

引文格式: 段现银, 彭可为, 朱鲲鹏, 等. 基于机器学习的选区激光熔化过程熔池类别预测[J]. 航空制造技术, 2025, 68(10): 58-67.

DUAN Xianyin, PENG Kewei, ZHU Kunpeng, et al. Prediction of melt pool category in selective laser melting process based on machine learning[J]. Aeronautical Manufacturing Technology, 2025, 68(10): 58-67.

基于机器学习的选区激光熔化过程熔池类别预测

段现银¹, 彭可为¹, 朱鲲鹏^{1,2}, 王齐胜², 彭宽宝¹

(1. 武汉科技大学冶金装备及其控制教育部重点实验室, 武汉 430081;

2. 中国科学院合肥物质科学研究院智能机械研究所, 常州 213164)

[摘要] 选区激光熔化(Selective laser melting, SLM)作为最实用的金属激光增材制造技术之一, 凭借在复杂薄壁件快速成形中的显著优势, 在航空、航天和能源等领域中得到广泛应用。然而, 成形过程中的一致性限制了构件质量的进一步提升, 该问题与熔池尺寸和形状的不断变化导致的缺陷密切相关。为更有效地监控熔池动态变化, 本文提出了一种基于高维熔池运动特征提取和长短期记忆(Long short-term memory, LSTM)模型的熔池熔化状态类别预测方法。首先, 利用 U-net 模型从熔池图像中提取熔池形貌特征, 计算熔池质心到边界的距离, 并沿轮廓展开为高维矢量, 以此来表征熔池运动特征。然后, 应用 k -means 聚类算法对不同工艺参数下的熔池运动特征进行聚类分析, 构建出 4 种熔池熔化状态类别, 并通过 LSTM 模型开展了熔化状态类别的时间序列预测。最后, 以典型航空用高温合金材料 Inconel 625 的 SLM 过程为例, 进行熔池状态类别预测验证。结果显示, 预测准确率达到 85.92%, 本文为 SLM 过程的实时监控和质量控制提供了新的方法和思路。

关键词: Inconel 625; 选区激光熔化(SLM); 熔池运动特征; k -means 聚类算法; 时间序列预测

中图分类号: V26; TG1 **文献标志码:** A **DOI:** 10.16080/j.issn1671-833x.2025.10.058



段现银

博士, 教授, 研究方向为精密制造与智能制造。

航空航天领域的快速发展对空天装备的性能提升和缩短生产周期提出了更高要求。复杂薄壁件的高质量快速成形是提升空天装备性能和生产效率的关键因素之一。选区激光熔化(Selective laser melting, SLM)技术凭借高精度、复杂结构的成形能力以及对多种金属材料的适用性, 在航空航天薄壁件制造领域的应用愈发广泛^[1]。然而, 尽管 SLM 在复杂薄壁件的快速成形方面表现出巨大的潜力, 其成形质量的一致性、稳定性和可重复性仍面临诸多挑战^[2]。在 SLM 过程中, 熔池的形成和运动状态是决定薄壁件成形质量的关键因素。熔池在凝固前始终处于运动和振荡之中, 因此对其运动状态的准确预测能够帮助研究人员及时发现潜

在问题, 为成形过程的监控、工艺参数优化以及成形质量的提升提供重要支持。

目前, 众多学者围绕金属增材制造在线监测这一热门研究领域开展了广泛探索。Zou 等^[3]采用统计分析方法对熔池光强和熔池面积进行了融合分析, 从而实现了对粉末床厚度变化引发的熔池状态的在线监测。陈香媛等^[4]结合在线监测信号特征与零件质量分析, 提出了一种基于熔池光强信号的沉积缺陷在线诊断方法。Yao 等^[5]研制了一套多传感器在线监测系统, 用于监测和评估激光热丝熔覆过程。李子帆等^[6]提出了一种基于图像处理的识别测量算法, 帮助熔池实时监控。本团队段现银等^[7]基于数字孪生技术, 在物

理空间和虚拟空间建模的基础上,开展了熔池在线监控系统的设计和案例应用。

由于金属增材制造工艺过程具有高度复杂性,即使在相同工艺参数条件下,熔池形态仍可能出现显著差异,导致难以在两者之间建立稳定的物理联系。因此,人工智能技术被广泛应用于金属增材制造领域^[8]。Kwon等^[9]通过调整深度学习神经网络,构建了一个分类模型,通过识别熔池图像筛选出可能存在缺陷的产品。Wang等^[10]提出了一种时间卷积网络方法,通过识别与熔池宽度、层高密切相关的物理特征及关键工艺参数,实现了对熔池宽度的预测。Raj等^[11]利用机器学习模型预测了不同零件位置和摆放方向对零件表面熔池形态的影响。Zhang等^[12]展示了一种基于机器学习的预测建模方法,用于估算激光增材制造过程中的熔池温度。李春凯等^[13]基于深度卷积神经网络对熔池状态进行分类,展示了良好的网络泛化能力。本团队Wang等^[14]构建了基于运动特征的高斯过程分类模型,从而识别熔化状态。

综上所述,当前已有大量针对SLM的在线监测研究,特别是运用

人工智能技术分析金属增材制造过程中的熔化状态。但现有研究将熔池宽度或熔池面积作为特征进行熔化状态分类,这些几何特征无法完全准确地反映实际熔池的形态^[15]。熔池作为一个动态变化的运动目标,在形成过程中呈现出复杂的运动状态,因此基于运动特征的识别方法更适用于熔池熔化状态的监测。然而,现有研究主要关注运动状态的识别和分类,尚未有研究提出基于运动状态的熔化类别预测方法。

为此,本文提出了一种结合高维熔池运动特征与机器学习模型的熔化状态预测方法,从而精确预测熔池熔化状态类别并提高在线监测的有效性。设计了熔化状态类别预测方法的总体框架,应用U-net网络对熔池形貌进行捕获,并利用Canny算子进行熔池轮廓提取,使用平均交并比(mIoU)、平均像素准确度(mPA)和平均召回率(mRecall)等指标进行效果评估。通过计算熔池质心到轮廓的距离并展开,实现熔池运动特征提取。再基于主成分分析法(Principal component analysis, PCA)进行数据降维,并采用k-means算法对熔池运动特征进行聚类分析,

建立了4种熔池熔化状态类别。使用长短期记忆网络(Long short-term memory, LSTM)对熔池熔化状态类别进行时间序列预测,通过混淆矩阵分析模型的预测效果。

1 熔池运动特征提取与熔化状态类别预测方法

在SLM工艺中,熔池以一种连续运动的状态存在,其尺寸与形状会随时间发生显著变化。这种时变特性是导致加工过程中出现缺陷的关键诱导因素之一。如果能够准确预测熔池在未来时间段内的动态变化,就有可能通过优化工艺参数有效避免缺陷的产生。为实现对熔池动态变化的预测,本研究基于熔池的运动特征,建立了熔池熔化状态类别,并在此基础上训练了用于预测熔化状态的模型,相关研究流程如图1所示。

首先,根据激光光斑位置的变化确定熔池的运动方向,并精确定位熔池的质心坐标。为提取熔池的轮廓信息,采用U-net深度学习模型精准分割熔池区域。随后,将熔池沿其轮廓展开,计算质心到轮廓的距离分布,从而提取熔池的运动特征。基于这些特征,利用k-means聚类算法对

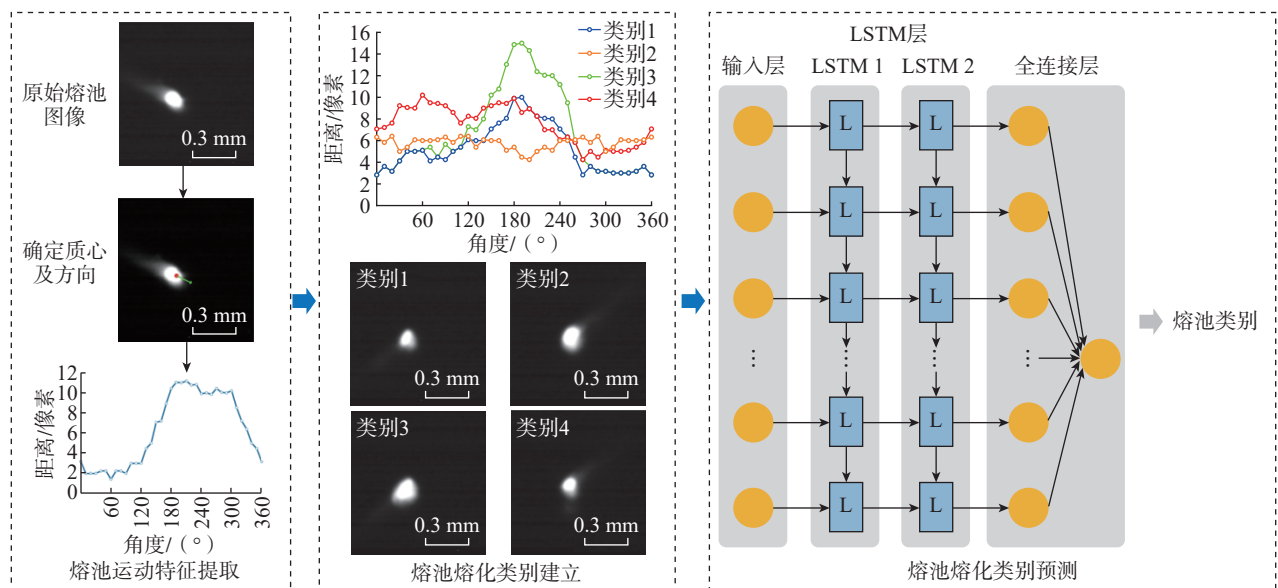


图1 熔池运动特征提取及熔化状态预测

Fig.1 Motion feature extraction and melting state prediction of melt pool

熔池运动特征进行聚类,划分出4种典型的熔化状态类别。

在此基础上,结合实际工艺参数构建了一个包含多维特征的熔池数据集,使用LSTM对熔池的熔化状态进行预测。训练完成后,该模型能够在成形过程中实现对后续熔池所属熔化状态类别的高精度预测,为实时监测和工艺参数优化提供重要依据。

1.1 熔池形貌捕获和轮廓提取

SLM过程中,会产生红外光、紫外光、可见光、声音及超声波等多种信号,这些信号可通过光学、热学和声学等传感器进行监测。高速摄像机具有非接触性、不干扰成形过程且能捕获大量信息的特点,被广泛应用。通过高速摄像机获取图像信息可以直观地显示熔池现象,还具有较高的经济性和实用性。本文熔池图像来自公开数据集^[16],该数据集通过SLM成形与熔池图像监测试验获取。在试验中,通过SLM设备成形制造了12个削边矩形试样,样件的长、宽、高分别为10 mm、10 mm和5 mm,各个试样采用变化的工艺参数与扫描策略。粉末材料采用Inconel 625,从低温到1000℃的整个使用温度范围内,该材料具有高拉伸强度、良好的可焊性、优异的耐腐蚀性和抗

疲劳强度,广泛应用于飞机等航空器的关键零部件制造^[17]。激光的波长为1070 nm,光斑直径约为85 μm。根据传感器位置,监测系统分为同轴和离轴两类。在熔池图像获取中,通过确保同轴的熔池监测摄像机与激光轴线的光学对准,使得熔池在摄像机视场内呈现静止状态,不随振镜系统XY位置的变化而变化,从而能够从拍摄的视图中清晰地获取熔池的完整图像,且无需像离轴监测那样进行复杂的校准。因此同轴高速摄像机图像更适合表征熔池变化。

本文对所获取到的熔池完整图像进行了一系列的处理,以构建熔池特征,处理步骤如图2所示。由于关键信息局限在小区域,首先通过确定熔池最小包围矩形,从高速摄像机捕获的熔池图像中提取感兴趣区域(Region of interest, ROI),将熔池图像从120像素×120像素缩小到40像素×40像素,以避免飞溅等特征的影响,同时提高操作效率,如图2(a)和(b)所示。

为了后续的熔池轮廓及运动特征提取,需要进行熔池形貌的分割。在常用的图像分割方法中,相较于阈值分割法和活动轮廓法,基于U-net的图像分割方法在复杂情况下提取

熔池轮廓的mIoU更高,而且模型计算成本更低^[18]。因此,本文采用基于U-net的图像分割方法确定熔池形貌。

在基于U-net的图像分割研究中,针对熔池图像数据进行了模型训练。为防止模型出现过拟合,从不同成形层中随机挑选多个熔池图像,并按照不同数量组合,构建了3000张熔池图像,以及3000张与之对应的熔池标签。为进一步提升样本的多样性和数据量,通过对原始熔池图像进行水平反射的数据增强操作,将数据集扩展至30000张熔池图像,以及30000张与之对应的熔池标签。

在数据划分阶段,将增强后的数据集分为训练集(24000张)、验证集(3000张)和测试集(3000张)。其中,验证集用于实现早停机制以防止过拟合,测试集用于评估模型的最终性能。在训练过程中,采用了二元交叉熵损失函数(Binary cross-entropy loss),并设置了50轮训练(Epochs)。训练完成后,选取验证集损失趋于稳定时的模型作为最终模型,用于提取熔池的形貌特征(图2(c))。

在后处理阶段,为了消除边缘检测过程中可能出现的尖锐阶梯状轮廓或孤立噪点,利用高斯滤波对提取的熔池边缘进行平滑和去噪处

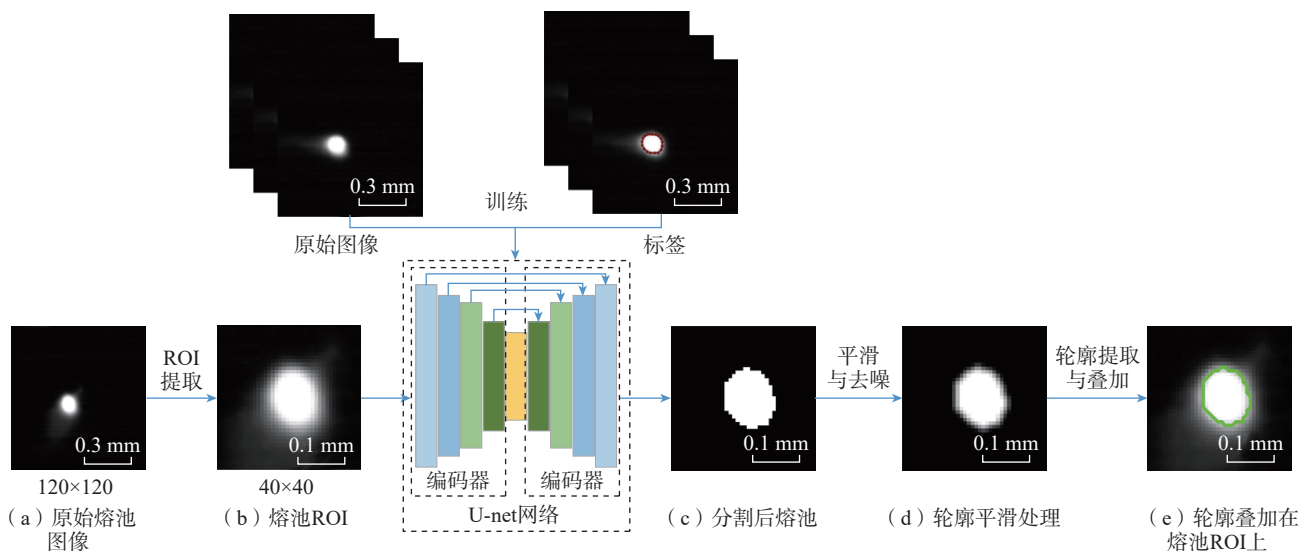


图2 熔池轮廓提取

Fig.2 Extraction of melt pool contour

理。经过平滑处理后,熔池的区域分割结果如图 2 (d) 所示。随后,应用 Canny 算子对平滑后的熔池图像进行轮廓检测,最终生成的熔池轮廓叠加在 ROI 上,结果如图 2 (e) 中的绿色曲线所示。

此流程可有效提高熔池轮廓提取的精度和鲁棒性,从而为熔池特征提取提供可靠的数据支持。

1.2 熔池高维运动特征提取

在 SLM 工艺中,熔池在扫描过程中呈现出连续的运动状态,主要表现为沿扫描轨迹的移动以及熔池自身的振动。熔池复杂的运动会对其尺寸和形状产生显著影响。为实现熔池动态行为的系统化表征,需精准识别或提出能完整表征其三维形貌及尺寸演化的核心特征参数。传统几何特征(如熔池宽度和面积)在捕捉熔池尺寸和形状随时间的动态变化方面存在一定局限性,难以反映其演变的全貌。本团队的 Wang 等^[14]对熔池图像的轮廓进行展开处理,将其转化为以熔池质心为基准到轮廓边界的距离序列,试验表明,这一长度序列能够更直观、完整地描述熔池轮廓的动态变化,从而可以更有效地分析熔池随时间演变的尺寸和形状特性。

本文采用同样思路,将熔池沿其轮廓展开,并将其转化为熔池质心到轮廓边界的距离序列。在此过程中,鉴于所用熔池图像是通过同轴监测获取,激光光斑中心在图像坐标系中的位置保持不变,且熔池的形成是由激光中心向外熔化的过程,本文将熔池质心视为激光光斑中心。这一简化能够有效减少因熔池质心动态变化带来的复杂计算,并确保对熔池动态特性描述的一致性。

在确定激光光斑中心的过程中,当激光处于关闭或刚开启状态时,所获取的熔池图像较为暗淡,该状态下熔池尚未充分流动,此时熔池质心与激光光斑中心最为接近。因此,激光

光斑中心的确定步骤:对 20 张暗淡熔池图像进行二值化处理,随后对二值化图像进行质心坐标计算,并对所得坐标进行平均化处理,最终确定熔池质心在图像坐标系中的平均位置为 (52, 65),并将该位置作为所有熔池质心的统一参考基准。

熔池运动特征的提取如图 3 所示,首先以熔池运动方向线与熔池边界的交点 A 为起点,沿某一固定方向(本文为逆时针方向)以固定角度步长(本文设置为 10°)展开熔池轮廓。然后,依次计算从熔池质心 O 到边界各点的距离,形成一个固定维度(本文为 36)的向量特征 $D = \{d_0, d_1, d_2, \dots, d_{35}\}$ 。其中, 0° 和 360° 被视为同一特征,用于表示熔池在一个完整周期内的形状变化。

为便于理解,图 3 (a) 中标注了熔池质心 O 到边界不同点(如起点 A 及其他随机点 B 、 C 和 D) 的距离,这些距离分别对应图 3 (b) 中 A 、 B 、 C 和 D 处的纵坐标值。这种特征提取方法通过对熔池轮廓的定量描述,捕捉了熔池的动态形变,为后续熔池熔化状态类别的建立提供了可靠的输入数据。

在向量特征 D 中,特征元素 d_i 为

$$d_i = \sqrt{(x_i - x_0)^2 + (y_i - y_0)^2} \quad (1)$$

式中, (x_i, y_i) 是在相应角度处的边界像素的坐标 ($i=0, 1, 2, \dots, 36$); (x_0, y_0) 是熔池质心。在本文中,质心坐标为 (52, 65) 对应的像素点。

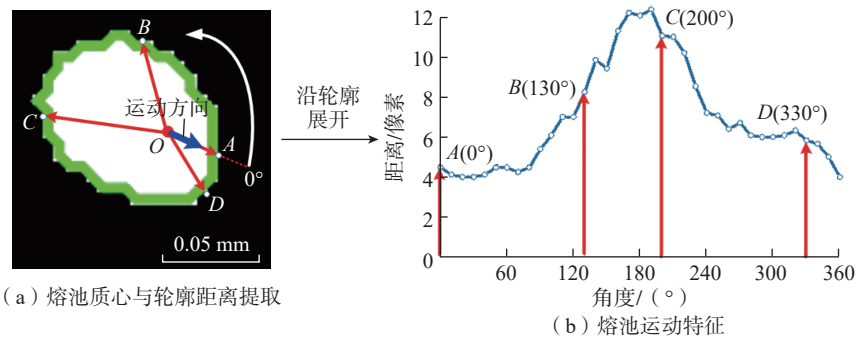


图 3 熔池运动特征提取

Fig.3 Extraction of melt pool motion features

结果显示,金属粉末在吸收激光能量后,并非在激光光斑中心附近均匀熔化,不同方向上的熔化程度存在显著差异。

1.3 熔池熔化状态类别预测

在 SLM 过程中,熔池形貌特征表现出显著的周期性变化^[19]。基于熔池形貌提取的运动特征,以及由此建立的熔化状态类别,同样具有周期性规律。这使得根据历史数据变化来预测未来数据的变化成为可能。针对这类具有周期性变化规律的熔池熔化状态类别预测,可采用基于机器学习的时间序列预测方法。该方法利用历史数据的时间序列关系,对未来数据值进行推测,从而实现动态过程的精准预测。具体而言,采用循环神经网络 (Recurrent neural network, RNN) 的变体,即采用 LSTM 模型进行熔化状态类别预测。LSTM 通过其独特的单元状态结构,以及引入的输入门、遗忘门和输出门,有效缓解了传统 RNN 中存在的梯度消失问题。这种改进使得 LSTM 模型在处理复杂的时序数据时具有更强的能力和稳定性。

对熔池熔化状态类别展开精确预测,能够为工艺参数(如激光功率、扫描速度和扫描方向)的优化提供有力指导,进而实现 SLM 过程的实时监测与有效控制,提高成形质量。通过分析 Pearson 相关系数,进一步研究了工艺参数与熔池熔化状

态类别的相关性。相关性强的特征通常与输出特征(熔池熔化状态类别)之间存在显著的统计关系,这意味着它们能够为模型提供有价值的信息。通过这些特征,模型能够更准确地捕捉数据中的模式和趋势,从而提高预测的准确性。

本文通过 Pearson 相关系数矩阵呈现了激光功率、扫描速度和扫描方向这 3 个工艺参数与熔池熔化状态类别之间的相关性,如图 4 所示。可以看出,熔池熔化状态类别与激光功率、扫描速度和扫描方向均呈正相关,相关系数分别为 0.67、0.18 和 0.45。其中,激光功率对熔池熔化状态类别的影响最大,存在直接关系。因此,为了在后续的时间序列预测中准确预测熔池的熔化状态类别,将激光功率和激光扫描方向作为模型的输入特征。尽管扫描速度对熔池熔化状态类别的影响相对较小,本文仍在模型中将其作为输入特征,但降低其输入权重,以确保全面准确地预测熔池的熔化状态类别。Pearson 相关系数 $\rho_{X,Y}$ 的计算公式为

$$\rho_{X,Y} = \frac{\text{cov}(X,Y)}{\sigma_X \sigma_Y} \quad (2)$$

式中, $\text{cov}(X, Y)$ 表示 X 和 Y 的协方差; σ_X 和 σ_Y 分别表示 X 和 Y 的样本标准差。在机器学习中, $\rho_{X,Y}$ 可用于计算特征与类别之间的相似性,判断提取的特征和类别是否呈正相关、负相关或无相关。当相关系数为 0.00 时,表示变量 X 和 Y 之间无关联。

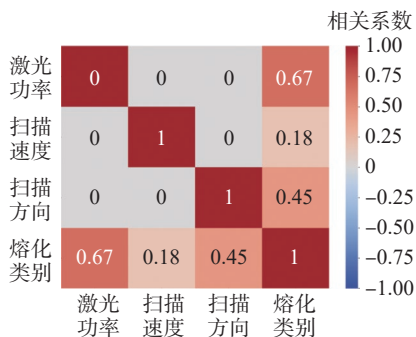


图 4 Pearson 相关系数分析

Fig.4 Pearson correlation coefficient analysis

当 X 的值增加(或减少)时, Y 的值也相应增加(或减少),两个变量呈正相关,相关系数在 0.00 到 1.00 之间;当 X 的值增加(或减少)而 Y 的值减少(或增加)时,两个变量呈负相关,相关系数在 -1.00 到 0.00 之间。相关系数的绝对值越大,关联性越强,而越接近 0,关联性越弱。

本文使用具有相同扫描策略第 10、22、34、46、58、70 层的数据,一共 17270 条数据,将训练样本和验证样本的比例设置为 4:1。使用第 82 层数据,共 2892 条数据作为测试集。熔池熔化状态类别作为模型的输出特征,如图 5 所示。总体来看,熔池熔化状态类别呈现出一定的周期规律性,这使得 LSTM 模型可以很好地捕捉这一特性,从而预测未来的趋势。由于 SLM 过程中能量吸收和温度的不稳定性,熔池在沉积过程会出现缺陷。例如,在图 5 中,每一层前半部分在低激光功率条件下出现 3 类、4 类熔池,这些熔池可能有缺陷。随着沉积层数的递增,这些缺陷熔池的数量逐渐减少,可能是因为在沉积的初期阶段,温度和物理场的不稳定性所致。将这些潜在的问题也纳入模型的输出特征中,有助于提升模型的鲁棒性,使其能够更准确地预测符

合实际情况的结果。

通过多次调试对比,确定在时间步长为 30 时,模型预测效果最好。随后对网络参数(批处理大小,丢弃率,损失函数和 LSTM 神经元个数)采取随机搜索调优,运行两次试验,每次试验做 100 次随机搜索调优以避免结果的偶然性和误差。将得到的最优参数组合作为最终确定的参数组合,代入模型中,对归一化后的数据进行预测。此外,结合交叉验证法,采用可以动态调整学习率的自适应矩阵估计(Adaptive moment estimation, ADAM)优化器,将初始学习率设置为 0.00001。设置早停策略阈值为 10,当验证集损失超过 10 轮未改善则终止训练。模型参数调优如表 1 所示。模型隐藏层参数如表 2 所示,其中,总参数为 5301,可训练参数为 5301,不可训练参数为 0。

2 结果与讨论

2.1 熔池图像处理

在测试集中综合使用 mIoU、mPA 和 mRecall 3 项指标评估模型性能。测试结果显示,模型的 mIoU 为 89.68%,表明其在各类别上的分割质量较高;mPA 为 89.94%,直观反映了模型在整体分类任务中的良

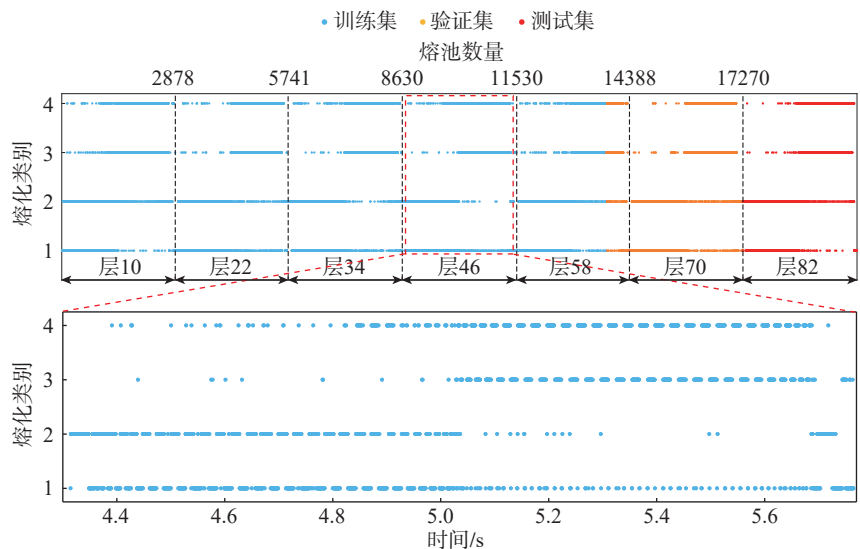


图 5 零件各层的熔池熔化状态类别

Fig.5 Melting state categories of the melt pool of each layer of the part

好准确性,证明此模型能够正确分类大多数像素点; mRecall 达到了 88.94%,这一指标通过模型成功识别出的正例数量,与实际正例总数的比例的平均值,反映了模型对各个类别的正例都有良好的识别能力。综合上述评估结果可得,模型在捕捉熔池形貌特征方面具有优异性能。

本文所用数据集对应的 SLM 试验成形了 12 个样件(3×4 排列),从中随机选取一个样件(编号 10)对应的熔池监测图像进行处理,提取了图像中的熔池轮廓特征。为直观展示轮廓提取的效果,选取了 3 张具有代表性的熔池监测图像及其提取的轮廓结果。其中,图 6(a)和(b)分别对应较小激光功率(156 W)和较大激光功率(234 W)的工况;图 6(c)则反映了受到飞溅干扰的典型场景。

针对上述不同工况,模型在熔池分割和轮廓提取任务中均表现出良好的效果。结果表明,结合 U-net 深度学习模型与 Canny 边缘检测算法,可以有效实现熔池监测图像的分割与轮廓提取,为进一步分析熔池运动特征提供了可靠的数据支持。

2.2 熔池聚类

为构建熔池熔化状态类别,基于熔池运动特征,对第 10 层共 2878 张熔池图像进行聚类分析。由于提取的熔池运动特征维度高达 36 维,不仅增加了计算复杂性,也不利于统计分析和可视化。因此,本文采用 PCA 对数据进行降维。结果表明,第一、第二、第三主成分的贡献率分别为 44%、28%、16%,累计贡献率达到 88%,说明前 3 个主成分能够有效代表 36 维特征信息,满足后续聚类分析和可视化的需求。

k 值的选取对于聚类结果至关重要,本文通过轮廓系数法来确定 k 的取值。轮廓系数依据数据点到其所属聚类中心点的距离,以及到与之最近的其他聚类中心点的距离之间的比值来计算的。对于一个合适的 k 值,其轮廓系数应该最大,轮廓系数的计算公式为

$$S(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (3)$$

式中, $S(i)$ 是第 i 个数据点的轮廓系数; $a(i)$ 表示第 i 个数据点与其所属簇中其他数据点的平均距离; $b(i)$

表示第 i 个数据点与非所属簇中最近簇的数据点的平均距离。为了评估整个聚类的效果,计算所有数据点轮廓系数的平均值,将其作为整个聚类分析的轮廓系数,轮廓系数的取值范围为 $[-1, 1]$ 。取 $k=2, 3, 4, 5, 6$, 发现当 $k=4$ 时轮廓系数最高,为 0.51, 所以将熔池状态划分为 4 类。图 7 为将熔池特征降维后, $k=4$ 的聚类效果。

图 8 为第 10 层 4 个聚类中心的熔池和对应的运动特征。观察聚类中心的熔池特征曲线可知,熔池运动特征对激光扫描方向变化非常敏感,相同激光扫描方向所对应的熔池特


表 1 模型参数调优
Table 1 Model parameters tuning

| 参数 | 参数范围 | 最优参数 |
|--------------|-------------------|------|
| LSTM 1 神经元个数 | (10, 50) 步长 10 | 10 |
| LSTM 2 神经元个数 | (10, 50) 步长 10 | 30 |
| 损失函数 | MAE, MSE | MSE |
| 批处理大小 | (16, 32, 64) | 32 |
| 丢弃率 | (0.1, 0.5) 步长 0.1 | 0.2 |


注: 平均绝对误差 (Mean absolute error, MAE); 均方误差 (Mean squared error, MSE)。

表 2 隐藏层参数
Table 2 Hidden layer parameters


| 隐藏层 | 输出形状 | 参数 |
|--------|----------------|------|
| LSTM 1 | (None, 30, 20) | 2000 |
| LSTM 2 | (None, 20) | 3280 |
| 丢弃层 | (None, 20) | 0 |
| 全连接层 | (None, 1) | 21 |



(a) 激光功率 156 W



(b) 激光功率 234 W



(c) 受飞溅干扰的典型场景

图 6 基于 U-net 的图像处理结果

Fig.6 Image processing results based on U-net

征曲线相似,不同扫描方向所对应的熔池特征曲线在形状上差异很大。

激光功率的大小,最直观的影响体现在熔池面积的大小上,反映在熔池运动特征上是曲线峰值的大小。在扫描时有两个阶段,阶段 I 的标称激光功率为 156 W,阶段 II 的标称激光功率为 234 W,扫描路径比阶段 I 略有偏移,不重新添加粉末。不同的激光功率会导致不同的最终成形质量,对应不同的熔化类别。

激光功率过小会导致熔池受热不足,层间无法充分黏合导致孔洞等缺陷。激光功率过高材料可能过度熔化,产生球化、飞溅等现象。

在 SLM 成形过程中,氩气等保护气体的流动对于保护熔池、减少氧化以及确保成形质量至关重要。Andreau 等^[20]研究了平行于保护气流方向和垂直于保护气流方向两种激光扫描方式,发现扫描方向和气流显著影响熔池的形状和尺寸。此外,在相同的参数下,沿气流方向扫描可以使熔池深度减小 33%。试验采用惰性氩气作为保护气体,向图像右上方运动的熔池与保护气体流动方向成锐角,向图像左下方运动的熔池与保护气体流动方向成钝角。这两类熔池的形状和大小不同,这可能受到扫描方向和保护气体流动方向的影响,导致两类熔池内部的动力学特性和温度梯度可能不同。因此,具有不同扫描方向的两类熔池最终成形质

量不同,对应不同的熔化类别。

映射在扫描路径上的聚类结果如图 9 所示。在阶段 I 左上半部分分布着类别 3 和类别 4 的熔池;在阶段 II 中,零星分布着一些类别 1 和类别 2 的熔池。这表明即使工艺参数相对稳定,也可能出现与工艺参数对应之外的熔池运动特征,导致熔化状态发生意外变化,这意味着加工过程

中可能存在成形缺陷或工艺参数异常。根据重熔对金属激光熔单熔道成形质量的影响研究可知^[21],重熔可以改善单熔道表面质量,减少熔道表面缺陷。图 9 中,阶段 I 左上部分可能存在成形缺陷,阶段 II 的熔池可能受到重熔的影响,熔化类别较为稳定,但仍出现黑圈中的类别 1 熔池,代表可能存在成形缺

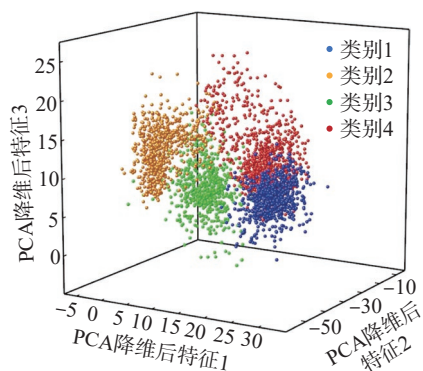


图 7 熔池聚类结果 ($k=4$)

Fig.7 Results of melt pool clustering ($k=4$)

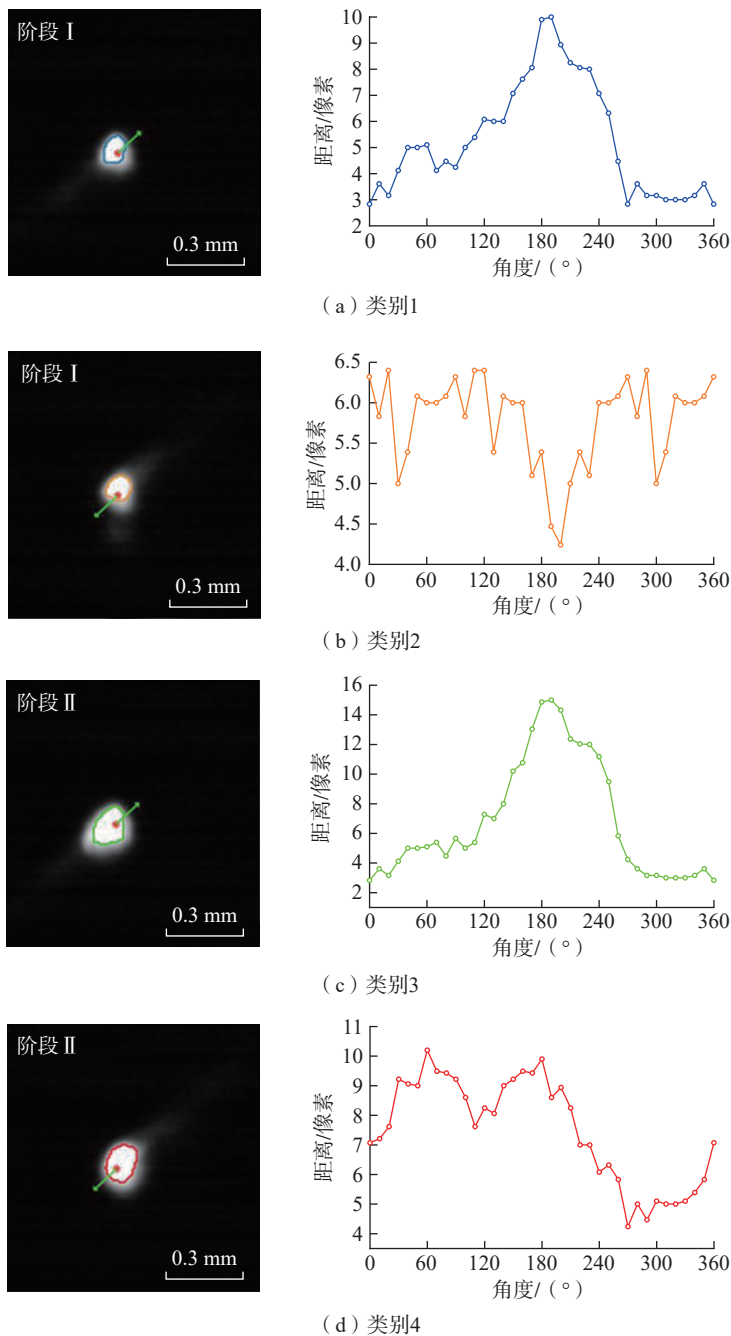


图 8 4 种典型聚类中心对应的熔池熔化状态

Fig.8 Melting states of the melt pools corresponding to four typical clustering centers

陷,需要调整工艺参数减少熔池熔化状态的意外变化。

对后续第 22、34、46、58、70、82 层同样进行 $k=4$ 的聚类,扫描路径会随着层数的增加有 84° 旋转,在相同激光功率的类别中,将角度补偿后相同方向的熔池归为一类,使不同层的相同类别可以相互对应。

为了进一步分析熔池熔化状态与工艺参数之间的对应关系,从图 9 的映射结果中选取局部扫描路径进行研究,如图 10 (a) 所示,其对应的工艺参数变化如图 10 (b) 所示,并在成形过程的不同时刻标记出相应的熔池熔化状态类别。可见,在扫描

路径的直线部分,激光功率稳定在 234 W,扫描速度保持在 800 mm/s,熔池熔化状态稳定在类别 3 和类别 4。在扫描路径的拐弯处,激光功率与扫描速度显著同步下降,熔池熔化状态转变为类别 1 和类别 2,这种变化主要是由于激光功率降低导致熔池面积减小所引起的。此外,拐弯处的熔池表面形态通常不会明显朝特定方向延伸,降低了其对扫描方向的指示性,如图 10 (a) 中黑色圆圈所示。综上所述,熔池熔化状态类别能够准确反映工艺参数的变化。

2.3 时间序列预测

图 11 展示了模型在测试集中对

于熔池类别预测的部分结果。因为前半部分主要是 1 类、2 类、3 类和 4 类可能是隐藏的异常值,模型在训练过程中更多地关注多数类别,所以 3 类、4 类预测效果相对较差;后半部分 3 类、4 类集中,激光在转向时功率有所减小,所以会出现部分的 2 类熔池。此外,1 类可能是隐藏的异常值,所以 1 类的预测结果相对较差。整体上,该模型预测错误的数目相对较少,这表明模型对于熔化类别的预测具有较高准确性。

为了更全面地评估模型的性能,图 12 进一步通过混淆矩阵验证了模型的性能,其中 4 个类别平均准确

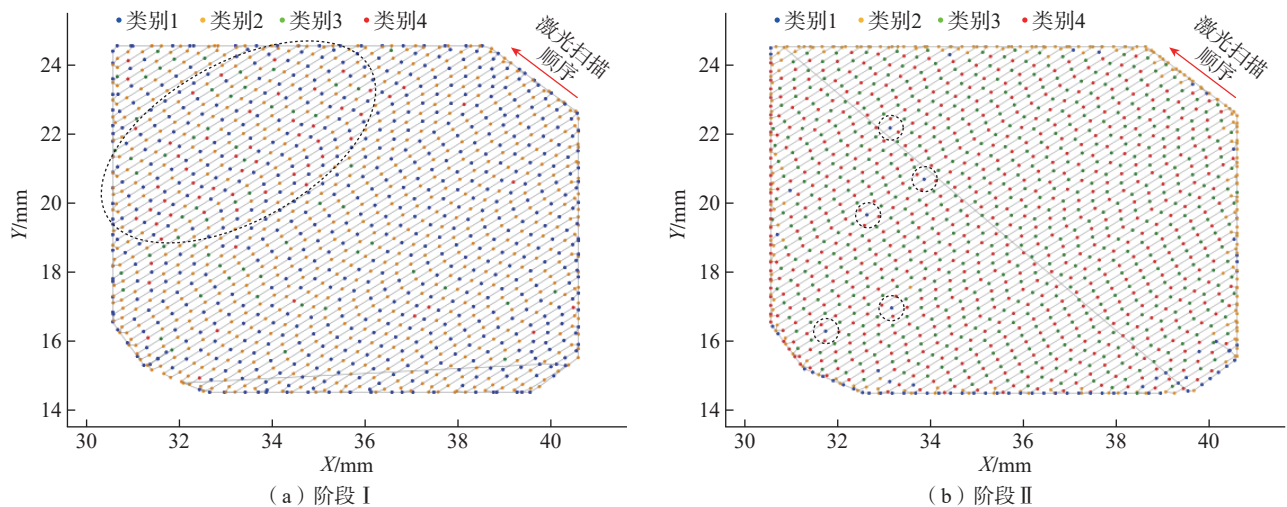


图 9 聚类结果在扫描路径上的映射

Fig.9 Mapping of clustering results on scan paths




图 10 局部聚类结果及对应的工艺参数

Fig.10 Local clustering results and corresponding process parameters




图 11 熔化类别预测结果

Fig.11 Prediction results of melting category

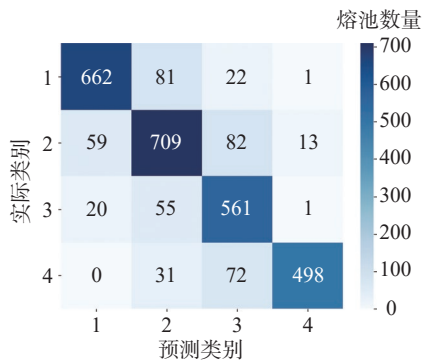


图 12 熔化类别预测混淆矩阵

Fig.12 Prediction confusion matrix of melting category

率为 85.92%， $F1$ 分数达到 85.12%， $mRecall$ 达到 84.88%。评估结果充分展现了时间序列模型在预测具有规律性数据时的显著优势。这一研究为熔池动态监测提供了一种全新且有效的方法，为进一步研究提供了有益的参考。

3 结论

本文以 Inconel 625 航空材料为对象，针对该材料的 SLM 成形过程，提出了基于机器学习的粉末熔化过程熔池熔化状态类别预测方法，并通过实例分析，验证了该方法的预测有效性和较高的准确率，得出以下结论。

(1) 进行了基于 U-net 神经网络的熔池图像分割与轮廓提取。通过熔池 ROI 设置，减少了飞溅的影响。通过 U-net 神经网络和 Canny 算子分别实现了熔池形貌捕获和轮廓提取， $mIoU$ 达到 89.68%， mPA 达到 89.94%， $mRecall$ 达到 88.94%，实现了

较高准确度的熔池图像分割和轮廓提取。

(2) 针对所提取熔池轮廓，开展了熔池运动特征提取与聚类分析。以运动方向线为起始，将熔池质心到边界的距离矢量作为熔池运动特征。通过 PCA 对数据进行降维，并应用 k -means 算法进行聚类分析，轮廓系数为 0.51。结果表明，在相同扫描策略下，熔池熔化状态可分为 4 类。不同的工艺参数对应不同的熔化类别，利用 36 维运动特征可有效反映不同参数所产生的熔化状态差异。

(3) 将工艺参数作为输入特征，进行了基于 LSTM 模型的熔池熔化状态类别时间序列预测。4 种类别的平均准确率为 85.92%， $F1$ 分数达到 85.12%， $mRecall$ 达到 84.88%。结果表明，熔池熔化状态类别预测结果准确度高，可用于 SLM 成形前对熔化状态类别进行预评估，为 SLM 在线监测和成形工艺参数优化提供参考。

本文研究也为人工智能技术在 SLM 成形质量预测与调控中的应用提供了有益的探索。

参考文献

[1] DUAN X Y, LONG T, ZHU K P, et al. Formation mechanism of pore defects and surface ripples under different process parameters via laser powder bed fusion by numerical simulation and experimental verification[J]. The International Journal of Advanced Manufacturing Technology, 2024, 135(1): 883–898.

[2] PENG C, XU Q H, DING L, et al. Novel insights into abrasive flow machining uniformity for SLM channels[J]. International Journal of Mechanical Sciences, 2024, 262: 108726.

[3] ZOU Z Y, ZHANG K, ZHU Z G, et al. Multi-sensor monitoring of powder melting states via melt pool optical emission signals during laser-based powder bed fusion[J]. Optics Laser Technology, 2024, 169: 109880.

[4] 陈香媛, 韦辉亮, 刘婷婷, 等. 基于熔池光信号的激光粉末床熔沉积缺陷在线监测与诊断[J]. 中国激光, 2024, 51(10): 146–159.

CHEN Xiangyuan, WEI Huiliang, LIU

Tingting, et al. In-situ monitoring and diagnostics for deposition defects in laser powder bed fusion process based on optical signals of melt pool[J]. Chinese Journal of Lasers, 2024, 51(10): 146–159.

[5] YAO M P, SHENG J, KONG F R, et al. A multi-sensor based online monitoring system for laser hot-wire surface cladding process[J]. Optics & Laser Technology, 2024, 177: 111074.

[6] 李子帆, 蔡振华, 刘琦, 等. TC17 钛合金激光熔覆熔池实时监测算法研究[J]. 航空制造技术, 2024, 67(4): 110–117.

LI Zifan, CAI Zhenhua, LIU Qi, et al. Research on real-time monitoring algorithm of TC17 titanium alloy laser cladding melting pool[J]. Aeronautical Manufacturing Technology, 2024, 67(4): 110–117.

[7] 段现银, 陈昕悦, 向峰, 等. 数字孪生驱动的金属选择性激光熔融成形过程在线监控[J]. 计算机集成制造系统, 2021, 27(2): 403–411.

DUAN Xianyin, CHEN Xinyue, XIANG Feng, et al. Digital twin-driven on-line monitoring method of metal selective laser melting building process[J]. Computer Integrated Manufacturing Systems, 2021, 27(2): 403–411.

[8] JOHNSON N S, VULIMIRI P S, TO A C, et al. Invited review: Machine learning for materials developments in metals additive manufacturing[J]. Additive Manufacturing, 2020, 36: 101641.

[9] KWON O, KIM H G, HAM M J, et al. A deep neural network for classification of melt-pool images in metal additive manufacturing[J]. Journal of Intelligent Manufacturing, 2020, 31(2): 375–386.

[10] WANG Y H, HU K X, LI W D, et al. Prediction of melt pool width and layer height for laser directed energy deposition enabled by physics-driven temporal convolutional network[J]. Journal of Manufacturing Systems, 2023, 69: 10–17.

[11] RAJ A, HUANG D L, STEGMAN B, et al. Modeling spatial variations in co-axial melt pool monitoring signals in laser powder bed fusion[J]. Journal of Manufacturing Processes, 2023, 89: 24–38.

[12] ZHANG Z Y, LIU Z C, WU D Z. Prediction of melt pool temperature in directed energy deposition using machine learning[J]. Additive Manufacturing, 2021, 37: 101692.

[13] 李春凯, 王嘉昕, 石玕, 等. GTAW 熔池激光条纹动态行为与熔透预测方法研究[J]. 机械工程学报, 2024, 60(6): 236–244.

LI Chunkai, WANG Jiixin, SHI Yu, et

al. Study on the dynamic behavior of GTAW melt pool laser streak and penetration prediction method[J]. Journal of Mechanical Engineering, 2024, 60(6): 236–244.

[14] WANG Q S, LIN X, DUAN X Y, et al. Gaussian process classification of melt pool motion for laser powder bed fusion process monitoring[J]. Mechanical Systems and Signal Processing, 2023, 198: 110440.

[15] FOX J C, LANE B M, YEUNG H. Measurement of process dynamics through coaxially aligned high speed near-infrared imaging in laser powder bed fusion additive manufacturing[C]//Thermosense: Thermal Infrared Applications XXXIX. Anaheim: SPIE, 2017: 1021407.

[16] LANE B, YEUNG H. Process monitoring dataset from the additive manufacturing

metrology testbed (AMMT): “Three-dimensional scan strategies”[J]. Journal of Research of the National Institute of Standards and Technology, 2019, 124: 1–14.

[17] SINGH C V, BAGUI S, SAHOO B K, et al. Comparison of low cycle fatigue behaviour of additively manufactured and wrought Inconel 625 alloys[J]. Materials Science and Engineering: A, 2024, 903: 146682.

[18] FANG Q H, TAN Z B, LI H, et al. In-situ capture of melt pool signature in selective laser melting using U-net-based convolutional neural network[J]. Journal of Manufacturing Processes, 2021, 68: 347–355.

[19] LIN X, WANG Q S, FUH J Y H, et al. Motion feature based melt pool monitoring for selective laser melting process[J]. Journal of Materials Processing Technology, 2022, 303: 117523.

[20] ANDREAU O, KOUTIRI I, PEYRE P, et al. Texture control of 316L parts by modulation of the melt pool morphology in selective laser melting[J]. Journal of Materials Processing Technology, 2019, 264: 21–31.

[21] 刘玉德, 贾世龙, 石文天, 等. 激光重熔对TC4选区激光熔化单熔道成形质量的影响[J]. 应用激光, 2024, 44(6): 10–19.

LIU Yude, JIA Shilong, SHI Wentian, et al. Effect of laser remelting on single pass quality of TC4 selective laser melting[J]. Applied Laser, 2024, 44(6): 10–19.

通信作者: 朱锟鹏, 教授, 博士, 研究方向为精密制造与智能制造。

Prediction of Melt Pool Category in Selective Laser Melting Process Based on Machine Learning

DUAN Xianyin¹, PENG Kewei¹, ZHU Kunpeng^{1,2}, WANG Qisheng², PENG Kuanbao¹

(1. Key Laboratory of Metallurgical Equipment and Control Technology, Ministry of Education, Wuhan University of Science and Technology, Wuhan 430081, China;

2. Institute of Intelligent Machines, Hefei Institutes of Physical Science, Chinese Academy of Sciences, Changzhou 213164, China)

[ABSTRACT] As one of the most practical metal laser additive manufacturing technologies, selective laser melting (SLM) has been widely adopted in aviation, aerospace, and energy sectors due to its advantages in rapid forming of complex thin-walled components. However, the consistency issue during the forming process still limits further improvements in component quality, which is closely related to defects arising from the constant variations in melt pool size and shape. Therefore, to more effectively monitor the dynamic changes of the melt pool, a method for predicting melt pool melting state categories based on extraction of high-dimensional melt pool motion features and a long short-term memory (LSTM) model is proposed. Firstly, the U-net model is utilized to extract melt pool morphology features from melt pool images, and the distances from the melt pool centroid to its boundary are calculated and unfolded along the contour into high-dimensional vectors to represent the motion features of the melt pool. Subsequently, the *k*-means clustering algorithm is applied to perform clustering analysis on the melt pool motion features under different process parameters, leading to the construction of four categories of melt pool melting states. Time series prediction of the melting state categories is then conducted using the LSTM model. Taking the SLM process of Inconel 625, a typical high-temperature alloy material for aviation, as an example, verification of melt pool state category prediction was conducted. The results demonstrate a prediction accuracy of 85.92%, providing a novel approach and insight for real-time monitoring and quality control in the SLM process.

Keywords: Inconel 625; Selective laser melting (SLM); Motion feature of melt pool; *k*-means clustering algorithm; Time series prediction

(责编 七七)