

激光熔化沉积过程缺陷识别方法

刘伟崑^{1,2}, 刘炳君¹, 刘焕强¹, 刘泽远¹

(1. 大连理工大学 机械工程学院, 辽宁 大连 116024;

2. 大连理工大学 高性能精密制造全国重点实验室, 辽宁 大连 116024)

摘要: 激光熔化沉积加工过程中的缺陷萌生是制约激光熔化沉积技术发展的关键性问题. 实现对缺陷的精确自动识别是提高激光熔化沉积技术应用水平的重要途径. 提出了熔池瞬态特征提取算法, 分析了熔池瞬态特征对沉积层熔合不良缺陷的影响关系, 建立了熔池瞬态特征数据集. 对主流识别算法进行了模型训练测试, 获取了相对最优模型 ResNet 34. 为解决 ResNet 34 训练损失拟合效果差、计算速度慢的问题, 结合传统卷积网络和 LSTM(long short-term memory)网络, 建立了训练和测试精度高且计算速度快的 LRCN 64 模型, 测试准确率达 95.8%, 实现了对熔合不良缺陷的识别, 为实现沉积件在线无损检测提供了技术支撑.

关键词: 激光熔化沉积; 熔池瞬态特征; 熔合不良; 长期循环卷积神经网络(LRCN); 残差神经网络(ResNet)
中图分类号: TU 621 **文献标志码:** A **文章编号:** 1005-3026(2024)08-1150-09

Defect Identification Method for Laser Melting Deposition Process

LIU Wei-wei^{1,2}, LIU Bing-jun¹, LIU Huan-qiang¹, LIU Ze-yuan¹

(1. School of Mechanical Engineering, Dalian University of Technology, Dalian 116024, China; 2. State Key Laboratory of High-Performance Precision Manufacturing, Dalian University of Technology, Dalian 116024, China. Corresponding author: LIU Wei-wei, E-mail: liuww@dlut.edu.cn)

Abstract: Defects in laser melting deposition are key problems restricting its development. Achieving precise automatic identification of defects is a crucial approach to enhance the application level of laser melting deposition technology. A novel algorithm for extracting the melt pool's transient characteristics was presented, and the relationship between transient characteristics and lack of fusion defects of the deposition layers was found. Moreover, a dataset of the melt pool's transient characteristics was established. The mainstream recognition algorithms were trained and tested, leading to the identification of the most effective model, ResNet 34. In order to solve the poor fitting training loss effect and slow calculating speed of ResNet 34, a hybrid LRCN 64 model was proposed combining the traditional convolutional networks and LSTM(long short-term memory) networks. It exhibited remarkable accuracy and significant calculating speed. The testing accuracy of the LRCN 64 model reaches 95.8%, thereby realizing the identification of lack of fusion defects, which provides valuable technical support to facilitate online non-destructive testing of deposited parts.

Key words: laser melting deposition; molten pool transient characteristics; lack of fusion; long-term recurrent convolutional neural network (LRCN); residual neural network (ResNet)

在机械工程领域,以高功率激光为热源,金属粉末(尺寸小于1 mm的金属颗粒群)和丝材为原料,通过CAD模型或者编程控制激光头,直接形成目标零件的激光熔化沉积(laser melting

deposition, LMD)技术^[1]应用广泛.在激光熔化沉积加工中,热传递效应是影响沉积层加工质量的关键因素,由于高能激光热源具有较高的能量密度,加工过程具有极高的加热、冷却速率,温度

梯度导致沉积层的内部微观组织出现多种缺陷^[2]。

激光熔化沉积加工中,常见的沉积层缺陷包括:熔合不良^[3]、气孔^[4]、裂纹等。气孔缺陷^[4]主要分为锁孔、层内气孔及层间气孔,其中,由于沉积加工采用的能量密度不足,使沉积粉末未能完全熔化而产生层间气孔的现象,被称作熔合不良(lack of fusion)缺陷,其主要集中在薄壁件底部的初始加工层之间^[5]。

Guo 等^[5]采用透射电镜、背散射电子衍射、扫描电镜、金相显微镜、激光共聚焦显微镜和宏观立体显微镜,研究了激光能量区密度(energy area density, EAD)对熔合不良缺陷和裂纹形成机理的影响,发现在不同能量密度下,熔池的熔化状态不同,进而导致了在低能量密度条件下,熔合不良缺陷的产生。目前针对熔合不良缺陷,大多数研究多集中在其形成机制及抑制、消除方法^[6]。传统观念认为,可通过提高热输入密度改变工艺参数组合水平,减少、抑制熔合不良缺陷的产生,进而获得具有致密内部组织的沉积层。然而研究者发现,熔合不良缺陷的出现,会导致双相微观结构的出现,进而导致熔合不良缺陷周围出现低纵横比的 α 晶粒,这种结构会在保证沉积层强度的基础上,极大提高塑性^[7]。在此基础上,Bustillos 等^[8]利用热等静压(hot isostatic pressing, HIP)处理修复了熔合不良缺陷所导致的表面能降低和再结晶,获得了比铸造、锻造、退火、固溶处理和时效处理更好的延展性。因此,探寻熔合不良缺陷的预测识别方法,从而提高对熔合不良缺陷的监控识别能力,实现对加工过程的智能识别,是解决激光溶化沉积技术发展难题的关键。

加工缺陷的识别预测技术主要分为基于仿真数值模型的预测以及基于加工过程采集信号的机器学习识别预测。Wang 等^[9]通过线性热源模型和热沉降模型建立了沉积层温度分布,进而建立了分析热模型,实现了对熔合不良气孔的预测,预测最大偏差为 5.91%。Seifi 等^[10]利用非参数曲面插值对熔池红外热图像进行时空序列建模,利用卷积神经网络实现了对熔合不良缺陷的尺寸预测。目前以熔池的原位监测信号为数据源,利用机器学习方法实现了对熔合不良缺陷的自动识别研究尚存在较大空缺。

本文通过建立的激光熔化沉积原位监测系统,对加工过程中的熔池瞬态行为进行数据实时采集,提出熔池瞬态特征提取算法,研究出现熔

合不良气孔缺陷时熔池瞬态特征的演变行为;建立熔池瞬态特征数据集,基于深度学习理论,建立熔合不良缺陷识别模型,实现对激光熔化沉积过程缺陷的识别。

1 实验装置与数据采集

1.1 实验设备

采用了同轴送粉式半导体激光熔覆加工系统,如图 1 所示。主要由半导体激光器、六轴工业机器人、同轴激光熔覆头、双料载气式送粉器、冷水机以及数控系统、空气压缩机等设备组成,具体型号如表 1 所示。所用半导体激光器的光斑模式为圆形光斑,直径为 2 mm,光斑内激光能量强度分布均匀,超出光斑后能量强度迅速下降至零。




图 1 同轴送粉式半导体激光熔化沉积加工系统

Fig. 1 Coaxial powder-delivering semiconductor laser melting deposition system

(a)—半导体激光器; (b)—六轴机器人; (c)—同轴激光头; (d)—载气式送粉器; (e)—冷水机; (f)—集成控制器。

表 1 同轴送粉式半导体激光熔化沉积加工系统设备
Table 1 Equipment of coaxial powder-delivering semiconductor laser melting deposition system

设备名称	型号
半导体激光器	LDF 4000-100 VGP
六轴机器人	KUKA KR30HA-KRC4
激光熔覆头	PRECITEC Cladding Head YC52
送粉器	煜宸 RC-PGF-D 双筒载气式送粉器
冷水机	MCWL-150T-01AK1S4 精密冷水机

本文中所采用的熔池图像采集设备为德国 Ximea 公司生产的 CMOS 同轴相机(型号: MQ13MG-ON)。

1.2 实验材料

本文所使用的沉积基体与粉末均为 316L 奥氏体不锈钢,其主要成分如表 2 所示.粉末的粒度为 53~150 μm ,基体的尺寸为 15 mm \times 15 mm \times 60 mm,为去除基体表面氧化层对沉积效果的影响,对待沉积表面进行抛光处理,并在实验之前采用先砂纸打磨后酒精擦拭的操作,实验中所采用的吹粉气体与激光保护气体均为质量分数为 99.99% 的高纯度氩气。

表 2 316L 不锈钢粉末化学组成(质量分数)
Table 2 Chemical composition of 316L stainless steel powder (mass fraction) %

C	Mo	Ni	B	Cr	Si	Fe
0.06	2.28	11.78	0.78	18.51	0.99	余量

1.3 工艺参数设置

激光熔化沉积加工中,可调控的工艺参数包括激光功率、z 轴提升量、扫描速度等,综合考虑以上参数,本文引入激光沉积密度 $E^{[5]}$ 作为调控工艺参数的主要手段。

$$E = \frac{P}{D \cdot v} \quad (1)$$

其中: P 为激光功率; D 为光斑直径; v 为扫描速率.实验工艺参数见表 3。

表 3 实验工艺参数
Table 3 Experimental process parameters

序号	激光沉积密度 $\text{J} \cdot \text{mm}^{-2}$	激光功率 W	扫描速度 $\text{mm} \cdot \text{s}^{-1}$	z 轴提升量 mm	激光光斑直径 mm
1	40	320	4	0.5	2
2	45	360	4	0.5	2
3	50	400	4	0.5	2
4	55	440	4	0.5	2
5	60	480	4	0.5	2
6	65	520	4	0.5	2
7	70	560	4	0.5	2
8	75	600	4	0.5	2
9	43	430	5	0.5	2
10	48	480	5	0.5	2
11	53	530	5	0.5	2
12	58	580	5	0.5	2
13	63	630	5	0.5	2
14	68	680	5	0.5	2

本文实验方式为单道 10 层往复沉积实验,实验结束待试样冷却至室温,用线切割机切割

试样,固化剂与亚克力粉末按质量比 5:4 混合制备金相试样,用 80#~2000# 砂纸打磨后进行抛光、腐蚀,利用光学显微镜观测试样截面,熔合不良缺陷如图 2 所示.利用超景深显微镜获取熔合不良缺陷的位置信息,统计熔合不良缺陷出现情况。




图 2 熔合不良缺陷显微图像

Fig. 2 Micro image of lack of fusion defects

通过对沉积层边缘区域进行显微观测,共标记 103 处熔合不良缺陷,获取熔合不良熔池图像共计 311 张。

2 数据分析与处理

2.1 熔合不良缺陷影响关系分析

熔合不良缺陷产生根本原因是连续熔池重叠不足^[11],同一层相邻熔池的熔化、重叠状态以及加工实时产生的熔池与沉积层重熔结合状况决定了熔合不良缺陷萌生可能性.因此,本研究利用多源异构原位监测设备,针对加工过程中金属粉末在高能激光束的作用下的熔化与快速凝固过程,获取加工过程中的辐射信号,利用特征提取算法实现对熔池状态的定量描述,获取熔池瞬态特征,分析熔池瞬态特征对熔合不良缺陷的表征能力,结合深度学习方法,实现对熔合不良缺陷的识别。

金属粉末被高能激光束加热时,会向空间辐射出电磁波,随着粉末熔化,温度急剧升高,辐射出的电磁波波长逐渐接近可见光,在激光熔化沉积加工过程中,熔池温度保持在 1 200~2 800 $^{\circ}\text{C}$,此时液态金属熔池辐射出的可见光,被 CMOS 同轴相机上的传感器接收,形成熔池图像.根据热辐射定律,金属热辐射强度与温度相关,温度则与金属粉末的熔化状态有关,当熔池图像灰度不均一时,说明熔池中金属粉末的熔化状态存在差异,因此,熔池图像对熔池内部金属粉末的熔化状态具有表征作用.如图 3 所示,熔池在不同加工

时刻具有不同的形态特征,不同的形态特征代表了熔池中金属粉末处在不同的熔化状态.




图 3 第 5 组实验熔池图像

Fig. 3 The fifth set experiment melt pool images

(a)—第 1 层加工图像; (b)—第 3 层加工图像; (c)—第 5 层加工图像.

基于文献[12],熔池瞬态几何特征主要由 CMOS 相机针对液态熔池所采集到的高灰度区域的整体分布形态决定,不同的高灰度分布形态表征了沉积金属粉末在熔池中的熔化状态^[13],因此实现对 CMOS 相机所采集到的高灰度区域分布形态的精准提取,即可获得熔池视觉特征.

激光熔化沉积加工过程中,根据几何轮廓,熔池可分为 4 类.如图 4a 所示,第一类熔池轮廓近似呈圆形,此时熔池中粉末融化与液态金属凝固相对速率平衡,沉积状态良好,此时沉积层较少出现缺陷且表面质量良好;第二类熔池尾部角度增大,近似呈矩形,此时熔池中液态金属凝固速率较低,熔池接收能量过高,为过度熔融状态,此时由于能量输入过大,导致表面出现过热现象^[14],且能量输入过高导致内部元素气化,在熔池凝固之前无法逸出^[15],导致出现锁孔缺陷^[16],如图 4b 所示;第三类熔池为不规则形状,激光沉积密度较低,导致粉末熔化率较低,无法形成稳定的边缘传质状态,为不完全熔融状态,此时粉末熔化状态不稳定,当激光沉积密度小于 67 J/mm^2 时^[5],易出现熔合不良缺陷,如图 4c 所示;第四类熔池为不连续状态,此时能量沉积密度进一步降低,无法形成连续熔池,进而无法形成连续沉积层,如图 4d 所示.




图 4 不同熔融状态下的熔池几何轮廓

Fig. 4 Geometric contour of molten pool in different molten states

(a)—正常熔融; (b)—过度熔融;
(c)—不完全熔融; (d)—不连续熔融.

2.2 熔池瞬态特征提取算法

本文提出了基于开源 OpenCV 计算机视觉库的熔池瞬态特征提取算法模型,主要包括相机标定、图像滤波、二值化阈值分割、形态学处理和轮廓检测,特征提取算法流程如图 5 所示.其中相机标定消除 CMOS 相机镜头所带来的畸变效应,以及确定像素值与真实世界坐标比例;中值滤波消除视野中的噪声,并保持目标边缘特征,提高特征提取精度;二值化阈值分割将灰度图转化为黑白二值化图,排除因熔池表面漫散射导致的灰度局部不均,便于后续进行轮廓提取;形态学处理消除

加工过程中熔渣以及粉末飞溅导致的空洞与边缘毛刺,提高轮廓提取精度,利用轮廓提取算子实现对熔池几何轮廓特征的提取.




图5 特征提取算法流程图

Fig. 5 Flowchart of the feature extraction algorithm

2.3 基于LRCN的熔合不良识别模型

本文所建立熔合不良识别模型是基于LRCN模型^[17]进行的模型设计与优化,模型是结合了传

统卷积神经网络对单张二维数据的特征提取能力与LSTM神经网络对序列问题的处理方法的新网络结构,利用卷积神经网络层,对二维图像进行特征提取,获取图像特征序列,利用LSTM神经网络对获得的特征序列进行预测识别,输出分类结果.

模型结构如图6所示,主要包括5层2D卷积层,其中第1,3,5层卷积层附加最大池化层,实现对图像数据的特征提取,采用ReLU激活函数,防止模型训练过程中梯度消失现象的出现,将最后一层卷积层的输出进行维度调整,使适应LSTM网络的数据结构,之后将数据输入LSTM网络中,通过改变LSTM隐含层的大小以及LSTM网络层数进行结构优化,再将输出传入随机失活全连接层(Dropout linear)以降低模型过拟合程度,将数据通过输出识别预测结果.

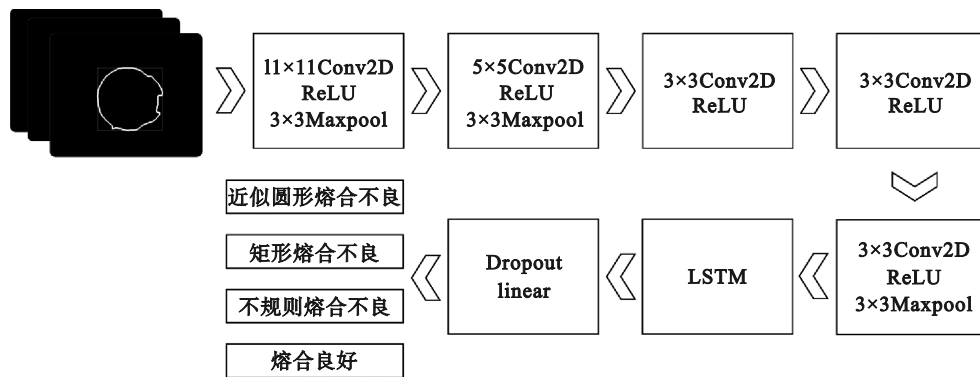


图6 LRCN模型

Fig. 6 LRCN model

2.4 制作数据集

由于熔合不良缺陷是存在于连续沉积层中的微小缺陷,因此本研究不考虑无法形成连续沉积层的不连续熔融态的熔池数据.在过度熔融熔池、正常熔融熔池以及不完全熔融熔池的基础上,通过观测沿沉积方向制备的沉积层金相试样,确定熔合不良缺陷萌生的时空坐标,基于熔池轮廓特征提取算法,获取了熔池瞬态几何轮廓,将获取的熔池瞬态几何特征与熔合不良缺陷的出现情况进行对应,实现对熔池瞬态形状特征的标注,将3种熔池根据熔合不良缺陷的萌生情况进一步细分为4类熔池,以建立原始数据集.由于熔合不良缺陷萌生的随机性^[10],为改善数据集之间的数据占比,防止模型过拟合现象的出现,对熔合不良熔池图像数据进行了数据增强处理,所采用数据增强处理包括:90°旋转、180°旋转、翻转、高斯模糊,如图

7所示.增强数据集分布如图8所示,将数据集按类别以4:1的比例划分训练集与测试集,同时为了保证模型结果稳定可复现,且训练结果不受初始数据集图像文件排序影响,引入随机种子.为了方便模型进行数据处理,在进行了数据增强之后,将熔池图像以熔池为中心裁剪至500像素×500像素大小,输入模型进行训练.




图7 图像增强

Fig. 7 Image augmentation




图 8 增强数据集分布

Fig. 8 Distribution of enhanced datasets

利用训练集数据对模型进行训练,在完成一次全部数据遍历后,将测试集输入模型,输出测试集准确度,通过测试集准确度与历史最优准确度对比,确定是否保存本次训练模型参数,在完成所有训练后,将最优模型参数保存,模型训练与验证如图 9 所示.

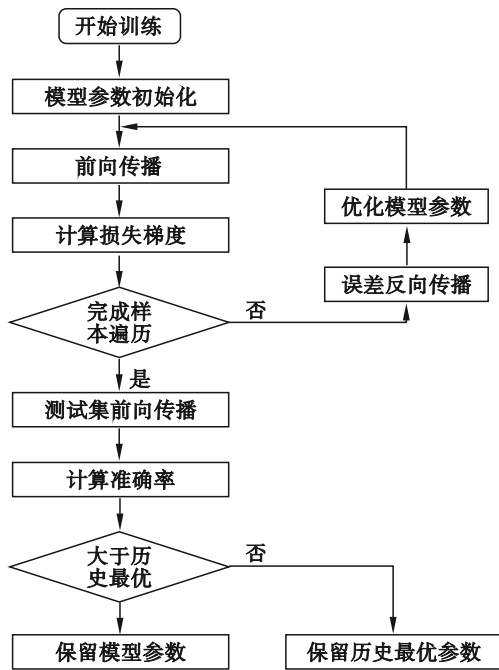


图 9 模型训练与验证流程

Fig. 9 Model training and validating process

3 结果与讨论

为获取针对熔合不良缺陷识别预测效果最好的模型,本文对比了常用的分类算法模型在熔合不良缺陷识别中的应用效果,并通过优化各算法模型的超参数选择,排除因超参数选择导致的模型训练效果差、模型运行时间过长等问题.同

时,为了避免某些模型由于其结构复杂,需要训练的模型参数过多导致训练时间过长而降低模型效率,本研究选择了迁移学习^[18]的方法,从已训练好的用于分类识别任务的模型中下载部分模型参数,降低本文所选用模型的训练时间,提高训练效率和模型的识别准确度.针对各模型的训练,损失函数统一选择交叉熵(cross entropy)损失函数,权重优化器选择 Adams 优化器.

首先选择目前常用于分类识别任务的经典 CNN 网络进行训练测试,所用参数及训练与测试结果如表 4 所示.训练与测试结果如图 10,图 11 所示, ResNet^[19] 和牛津大学 Visual Geometry Group 小组提出的 VGG^[20] 网络由于模型参数较多,模型结构较深,直接进行训练所需时间较长,数据量较大,故利用迁移学习的方法,引入了预训练模型进行训练. VGG 网络相较于 ResNet 网络,实现了测试集精度略高于训练集,但整体准确率较低,且损失曲线下下降偏慢,模型拟合速度较慢,经过综合对比,在熔合不良缺陷识别任务中, ResNet 网络的识别效果最好.针对熔合不良缺陷识别任务,识别效果最好的是 ResNet 34 网络,测试准确率达 97.9%,然而 ResNet 网络训练损失收敛于 0.21,仍处于较高位置,模型训练结果尚不理想.为了提高模型识别精度以及降低训练损失至理想状态,同时考虑到熔池熔化状态的判定需与熔池边缘区域的各点坐标存在关联关系,本文引入了 LRCN 模型,将卷积神经网络和循环神经网络相结合,利用卷积神经网络对图像的特征提取能力,获取特征序列,并不再将卷积神经网络输出特征维度缩减至类别数,将输出特征序列输入至 LSTM 神经网络,利用 LSTM 对序列数据的处理能力,建立卷积神经网络输出特征序列不同序列步之间的关系,实现对熔合不良缺陷的识别.为了获取识别准确率最高的 LRCN 模型,本文对 LRCN 模型的结构进行了进一步微调优化,以提高模型训练的准确率,微调后 LRCN 模型参数如表 5 所示,所得结果如图 12 所示.

表 4 传统模型参数与运行结果

Table 4 Parameters and running results of the traditional models

模型	学习率	训练轮次	批数据大小	训练准确率/%	测试准确率/%
VGG 11	0.001	100	5	84.1	93.9
VGG 16	0.001	100	5	87.8	94.6
ResNet 18	0.001	100	5	88.4	96.3
ResNet 34	0.001	100	5	89.3	97.9

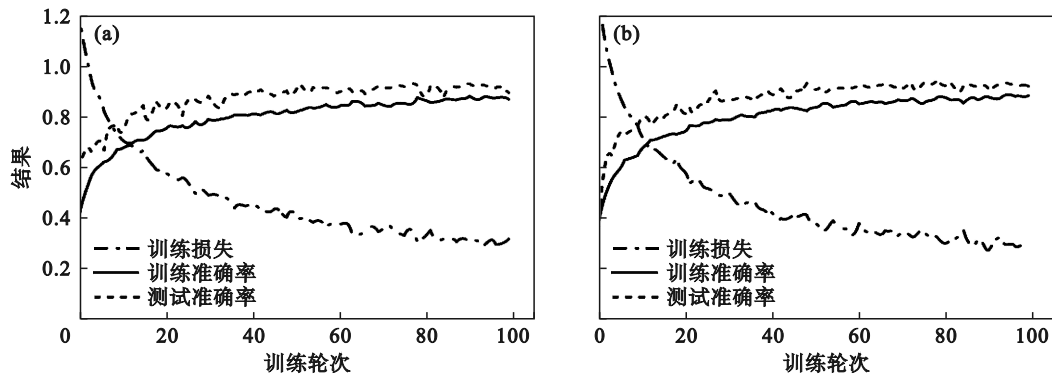


图 10 VGG 网络训练与测试结果

Fig.10 Training and testing results of VGG network

(a)—VGG 11; (b)—VGG 16.

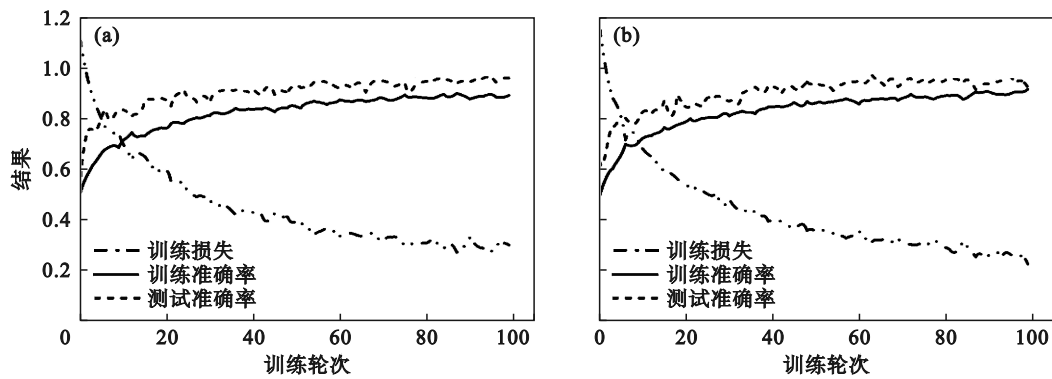


图 11 ResNet 网络训练与测试结果

Fig. 11 Training and testing results of ResNet network

(a)—ResNet 18; (b)—ResNet 34.

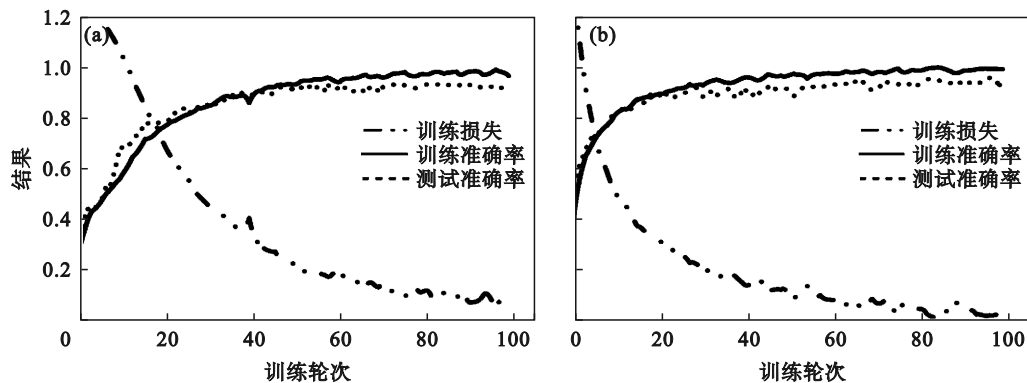
表 5 LRCN 模型参数与运行结果

Table 5 Parameters and running results of LRCN models

模型	学习率	训练轮次	批数据大小	隐藏层大小	训练准确率/%	测试准确率/%
LRCN 32	0.001	100	5	32	98.1	93.7
LRCN 64	0.001	100	5	64	99.3	95.8
LRCN 128	0.001	100	5	128	99.1	94.4
LRCN 256	0.001	100	5	256	99.4	94.9

由图 12 可得,LRCN 模型在训练集和测试集中拟合良好,在保持训练集准确率高于 98% 的前提下,实现了测试集模型准确率达 95.8%,且训练损失函数拟合结果较 ResNet 网络更低,训练损失更小.为了进一步表征 LRCN 模型对熔合不良缺陷

的识别能力,获取了 ResNet 34 网络和 LRCN 64 网络测试集数据的混淆矩阵(confusion matrix),以进一步表征 LRCN 模型对不同熔合不良缺陷标注图像的识别能力,如图 13 所示.



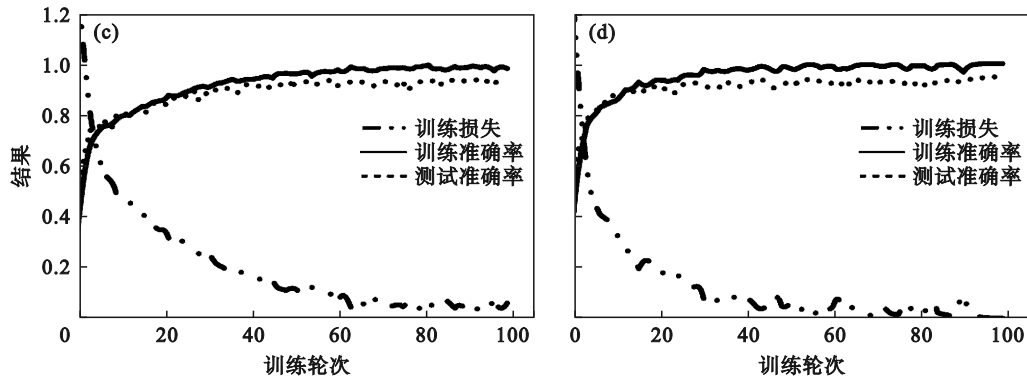


图 12 LRCN 模型训练与测试结果

Fig. 12 Training and testing results of LRCN model

(a)—LRCN 32; (b)—LRCN 64; (c)—LRCN 128; (d)—LRCN 256.




图 13 混淆矩阵图

Fig. 13 Confusion matrix diagram

(a)—ResNet 34; (b)—LRCN 64.

LRCN 64 模型对各类数据集的识别预测能力与 ResNet 34 模型基本一致,且在部分数据集中具有更高的识别精度和准确率,如表 6 所示. LRCN 64 模型训练及测试时间与 ResNet 34 网络相比更少,速度更快,如图 14 所示.

表 6 模型识别结果
Table 6 Model recognition results

熔合情况	ResNet 34			LRCN 64		
	准确率	灵敏度	特异度	准确率	灵敏度	特异度
近似圆形 熔合不良	0.962	0.977	0.983	0.953	0.931	0.98
矩形熔合 不良	0.98	0.951	0.994	0.949	0.912	0.985
不规则熔 合不良	0.975	0.987	0.994	0.919	1.0	0.98
熔合良好	1.0	1.0	1.0	1.0	1.0	1.0

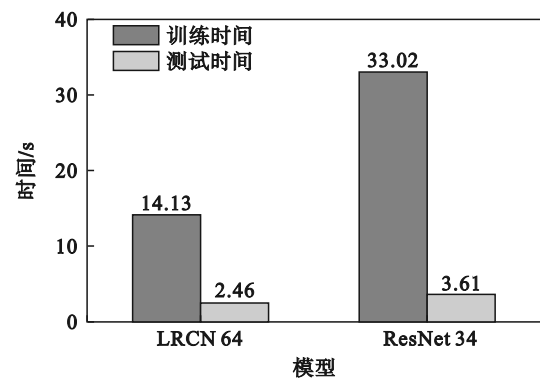


图 14 模型计算时间对比

Fig. 14 Comparison of model calculation time

4 结 论

1) 针对激光熔化沉积加工过程中采集到的熔池图像,建立了熔池瞬态特征提取算法,分析了熔池瞬态几何特征对沉积层熔合状态以及熔

合不良缺陷的影响,通过显微观测,实现了对沉积层熔合不良缺陷的定位以及对熔池瞬态几何特征数据集的数据标定。

2) 考虑到熔合不良缺陷萌生的偶然性,对建立的熔池瞬态几何特征数据集进行数据增强,将各类数据集的数据占比调整到合适比例,降低了模型过拟合的可能性.通过选择目前主流的识别预测模型 VGG 和 ResNet,选择了针对熔合不良缺陷识别任务精度相对较高的 ResNet 34 模型,其训练准确率为 89.3%,测试准确率为 97.9%,训练与测试时间分别为 33.02 和 3.61 s。

3) 针对 ResNet 34 模型存在运行时间长、训练损失拟合效果差等缺点,提出了基于 LRCN 模型的熔合不良识别预测 LRCN 64 模型,其训练准确率为 99.3%,测试准确率为 95.8%,且模型训练损失曲线拟合最低值为 0.011,而 ResNet 34 训练损失拟合最低值为 0.21,实现了模型运行效果的优化.同时在保证模型训练精度的前提下,LRCN 64 模型训练和测试时间分别降低至 14.13 和 2.46 s,为实现熔合不良缺陷在线识别提供了技术支撑。

参考文献:

- [1] Thompson S M, Bian L K, Shamsaei N, et al. An overview of direct laser deposition for additive manufacturing, part I: transport phenomena, modeling and diagnostics[J]. *Additive Manufacturing*, 2015, 8: 36-62.
- [2] Shamsaei N, Yadollahi A, Bian L K, et al. An overview of direct laser deposition for additive manufacturing, part II: mechanical behavior, process parameter optimization and control[J]. *Additive Manufacturing*, 2015, 8: 12-35.
- [3] 彭谦,董世运,闫世兴,等.激光熔化沉积成形缺陷及其控制方法综述[J]. *材料导报*, 2018, 32(15): 2666-2671, 2682.
(Peng Qian, Dong Shi-yun, Yan Shi-xing, et al. An overview of defects in laser melting deposition forming products and the corresponding controlling methods [J]. *Materials Review*, 2018, 32(15): 2666-2671, 2682.)
- [4] Svetlizky D, Das M, Zheng B L, et al. Directed energy deposition (DED) additive manufacturing: physical characteristics, defects, challenges and applications [J]. *Materials Today*, 2021, 49: 271-295.
- [5] Guo Q, Chen S Y, Wei M W, et al. Formation and elimination mechanism of lack of fusion and cracks in direct laser deposition 24CrNiMoY alloy steel [J]. *Journal of Materials Engineering and Performance*, 2020, 29(10): 6439-6454.
- [6] Nursyifaulkhair D, Park N, Baek E R, et al. Effect of process parameters on the formation of lack of fusion in directed energy deposition of Ti-6Al-4V alloy[J]. *Journal of Welding and Joining*, 2019, 37(6): 579-584.
- [7] Bustillos J, Kim J, Moridi A. Lack of fusion in additive manufacturing: defect or asset? [EB/OL]. (2021-04-14) [2023-01-16]. <http://arxiv.org/abs/2104.07014>.
- [8] Bustillos J, Kim J, Moridi A. Exploiting lack of fusion defects for microstructural engineering in additive manufacturing [J]. *Additive Manufacturing*, 2021, 48: 102399.
- [9] Wang W J, Ning J Q, Liang S Y. Prediction of lack-of-fusion porosity in laser powder-bed fusion considering boundary conditions and sensitivity to laser power absorption[J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 112(1): 61-70.
- [10] Seifi S H, Yadollahi A, Tian W M, et al. In situ nondestructive fatigue-life prediction of additive manufactured parts by establishing a process-defect-property relationship[J]. *Advanced Intelligent Systems*, 2021, 3(12): 2000268.
- [11] Tang M, Pistorius P C, Beuth J L. Prediction of lack-of-fusion porosity for powder bed fusion [J]. *Additive Manufacturing*, 2017, 14: 39-48.
- [12] 唐梓珏. 激光熔化沉积熔池动态特征演化行为及关键性质质量预测研究[D]. 大连: 大连理工大学, 2020.
(Tang Zi-jue. Study on evolution of molten pool dynamic characteristics and prediction of key product qualities in laser melting deposition [D]. Dalian: Dalian University of Technology, 2020.)
- [13] 唐梓珏, 刘伟巍, 颜昭睿, 等. 基于熔池动态特征的金属激光熔化沉积形状精度演化行为研究[J]. *机械工程学报*, 2019, 55(15): 39-47.
(Tang Zi-jue, Liu Wei-wei, Yan Zhao-rui, et al. Study on evolution behavior of geometrical accuracy based on dynamic characteristics of molten pool in laser-based direct energy deposition [J]. *Journal of Mechanical Engineering*, 2019, 55(15): 39-47.)
- [14] Song L J, Bagavath-Singh V, Dutta B, et al. Control of melt pool temperature and deposition height during direct metal deposition process [J]. *International Journal of Advanced Manufacturing Technology*, 2012, 58(1): 247-256.
- [15] Wang L, Zhang Y M, Chia H Y, et al. Mechanism of keyhole pore formation in metal additive manufacturing [J]. *NPJ Computational Materials*, 2022, 8(1): 143-153.
- [16] Gargalis L, Ye J C, Strantzis M, et al. Determining processing behaviour of pure Cu in laser powder bed fusion using direct micro-calorimetry [J]. *Journal of Materials Processing Technology*, 2021, 294: 117130.
- [17] Donahue J, Hendricks L A, Guadarrama S, et al. Long-term recurrent convolutional networks for visual recognition and description [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 677-691.
- [18] Lu J, Behbood V, Hao P, et al. Transfer learning using computational intelligence: a survey [J]. *Knowledge-Based Systems*, 2015, 80: 14-23.
- [19] Wen L, Li X Y, Gao L. A transfer convolutional neural network for fault diagnosis based on ResNet-50[J]. *Neural Computing & Applications*, 2020, 32(10): 6111-6124.
- [20] Chaib S, Liu H, Gu Y F, et al. Deep feature fusion for VHR remote sensing scene classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(8): 4775-4784.