2024-09-15;退修日期:2024-12-16;录用日期:2025-02-20

基金项目:国家自然科学基金(62173280,51975491);航空科学基金(2023Z049109001);四川省科技计划(2023NSFSC1956,2024JDRC0022);中央高校基本科研业务费(2682023ZTPY023)

引用格式: Cai Yuhua, Cheng Xinyu, Chen Yong, et al. Monitoring of deposition process stability in wire-laser direct energy deposition based on coaxial visual sensing[J]. Aeronautical Science & Technology, 2025, 36(5): 67-74. 蔡玉华,程新玉,陈勇,等. 基于同轴视觉传感的激光熔丝直接能量沉积过程稳定性监测[J]. 航空科学技术, 2025, 36(5): 67-74.

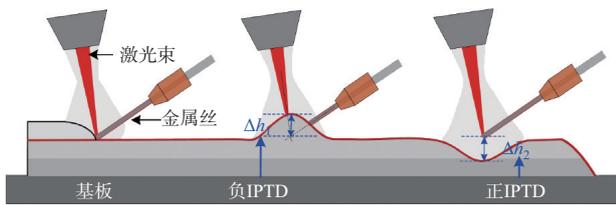


图1 高度偏差引起的沉积稳定性问题示意图

Fig.1 Schematic diagram of deposition stability issues induced by deposition height deviation

特征的有效方法,如成形缺陷^[5]、沉积宽度^[6]和沉积高度^[7]等。Shi Tuo等^[8]开发了一个基于电荷耦合器件(CCD)的传感系统,实时监测激光熔丝DED中的沉积高度,并通过调节激光头的移动速度来提高沉积层的高度稳定性。然而,目前用于监测沉积高度稳定性的视觉传感器通常固定在沉积头的对面,这意味着视觉传感器与具有复杂几何结构的金属构件之间存在空间干涉,导致激光DED系统的自由度降低。相比之下,与激光束同轴安装的视觉传感器可以避免上述问题,使得视觉传感机构更加紧凑并改善激光DED系统的自由度。Heralic等^[9]采用同轴CCD相机实时监测激光熔丝DED的熔池宽度,并开发了一个PI控制器实时调节激光功率以改善沉积层的宽度稳定性。Tang Zijun等^[10]采用同轴CCD相机实时监测激光熔粉DED过程中的熔池图像,研究了不同工艺条件下熔池的几何尺寸特征及形貌演化规律。目前,同轴视觉传感在激光DED中主要用于熔池尺寸及缺陷状态的监测,为工艺优化和质量控制提供依据。然而,从熔池正面图像中直接获取沉积高度特征相关的研究还未见报道。通常,传统的图像处理算法难以从同轴熔池图像中直接提取沉积高度特征。因此,探索一种基于同轴熔池图像的激光熔丝DED沉积稳定性监测方法至关重要。

作为一种不依赖物理建模的数据驱动方法,深度学习被认为是提取复杂数据深层次特征最有效的手段之一^[11]。其中,卷积神经网络(CNN)可以自动从原始数据中学习到有特征表达,在图像处理方面表现出显著的优势^[12-13]。目前,CNN已被广泛应用于增材制造及焊接过程的状态识别及质量诊断^[14-15]。Zhang Bin等^[16]将熔池图像输入CNN模型来直接预测激光DED过程中气孔缺陷的发生,预测准确率达到91.2%。Wang Mengjie等^[17]采用安装在沉积头对面的高速相机采集不同工艺条件下的激光熔丝DED熔池图像。然后,获得的熔池图像被用来训练CNN模型,并基于训练的CNN模型对沉积过程稳定性进行分类以辅助调整工艺参数。Jamnikar等^[18]设计了一个CNN模型来建立熔

池图像与激光熔丝DED工艺参数之间的映射,并在沉积过程中利用所建立的CNN模型预测工艺参数状态。

本文通过构建CNN模型来直接表征激光熔丝DED过程的IPTD值,以实现基于同轴视觉传感的沉积过程稳定性监测。为了验证该方法的有效性,通过执行分类任务研究了不同CNN模型从正面熔池图像中提取IPTD特征的能力,并根据不同CNN模型分类精度来确定最优的IPTD分类模型架构。基于训练的最优IPTD分类模型架构设计了IPTD回归模型,并通过验证试验对其性能进行了分析。

1 试验设置

图2所示为激光熔丝DED系统示意图。该系统主要包括一台ABB-IRB4600机器人、一台波长为1080nm的IPG YLS-4000激光器、一台WF-007A送丝机、一个与激光束同轴安装的CCD相机和一台计算机。金属丝送进模式为前送丝,金属丝与基板表面的夹角为35°,激光束与基板表面的夹角为82°。激光束在基板表面上的光斑直径为1.0mm。同轴保护气体为纯氩,流量为15L/min。CCD相机的采样频率为25fps,拍摄的原始熔池图像像素尺寸为1920×1024。为了提高熔池图像的拍摄清晰度,采用中心波长为650nm的窄带滤光片对熔池图像进行滤光。

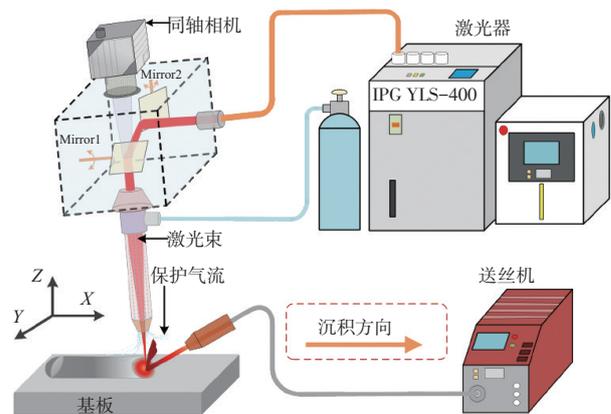


图2 激光熔丝直接能量沉积系统示意图

Fig.2 Schematic diagram of wire-laser DED system

试验基板为Q235低碳钢板,尺寸为200mm×100mm×6mm。采用直径为1.2mm的ER70S-6焊丝作为沉积材料。基板通过夹具固定在操作平台上,沉积头的定位和移动由ABB-IRB4600机器人操纵。沉积速度为2.5mm/s,沉积长度为120mm。工艺参数见表1。通过执行试验组A来获取IPTD分类任务中使用的熔池图像。为了增加数据的复杂性,设计了两种工艺参数组合,每个工艺参数组合对应6种

不同的 IPTD 条件, 总共进行了 12 组试验。从每个试验的熔池图像序列中提取 1000 帧图像。由于熔池形态的高度不稳定性, 不考虑在沉积开始及停止阶段所获得的图像。通过 IPTD 分类试验来比较不同 CNN 模型的熔池图像特征提取能力, 具有最佳分类性能的 CNN 模型将用于构建 IPTD 回归模型。通过执行试验组 B 来获取 IPTD 回归任务中使用的熔池图像, 其中激光功率设置了 5 个水平, IPTD 从 -2mm 线性增加到 3mm。图 3 所示为 IPTD 线性变化示意图, 随着沉积头沿着红色箭头所示的路径移动, IPTD 逐渐增加。通过执行试验组 C 来验证训练的 IPTD 回归模型的泛化性能。

表 1 试验设计
Table 1 Experimental design

组别	编号	送丝速度/(cm/min)	激光功率/kW	IPTD/mm
A	1	140	2.7	-2, -1, 0, 1, 2, 3
	2	160		-2, -1, 0, 1, 2, 3
B	3	140	2.7	-2~3
	4	150		-2~3
	5	160		-2~3
	6	170		-2~3
	7	180		-2~3
C	8	160	2.5	-2~3

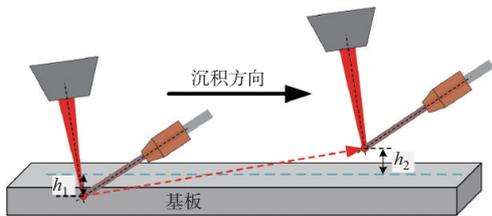


图 3 IPTD 线性变化试验设置示意图

Fig.3 Schematic diagram of experimental setup for linear variation of IPTD

CNN 通过连续的卷积和池化操作, 从图像信息中快速提取与目标相关的特征矢量。与传统的机器学习方法相比, 它避免了复杂的数据预处理和特征提取环节^[19-20]。通常, 一个 CNN 模型由输入层、卷积层、激活函数、池化层、全连接层和输出层构成, 并且通过优化这些结构可以有效改善模型性能。

近年来, 深度学习领域涌现出许多具有优异图像识别能力的 CNN 模型。其中, AlexNet 作为一个开创性模型, 由 5 个卷积层和 3 个全连接层构成, 其引入的修正线性单元 (ReLU) 激活函数、Dropout 技术及数据增广方法显著提高

了模型的泛化能力, 证明了深度学习在大规模图像识别任务中的巨大潜力^[21]。Vgg16 网络由尺寸为 3×3 的小卷积核堆叠而成 (深度为 16 层), 其在保证特征提取能力的同时减少参数量, 具有良好的扩展性和对图像细节的捕捉能力^[22]。此外, Vgg16 证明了增加网络深度可以有效地提高模型性能。然而, 网络深度的过度增加会导致模型退化, 影响模型精度。He Kaiming 等^[23]创造性地提出了一种残差连接方法, 即允许某一层的输出直接跳过一个或多个层直接连接到后续层的输入, 成功消除了由网络深度增加引起的模型退化问题, 并基于该方法开发了 ResNet18 模型。ResNet18 模型由输入层、卷积层、池化层及 4 个包含特定卷积和残差连接的残差块构成, 其架构如图 4 所示。上述三种 CNN 模型代表了深度学习发展历程中不同阶段的典型架构, 各自具有独特的优势, 通过研究这些模型的 IPTD 特征提取能力, 可以全面地探索不同深度学习模型架构在增材制造领域的应用潜力和性能表现。

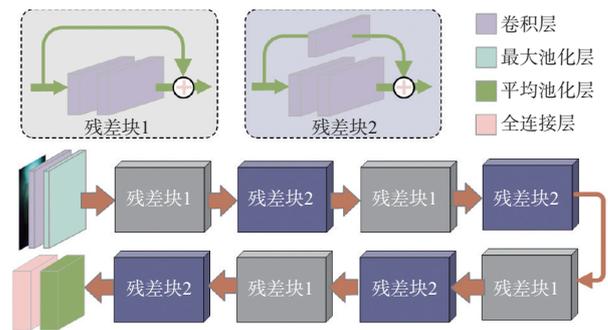


图 4 ResNet18 模型的架构

Fig.4 Architecture of the ResNet18 model

对于分类 CNN 模型, 最后一个全连接层将提取的图像特征矢量映射到类别概率, 将输入的图像归类为概率最高的类别。相比之下, 回归 CNN 模型的最后一个全连接层直接输出 IPTD 预测值。在建立回归 CNN 模型时, 采用迁移学习来保留分类模型学习到的图像特征, 可以有效地提高回归模型的训练速度和性能^[24]。

在 CNN 模型训练过程中, 将基于损失函数的计算值来调整权重和偏差值。损失值越低, 模型精度越高。分类 CNN 模型采用交叉熵损失函数来计算两个概率分布之间的差异, 它可以被描述为使用概率分布 $q(x)$ 来表示概率分布 $p(x)$ 的难度。交叉熵损失函数表示为

$$H(p, q) = \sum_{i=1}^n p(x_i) \log \frac{1}{q(x_i)} \quad (1)$$

回归 CNN 模型使用均方误差 (MSE) 损失函数来评估

预测值和实际值之间的偏差程度。MSE函数定义为

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (\tilde{y}_i - \hat{y}_i)^2 \quad (2)$$

式中, n 为样本的索引, \tilde{y}_i 为估计值, \hat{y}_i 为实际值。

CNN数据集的创建主要包括图像预处理和数据标记两个步骤。首先从捕获的原始熔池图像中裁剪出像素尺寸为 1200×700 的感兴趣区域(ROI)。然后,将这些ROI图像的像素尺寸调整为 180×105 。对于分类任务,采用沉积试验中对应的IPTD值进行标签。分类数据集中的熔池图像为12000帧,其中训练集和测试集分别为9600帧及2400帧。在回归任务中,沉积过程的IPTD值由 -2mm 线性增加至 3mm ,使用线性插值法来计算熔池图像序列中每一帧图像所对应的IPTD值,并进行标签操作。将从这些试验中获得的熔池图像随机划分为训练集和测试集,以验证IPTD回归模型的性能。训练集和测试集包含的熔池图像数量分别为11600帧及3400帧。为了增加数据集体积,对回归试验中获得的熔池图像进行了两种数据增广操作,包括对比度随机调整及亮度随机调整。图像亮度和对比度的随机调整系数范围为 $0.75 \sim 1.25$ 。

2 试验结果及讨论

2.1 IPTD分类结果

激光熔丝DED过程中的IPTD直接影响熔融金属丝的过渡模式和激光在沉积层表面的能量分布。保持适当的IPTD对激光熔丝DED沉积稳定性至关重要。图5为IPTD值线性变化时的沉积层外观和熔池行为,IPTD从 -2mm 连续线性增加到 3mm 。沿着沉积方向,沉积层宽度呈增加的趋势。当 $\text{IPTD} < 2\text{mm}$ 时,熔融金属丝表现出稳定的液桥过渡模式,沉积层成形良好,没有明显的缺陷。当 $\text{IPTD} > 2\text{mm}$ 时,过渡模式转变为液滴过渡,沉积层呈现波浪条纹状外观。随着IPTD的增加,羽辉的稳定性显著降低。

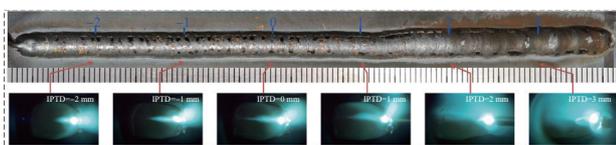


图5 IPTD线性变化下沉积层外观和熔池行为

Fig.5 Deposition layer appearance and molten pool behavior under IPTD linear variation

CNN模型的架构与其目标识别性能直接相关。本文采用三个CNN架构来构建IPTD分类模型,包括Vgg16、ResNet18和AlexNet,以确定最优的分类CNN模型架构。

IPTD分类模型结构如图6所示。模型训练过程持续100个周期,批量大小为30。

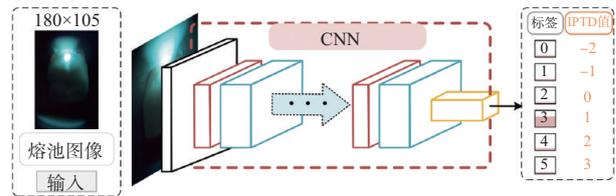


图6 IPTD分类模型结构

Fig.6 Structure of the IPTD classification model

图7(a)为不同CNN模型在训练过程中的精度演变曲线。三个模型在20个训练周期内迅速提高,在40个训练周期后逐渐趋于稳定。其中,ResNet18模型的收敛速度最快,在第32个训练周期达到最佳分类精度1。如图7(b)所示,这些分类模型在测试数据集上的分类精度出现明显的波动,特别是Vgg16和AlexNet模型。ResNet18模型在测试数据集上的分类精度也显著优于其他CNN分类模型,达到0.996。总体而言,ResNet18模型在建立熔池图像与IPTD的映射方面表现出更好的性能。因此,选择ResNet18为基础模型来构建IPTD回归模型。

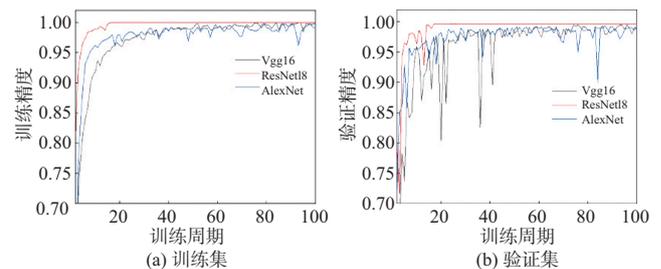


图7 不同CNN模型在训练和验证过程中的精度演化曲线

Fig.7 Accuracy evolution curves of different CNN models during training and validating

图8为ResNet18分类模型在测试数据集上的混淆矩阵。ResNet18分类模型对具有6种不同IPTD的熔池图像进行了区分。在2400张熔池图像中,只有10个样本被识别错误。通常,CNN模型出色的分类精度与显著的视觉特征直接相关。激光熔丝DED中IPTD变化会显著影响激光能量分布,导致熔池和羽辉的形态特征发生显著变化。CNN模型通过学习这些特征以准确地对熔池图像进行分类。

图9所示为ResNet18分类模型的不同卷积层提取的特征图。特征图中的高度激活区域代表了ResNet18分类模型卷积层所捕获的视觉模态。在第一层中,激活区域保留了原始图像中的大部分信息,包括熔池边缘和羽辉轮廓。随着卷积层深度的增加,特征图尺寸减小,抽象级别增加。

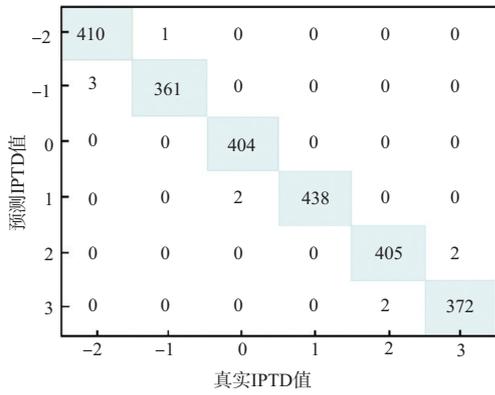


图8 分类结果的混淆矩阵

Fig.8 Confusion matrix of the classification result

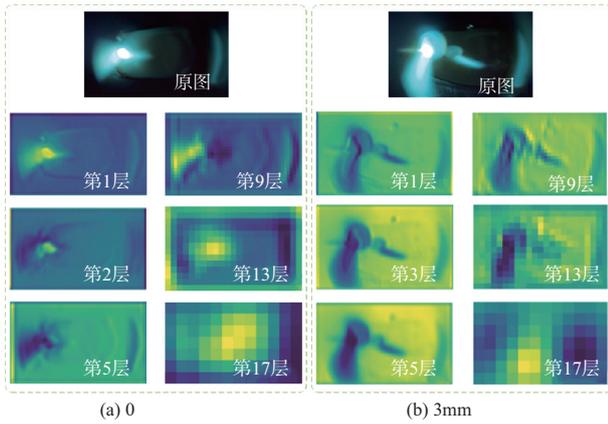


图9 不同IPTD条件下熔池图像的特征图

Fig.9 Feature maps of molten pool images with different IPTD values

ResNet18分类模型提取到的与熔池和羽辉形态相关的高层次语义信息是图像识别的基础。随着卷积层深度进一步增加,卷积核能提取更高级的抽象语义特征,以表征熔池图像中更复杂的模态和特征。具有不同IPTD状态的特征图中的熔池和羽辉形态特征存在显著差异,为构建高性能的IPTD回归模型奠定了坚实的基础。

2.2 IPTD回归结果

根据第2.1节中的试验结果,本节基于ResNet18来构建IPTD回归模型。图10为IPTD回归模型架构。与IPTD分类模型相比,IPTD回归模型的输出由6个特征向量变为IPTD回归值。训练过程持续400个周期,批量大小为30。

图11为IPTD回归模型在验证集上的预测结果。这些预测的散射点分布在真实的IPTD线周围。相关系数 R^2 值为0.981。图11(b)为IPTD回归模型预测的IPTD值的绝对误差(AE),AE最大值为0.96mm,平均绝对误差(MAE)平均值仅为0.137mm。AE<0.3mm的样本数量占总样本数的

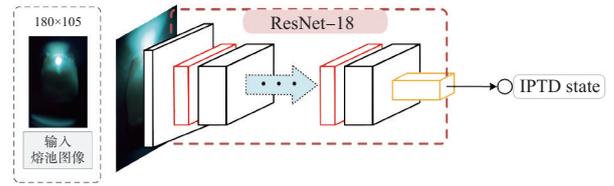
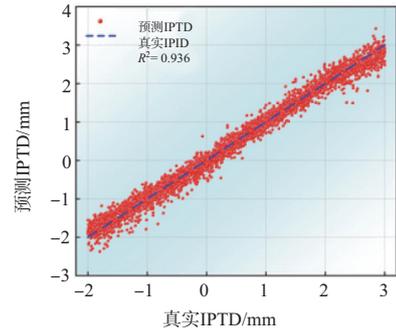
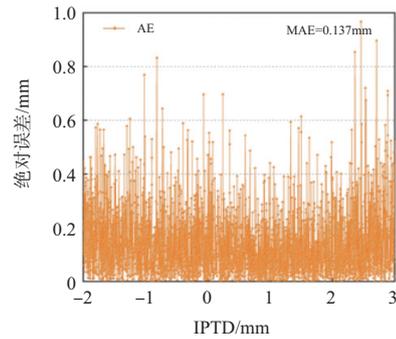


图10 IPTD回归模型结构

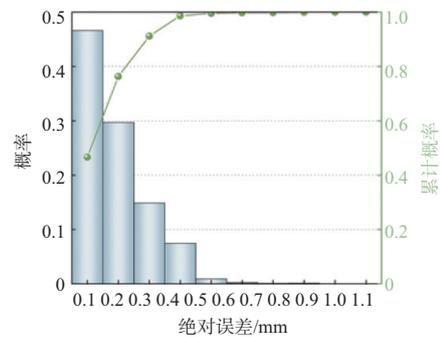
Fig.10 Structure of the IPTD regression model



(a) IPTD预测值



(b) IPTD预测值的绝对误差



(c) 绝对误差的概率分布

图11 IPTD回归模型在测试数据集上的预测结果

Fig.11 Estimated results of the IPTD regression model on the testing dataset

91.3%。IPTD回归模型的单帧图像处理时间在4ms以内。IPTD回归模型所取得的预测性能满足工程应用需求。

此外,本文设计了另一组试验来评估IPTD回归模型的泛化能力。试验细节见表1中试验组C,激光功率由2.7kW

降低为2.5kW。熔池的热输入随激光功率下降而降低,导致熔池的视觉特征发生显著变化,对IPTD回归模型的泛化能力提出巨大挑战。本文采集的熔池图像数量为1000帧。IPTD回归模型的预测结果如图12所示,IPTD实际值与预测值之间的MAE为0.318mm,AE<0.5mm的样本数量占总样本数量的80.4%。相关系数 R^2 为0.936。结果表明,在工艺参数变化情况下,IPTD回归模型仍然具有良好的预测精度,表明其具有优异的泛化性能,可应用于更复杂制造环境中激光熔丝DED过程的稳定性监测。

总体而言,新设计的基于深度学习和同轴视觉传感的监测方法实现了从熔池正面熔池图像中直接获取沉积高度

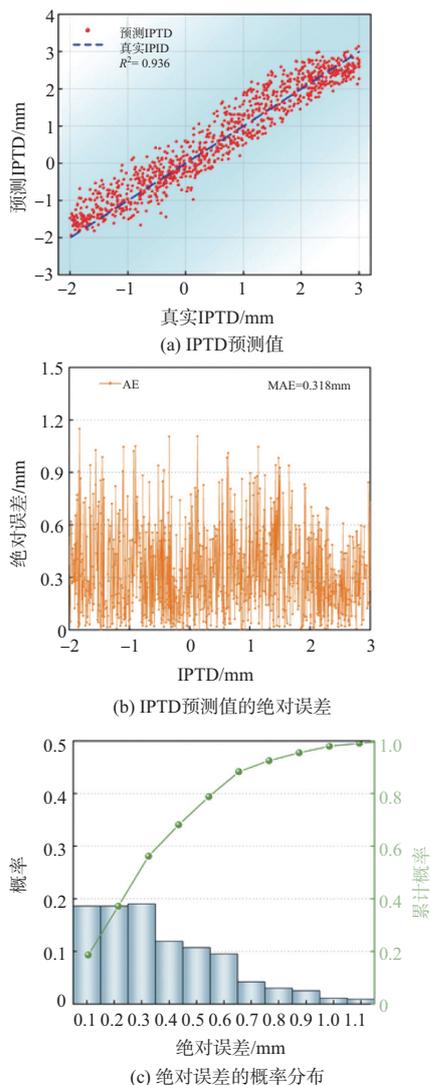


图12 IPTD回归模型在验证数据集上的预测结果

Fig.12 Estimated results of the IPTD regression model on the validating dataset

特征的愿景,具有一定的应用前景。在未来的研究中,所提出方法在实际工业环境应用中的鲁棒性及监测精度需要进一步提高,可以通过建立同时考虑工艺参数及熔池图像特征的多模态深度学习模型来改善该方法的鲁棒性,此外,可以通过优化同轴视觉传感质量来降低激光诱导羽辉对熔池图像特征的干扰,以及增加熔池图像的数量和代表性,来提高数据集的质量。

3 结论

保证稳定的沉积过程对于实现金属构件激光熔丝DED的高可靠、高自动化制造至关重要。本文提出基于同轴视觉传感和深度学习模型来监测激光熔丝DED过程稳定性。研究了IPTD对熔池行为和沉积层成形质量的影响。基于不同的CNN模型架构执行IPTD分类任务,研究了不同模型架构的熔池图像特征提取性能差异。基于IPTD分类模型架构设计了IPTD回归模型。通过回归试验研究了IPTD回归模型的性能。通过研究,得出以下结论:

(1)随着IPTD的增加,熔融金属丝的过渡模型逐渐从液桥过渡转变为液滴过渡,熔池形态特征呈现出强烈的波动,沉积过程稳定性及沉积层成形质量显著下降。

(2)与其他CNN模型相比,ResNet18分类模型在训练过程中具有最高的收敛速度,在20个训练周期内即获得最佳分类精度,达到0.996。基于IPTD分类模型构建了IPTD回归模型,并通过迁移学习来加速IPTD回归模型的训练过程。

(3)采用不同工艺条件下采集的熔池图像对IPTD回归模型进行训练和测试。IPTD回归模型在测试集上的 R^2 达到0.983,IPTD实际值与预测值之间的MAE为0.137mm。利用在不同激光功率条件下获取的熔池图像来测试IPTD回归模型的泛化性能,MAE为0.318mm,AE<0.5mm的样本数量占总样本数量的80.4%。结果表明,本文所提出的激光熔丝DED过程稳定性检测方法具有良好的精度和泛化性能。

AST

参考文献

[1] 王华明. 金属增材制造技术及其对重大装备制造业的影响[J]. 中国工业和信息化, 2019(12): 54-56.

Wang Huaming. Metal additive manufacturing technology and its impact on major equipment manufacturing industry[J]. China Industry and Information Technology, 2019(12): 54-56. (in Chinese)

- [2] 张李超, 胡祺, 王森林, 等. 金属增材制造数据处理与工艺规划研究综述[J]. 航空制造技术, 2021, 64(3): 22-31.
Zhang Lichao, Hu Qi, Wang Senlin, et al. A Review of data processing and process planning in metal additive manufacturing[J]. Aeronautical Manufacturing Technology, 2021, 64 (3): 22-31. (in Chinese)
- [3] Li Bin, Zhang Yi, Lei Yuchao, et al. A single-sensor multi-scale quality monitoring methodology for laser-directed energy deposition: Example with height instability and porosity monitoring in additive manufacturing of ceramic thin-walled parts[J]. Additive Manufacturing, 2023, 79: 103923.
- [4] 蔡玉华, 熊俊, 陈辉. 激光增材制造过程监测与控制研究进展及展望[J]. 电焊机, 2023, 52(9): 1-13.
Cai Yuhua, Xiong Jun, Chen Hui. Research progress and prospects of monitoring and control in laser additive manufacturing process[J]. Electric Welding Machine, 2023, 52 (9): 1-13. (in Chinese)
- [5] Chen Lequn, Bi Guijun, Yao Xiling, et al. Multisensor fusion-based digital twin for localized quality prediction in robotic laser-directed energy deposition[J]. Robotics and Computer-Integrated Manufacturing, 2023, 84: 102581.
- [6] Jeon I, Yang L, Ryu K, et al. Online melt pool depth estimation during directed energy deposition using coaxial infrared camera, laser line scanner, and artificial neural network[J]. Additive Manufacturing, 2021, 47: 102295.
- [7] Xiong Jun, Pi Yupeng, Chen Hui. Deposition height detection and feature point extraction in robotic GTA-based additive manufacturing using passive vision sensing[J]. Robotics and Computer-Integrated Manufacturing, 2019, 59: 326-334.
- [8] Shi Tuo, Lu Bingheng, Shen Ting, et al. Closed-loop control of variable width deposition in laser metal deposition[J]. The International Journal of Advanced Manufacturing Technology, 2018, 97: 4167-4178.
- [9] Heralic A, Christiansson A K, Ottosson M, et al. Increased stability in laser metal wire deposition through feedback from optical measurements[J]. Optics and Lasers in Engineering, 2010, 48: 478-485.
- [10] Tang Zijun, Liu Weiwei, Zhu Lina, et al. Investigation on coaxial visual characteristics of molten pool in laser-based directed energy deposition of AISI 316L steel[J]. Journal of Materials Processing Technology, 2021, 290: 116996.
- [11] Qin Jian, Wang Yipeng, Ding Jialuo, et al. Optimal droplet transfer mode maintenance for wire + arc additive manufacturing (WAAM) based on deep learning[J]. Journal of Intelligent Manufacturing, 2022, 33: 2179-2191.
- [12] Pandiyan V, Cui D, Le-Quang T, et al. In situ quality monitoring in direct energy deposition process using co-axial process zone imaging and deep contrastive learning[J]. Journal of Manufacturing Processes, 2022, 81: 1064-1075.
- [13] 韩仁坤, 杜焦喜, 刘子扬, 等. 基于深度神经网络的含运动边界非定常流场预测方法研究[J]. 航空科学技术, 2023, 34 (12): 37-42.
Han Renkun, Du Jiaoxi, Liu Ziyang, et al. Research on the prediction method of unsteady flow field with motion boundaries based on deep neural network[J]. Aeronautical Science & Technology, 2023, 34 (12): 37-42. (in Chinese)
- [14] Mi Jiqian, Zhang Yikai, Li Hui, et al. In-situ monitoring laser based directed energy deposition process with deep convolutional neural network[J]. Journal of Intelligent Manufacturing, 2023, 34: 683-693.
- [15] 周旷, 姜名. 基于迁移学习的小样本目标识别研究进展与展望[J]. 航空科学技术, 2023, 34(2): 1-9.
Zhou Kuang, Jiang Ming. Research progress and prospects of small sample object recognition based on transfer learning[J]. Aeronautical Science & Technology, 2023, 34 (2): 1-9. (in Chinese)
- [16] Zhang Bin, Liu Shunyu, Shin Y. In-Process monitoring of porosity during laser additive manufacturing process[J]. Additive Manufacturing, 2019, 28: 497-505.
- [17] Wang Mengjie, Kashaev N. On the maintenance of processing stability and consistency in laser-directed energy deposition via machine learning[J]. Journal of Manufacturing Systems, 2024, 73: 126-142.
- [18] Jamnikar N, Liu Sen, Brice C. Comprehensive molten pool condition-process relations modeling using CNN for wire-feed laser additive manufacturing[J]. Journal of Manufacturing Processes, 2023, 98: 42-53.
- [19] Guo Qiang, Yang Zi, Xu Jinting, et al. Progress, challenges and trends on vision sensing technologies in automatic/intelligent robotic welding: State-of-the-art review[J]. Robotics and

- Computer-Integrated Manufacturing, 2024, 89: 102767.
- [20] 张堃,李珂,邹杰,等. 基于深度迁移强化学习的无人机投放自主引导机动控制算法[J]. 航空科学技术, 2023, 34(11): 103-110.
- Zhang Kun, Li Ke, Zou Jie, et al. Autonomous guidance maneuver control algorithm for unmanned aerial vehicle deployment based on deep transfer reinforcement learning[J]. Aeronautical Science & Technology, 2023, 34 (11): 103-110. (in Chinese)
- [21] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2015, 60 (6): 84-90.
- [22] Karen S, Andrew Z. Very deep convolutional networks for large-scale image recognition[J]. arXiv:1409.1556, 2015.
- [23] He Kaiming, Zhang Xianyu, Su Jian. Deep residual learning for image recognition[J]. arXiv:1512.03385, 2015.
- [24] Li Wenhao, Zhang Haiou, Wang Guilan, et al. Deep learning based online metallic surface defect detection method for wire and arc additive manufacturing[J]. Robotics and Computer-Integrated Manufacturing, 2023, 80: 102470.

Monitoring of Deposition Process Stability in Wire-Laser Direct Energy Deposition Based on Coaxial Visual Sensing

Cai Yuhua¹, Cheng Xinyu¹, Chen Yong², Xiong Jun¹, Chen Hui¹

1. Southwest Jiaotong University, Chengdu 610031, China

2. AVIC Chengdu Aircraft Industrial (Group) Co., Ltd., Chengdu 610092, China

Abstract: The wire-laser directed energy deposition (DED) technique can balance forming accuracy and deposition efficiency, and has shown broad application prospects in the rapid manufacturing of complex components in the aerospace and defense fields. However, the immaturity of monitoring methods for the deposition process stability and the difficulty in real-time control of forming qualities in wire-laser DED seriously limit the manufacturing process's automation level and component reliability. This paper proposes a monitoring method based on coaxial visual sensing and deep learning to characterize the intersection point of the laser beam and the wire to the top layer distance (IPTD) in wire-laser DED for achieving real-time detection of the deposition process stability. The abilities of three different convolutional neural network models to extract IPTD features from molten pool images are studied by performing classification tasks. An IPTD regression model is designed based on the optimal CNN model determined by classification experiments. The fitting performance of the IPTD regression model is studied and discussed. Compared with other models, the ResNet18 model has the highest training convergence speed and an optimal classification accuracy of 0.996. The prediction results' average absolute error of the IPTD regression model on the testing dataset is less than 0.318mm. The prediction time of the IPTD regression model for a molten pool image is within 4ms. The research results indicate that the proposed detection method of deposition process stability in wire-laser DED has high detection accuracy, providing a theoretical and technical basis for the height stability control in wire-laser DED of complex metal components.

Key Words: laser DED; additive manufacturing; online monitoring; deep learning; forming quality

Received: 2024-09-15; **Revised:** 2024-12-16; **Accepted:** 2025-02-20

Foundation item: National Natural Science Foundation of China (62173280, 51975491); Aeronautical Science Foundation of china (2023Z049109001); Sichuan Science and Technology Program (2023NSFSC1956, 2024JDRC0022); Fundamental Research Funds for the Central Universities (2682023ZTPY023)