文章编号:1001-5078(2021)12-1576-10

·激光应用技术 ·

# SLM 成型件表面球化程度表征方法及等级检测

蒋国璋1,邱 鹤1,林 昕1,刘江昊2

(1. 武汉科技大学机械自动化学院,湖北 武汉 430081;2. 武汉科技大学材料与冶金学院,湖北 武汉 430081)

摘 要:球化现象是选区激光熔化(SLM)成型过程中最常发生的缺陷,同时影响了最终成型部件的疲劳寿命和物理性能。合理控制部件成型过程中球化现象的发生,对维持成型过程的持续进行以及获得高质量的成型部件具有重大意义。本文在研究 SLM 成型过程中部件表面球化特征提取方法的基础上提出了球化程度表征方法,并通过正交实验验证了球化程度表征方法的有效性,建立了球化程度与激光能量密度之间的关联关系。同时对球化程度等级做了界定,最终构建了深度卷积神经网络(CNN)模型自动识别部件表面球化程度等级,以辅助实验及生产人员做出相应的决策。模型识别结果表明,在小的图像分割集上,网络识别精度达到了 96.4 %,当在所采集的全局显微图像集上,其识别精度达到了 100 %,取得了良好的识别效果。本研究将为 SLM 成型过程中成型质量的实时控制提供有效实现途径。 关键词:选区激光熔化;球化现象;特征提取;球化程度等级;CNN 网络

中图分类号:TN249 文献标识码:A DOI:10.3969/j.issn.1001-5078.2021.12.005

## Characterization method and grade detection of surface balling degree of SLM formed parts

JIANG Guo-zhang<sup>1</sup>, QIU He<sup>1</sup>, LIN Xin<sup>1</sup>, LIU Jiang-hao<sup>2</sup>

School of Mechanical Automation, Wuhan University of Science and Technology, Wuhan 430081, China;
 School of Materials and Metallurgy, Wuhan University of Science and Technology, Wuhan 430081, China)

**Abstract**: Balling phenomenon is the most common defect in selective laser melting (SLM) forming process, which affects the fatigue life and physical properties of the final formed part. Reasonable control of the occurrence of balling phenomenon is of great significance to maintain the continuous forming process and obtain high-quality formed parts. In this paper, a balling degree characterization method was proposed based on the study of balling feature extraction method for parts surface during SLM forming process. The effectiveness of the method through orthogonal experiments is verified, and the correlation between balling degree and laser power density was also established. Moreover, the grade of balling degree was defined, and finally a deep convolutional neural network (CNN) model was constructed to automatically identify the grade of balling degree of the part surface to assist the experiment and production personnel to make corresponding decisions. The recognition results showed that the network recognition accuracy reaches 96.4 % on the small segmentation image set, and the recognition accuracy reaches 100 % on the global microscopic image set, which achieved a good recognition effect. This paper will provide an effective way to realize real-time control of forming quality in the SLM forming process.

Keywords: SLM; balling phenomenon; feature extraction; the grade of balling degree; CNN

作者简介:蒋国璋(1965 - ),男,教授,博士,主要研究方向为智能制造。E-mail:whjgz@wust.edu.cn

**基金项目:**国家自然科学基金项目(No. 51805384;No. 51875379);冶金装备及其控制教育部重点实验室开放基金项目 (No. 2018B08)资助。

**通讯作者:**林 昕(1987 - ),女,副教授,博士,主要研究方向为增材制造与在线监测。E-mail:xinlin@wust.edu.cn 收稿日期:2021-01-04;修订日期:2021-01-30

#### 1 研究背景

选区激光熔化技术 (selective laser melting, SLM) 作为一种新的快速原型制造技术,能够利用分 层制造原理根据零件的三维 CAD 模型直接从金属 粉末制造出致密的实体零件,而不受零件的形状和 结构的限制。相比于传统的加工技术具有时间成本 低、能够成型复杂薄壁零件以及无需后处理等优点, 已经被广泛应用到航空航天、生物医疗和其他工程 领域<sup>[1]</sup>。然而,SLM 是一个复杂的物理和化学冶金 过程,其成型过程涉及多种形式的热、力和动量传 递。在激光扫描过程中,熔池在表面张力的作用下 具有收缩成球的趋势,球化现象随即产生。

球化现象的发生在单层内宏观表现为金属球团 聚集,造成成型件表面粗糙,且金属球之间存在大量 间隙。在连续成型的过程中,虽然下一层铺粉可以 获得一个平坦的表面,但是粉末难以完全填充金属 球体之间的间隙,激光扫描之后这些间隙留存于零 件内部,形成不规则形状的锁孔。与传统制造的零 件类似,孔隙的存在降低了零件致密度,严重影响了 零件的力学性能,阻碍了高强度和抗疲劳应用<sup>[2]</sup>。 目前,对于成型过中可能出现的内部锁孔缺陷,一般 是对成型后的零件使用超声检测<sup>[3]</sup>、工业 CT 检 测<sup>[4]</sup>、X射线检测<sup>[2]</sup>等无损检测方法进行离线检 测,随后使用热等静压<sup>[5]</sup>等方法进行降低或消除。 这种被动性检测及后处理方法不仅耗时费力,而且 不能保证处理后的部件内部孔隙完全消除并达到使 用要求,对于成型过程中锁孔缺陷发生及累积也更 是无能为力。实际上,SLM 成型过程受大量参数支 配<sup>[6]</sup>,获得好的成型质量部件的关键是了解工艺参 数如何影响成型质量,从而从源头上控制孔隙缺陷 的产生。Aboulkhair 等<sup>[7]</sup>人指出,锁孔是由球化现 象以及粉末熔化凝固的体积收缩效应引起的,通过 改变扫描策略,在每层中进行双重扫描可以有效减 少锁孔的产生。Lee 等<sup>[8]</sup>人采用了基于 FDM 的商 业软件 Flow3D 来模拟 SLM 过程。他们的研究表 明,高扫描速度会导致球化现象,这是孔隙形成的间 接原因。而孔隙的大小和数量也可通过优化工艺参 数显著降低<sup>[9]</sup>。球化现象的发生通常也会导致下 一层铺粉不均匀,部分区域粉末厚度大于理论厚度。 Wu 等<sup>[10]</sup>研究表明,较大的粉层厚度是导致层间孔 隙的关键因素,这是因为激光能量不足以完全熔化 金属粉末,从而在相邻两层之间的界面诱导层间孔 隙。可以发现,球化现象与工艺参数及成型质量之 间有着密切的联系,合理的控制工艺参数可以避免 球化现象的发生,从而获得低孔隙率高致密度的零件。然而优化工艺参数的获取通常需要进行大量实验,这是一个昂贵和繁琐的过程。实际打印过程中,这些参数对环境敏感,且相互影响,导致实际获取的零件孔隙率和致密度未达到理论预期。因此,为了有效控制部件的成型质量,避免成型过程中出现大量锁孔缺陷以及粗糙的表面形貌,有必要在成型过程中对球化现象的发生进行监测和控制。然而目前大部分研究只着眼于如何优化工艺参数提高 SLM 成型质量,对球化现象的研究也局限于形成机理<sup>[11-12]</sup>和影响因素<sup>[13]</sup>方面,而忽略了在线监测控制的可行性。

作为联系工艺参数与成型质量的中间变量,球 化现象不仅反映了成型后零件内部孔隙缺陷以及表 面粗糙度等成型质量问题,同时也是工艺参数改变 的最直接影响对象,其出现在零件逐层打印表面,这 给逐层监测控制提供了可能。而建立这三者之间联 系的基础是定义什么是球化程度。球化程度是零件 成型过程中成型层内球化颗粒出现的数量、大小的 度量,直观反映了零件打印过程中成型层内的表面 质量,同时也间接反映了最终部件的内部孔隙的发 生。因此,有效识别成型层内球化程度等级是判断 最终零件成型质量的关键。为获得高质量的成型部 件,目前亟需解决的问题是球化程度的表征方法和 球化程度等级检测识别方法问题。

本文在研究 SLM 成型过程中部件表面球化特 征提取方法的基础上提出了球化程度表征方法。并 通过正交实验验证了表征方法的有效性,同时建立 了球化程度与激光能量密度之间的关联关系。最后 对球化程度等级进行了分级界定,构建了基于 SLM 成型件表面球化程度等级检测的 CNN 模型,旨在对 成型过程中部件表面球化程度等级进行自动检测, 辅助实验及生产人员做出相应的决策,并在必要时 刻对工艺参数进行调控,以获得低孔隙率高致密度 以及低表面粗糙度的零件。

#### 2 实现方法

2.1 球化特征提取及球化程度表征方法

近年来,随着深度学习技术的发展,应用深度神 经网络的方法在工业缺陷检测及特征提取领域逐渐 兴起。本节,我们将采用全卷积神经网络(FCN)进 行成型件表面显微图像的球化特征提取。有关 FCN 的工作,Long 等<sup>[14]</sup>人已经做了大量研究。不 同于 CNN 网络,FCN 将最后的全连接层替换为卷积 层,训练一种端到端、点到点的网络,以实现像素级 分割。经过训练优化的 FCN 模型,球化特征从复杂 背景中分离出来。如图 1 所示为最终的分割结果。



图 1 FCN 模型球化特征提取结果 Fig. 1 Balling feature extraction results of FCN model

由图 1(a)特征提取可视化图像可以发现,几乎 所有的球化颗粒均被提取出来,这意味着 FCN 能够 有效的提取部件表面的球化特征。而图 1(b)为所 对应的特征提取结果标签图,其中球化特征区域呈 现灰色(像素值为1),背景呈现黑色(像素值为0)。 则单个部件表面的球化程度表征公式可由下式 给出:

$$Q = \frac{1}{N} \sum_{k=1}^{N} \left( \frac{\sum_{i=1}^{H} \sum_{j=1}^{W} P_{ij}}{H \times W} \right)$$
(1)

式中,Q为单个部件表面的球化程度; P<sub>ij</sub>为单个小 图像在位置(*i*,*j*)处的像素值; H和W分别为所采集 显微图像的高和宽; N为单个部件表面均匀采集的 显微图像数量。

#### 2.2 正交实验

本实验采用4因素3水平的L,(3<sup>4</sup>)的正交实验 表,并以计算的球化程度为优化指标验证球化程度表 征方法的有效性。所有实验均在HK-M250平台上进 行,成型材料为气雾化316L不锈钢金属粉末。实验 分两组进行,扫描方式均为简单栅格扫描,其中第一 扫描方式扫描角度为45°,第二扫描方式扫描角度为 30°。实验完成后,用体式显微镜(ZXL-300,上海正 晞仪器设备有限公司)均匀采集各试件表面显微图像 (放大倍率400×),并计算各试件表面球化程度。如 表1所示为正交实验方案参数设置及结果,表中xly 代表两种扫描方式下所对应的结果。

采用正交试验的方差分析方法对试验结果进行 分析,得表2所示分析结果。

		因	素		试验结果
计心口	A. 激光功率 P/W	B. 扫描速度 v/(mm・s <sup>-1</sup> )	C. 扫描间距 h/mm	D. 层厚 d/mm	r赴仇田南 (M
诋验亏		列	号		
	1	2	3	4	
1	1(150)	1(50)	1(0.15)	0.05	1. 22   2. 54
2	1(150)	2(100)	2(0.20)	0.05	1. 24   2. 87
3	1(150)	3(150)	3(0.25)	0.05	1. 71   3. 44
4	2(175)	1(50)	2(0.20)	0.05	1. 31   4. 34
5	2(175)	2(100)	3(0.25)	0.05	1.58 5.09
6	2(175)	3(150)	1(0.15)	0.05	2. 11   4. 24
7	3(200)	1(50)	3(0.25)	0.05	1.68 4.44
8	3(200)	2(100)	1(0.15)	0.05	2. 22   5. 96
9	3(200)	3(150)	2(0.20)	0.05	4. 21   5. 45
$T_1$	4. 17   8. 85	4. 21   11. 32	5. 55   12. 74	1	
$T_2$	5.00 13.67	5.04 13.92	6.76 12.66	/	
$T_3$	8. 11   15. 85	8.03   13.13	4.97 12.97	/	
$\bar{x}_1$	1. 39   2. 95	1.40 3.77	1.85 4.25	/	17, 29 29, 27(T)
$\overline{x}_2$	1.67 4.56	1.68 4.64	2. 25   4. 22	1	17. 20130. 57 (1)
<i>x</i> <sub>3</sub>	2.7015.28	2.68 4.38	1.6614.32	/	
R	1. 31   2. 33	1. 28 0. 87	0. 59 0. 10	/	]
S	2. 8761   8. 5539	2. 6913   1. 1845	0. 5561   0. 0173	0. 7885   0. 8413	

### 表1 实验参数设置及结果

Tab. 1 Experimenta	l parameter	setting a	and result
--------------------	-------------	-----------	------------

#### 表2 方差分析结果

Tab. 2 Results of variance analysis

因素	$SS( \times 10^{-4})$	df	$MS( \times 10^{-4})$	F	$F_{0.05(2,2)}$
激光功率(A)	2. 8761   8. 5539	2	1. 4381   4. 2770	3. 65   10. 17	19.00
扫描速度(B)	2. 6913   1. 1845	2	1. 3457   0. 5922	3. 41   1. 41	/
扫描间距(C)	0. 5561   0. 0173	2	0. 2781   0. 0087	0.7110.02	/
误差	0. 7885   0. 8413	2	0. 3942   0. 4207	/	/
总 计	6. 912   10. 597	8	/	/	/

F 检验结果表明, 三个因素的 F 值均小于 F<sub>0.05(2,2)</sub>, 因此三个因素对部件表面球化程度的影响都不显著。考虑球化程度随各因素水平的变化趋势, 如图 2 所示。两种扫描方式下, 激光功率的减小显著减轻了部件表面的球化程度, 且扫描速度在第1 水平时球化程度最小。与第一扫描方式扫描间距在水平 3 处取得最小值不同, 第二扫描方式下, 扫描间距水平的变化对球化程度几乎没影响。因此, 两种扫描方式下, 激光功率在第1 水平、扫描速度在第1 水平、扫描间距在第3 水平

时,球化程度最小,此时各因子之间的最优组合为 A<sub>1</sub>B<sub>1</sub>C<sub>3</sub>,即激光功率为150 W,扫描速度为50 mm/ s,扫描间距为0.25 mm,层厚为0.05 mm,激光能 量密度为240 J/mm<sup>3</sup>。



Fig.2 The variation trend of balling degree with the level of each factor 在保持其他设置不变的情况下,利用最优组合 工艺参数在两种扫描方式下成型同尺寸试件。经体 式显微镜采集试件表面显微图像发现,成型件表面 光洁,熔道轨迹连续,搭接良好,没有明显的球化现 象。局部显微图像如图3所示,此时球化程度分别





为 0.75 % 和 1.46 %, 均小于相同扫描方式下其他 工艺参数组合所获得的球化程度。因此, 实验结果 验证了球化程度指标的有效性, 同时也间接说明了 球化程度表征方法的正确性。

2.3 球化程度与激光能量密度之间的关联关系

工艺参数的改变,最终影响的是激光能量的输入大小。为整体衡量能量输入与球化程度的作用关系,引入激光能量密度模型<sup>[15]</sup>:

$$E = \frac{P}{V \cdot H \cdot D} \tag{2}$$

式中,E 为激光能量密度( $J/mm^3$ );V 为激光扫描速度(mm/s);H 为扫描间距(mm);D 为层厚(mm)。

如图 4 所示,为成型件表面球化程度随激光能 量密度变化示意图。两种扫描方式下,均呈现出相 同的变化趋势。当激光能量密度为 150 J/mm<sup>3</sup> 时, 球化程度存在极小值,此时激光功率较小为150W, 但相应的激光扫描速度也相对较小为100 mm/s,较 小的激光扫描速度增加了激光的停留时间,使熔池 中的金属粉末能够充分融化,润湿性良好,提高了熔 池的稳定性。此时球化现象主要是由激光的长时间 停留使熔池中的金属液滴飞溅造成的。当激光能量 密度为133.33 J/mm<sup>3</sup>和266.67 J/mm<sup>3</sup>时,球化程 度存在极大值,我们称之为第一极大值点和第二极大 值点。此时激光功率较大为200 W,但在第一极大值 点中,激光扫描速度也较大,达到了150 mm/s,使激 光扫描的停留时间缩短,较小的激光能量密度不足以 充分熔化金属粉末,同时熔池的温度也相对较低,金 属熔滴黏性增大,趋向于大尺寸球化颗粒的产生。而 第二极大值点中,激光扫描速度为100 mm/s,相较于 极小值点,具有相同的激光扫描速度,但此时激光功 率更大,熔池中金属液滴飞溅现象更加剧烈。当激光 能量密度从 266.67 J/mm<sup>3</sup> 增大到 400 J/mm<sup>3</sup> 时,虽 然在一定程度上减小了球化现象的发生,这主要 是由较大的激光能量输入,使熔池面积扩大,进一 步对已成型的熔化道重熔造成的。但当激光能量 密度进一步增大时,导致激光直接照射区域内热 量大量累积,较高的熔池温度使熔体蒸发并迅速 膨胀,在反冲压力的作用下从熔池喷出形成金属 射流,从而进一步加剧部件表面的球化程度。从 以上分析可知,在激光能量密度从133.33 J/mm<sup>3</sup> 到 266. 67 J/mm<sup>3</sup> 的变化过程中,存在某一最优的 激光能量密度,此时部件表面的球化程度最小。 由2.2节的分析可知,最优的激光能量密度为  $240 \text{ J/mm}^3$ 



2.4 基于 CNN 的球化程度等级检测方法

CNN 是深度神经网络的一种,具有强大的特征 学习能力,目前已被广泛应用于自然语言处理、图像 识别和目标检测等领域<sup>[16]</sup>。在本文中,我们构建基 于深度 CNN 网络的分类模型来识别部件表面的球 化程度等级。通常,CNN 模型的性能是由数据集、 网络结构及训练方法共同决定。

#### 2.4.1 数据集准备

图像数据集是由 2.2 节实验获取。由图 4 可 知,两种扫描方式下试件表面球化程度具有相同的 变化趋势,故最终选择第二扫描方式下成型部件表 面显微图片作为数据集,单个显微图片分辨率大小 为 2592 × 1944 像素。同时将部件球化程度等级标 记为三个类别:轻微球化(试件 1、2 和 3),中度球化 (试件 4、6 和 7)以及重度球化(试件 5、8 和 9),其 中单个显微图像的标签与部件球化程度等级保持一 致。如图 5 所示为部件表面不同球化等级的局部显 微图像。很明显,部件表面显微图像决定了其球化 程度等级,这是因为不同工艺参数条件下所成型的 部件表面球化现象有明显的区别。虽然在高分辨率 图像上训练可以提供更好的分类精度,但考虑计算 平台 GPU 性能及时间成本,将所采集的显微图像分 割并转化成 600 × 600 像素的小灰度图像块,生成最 终的训练样本(其中训练集有 15311 样本,验证集有 1702 样本,测试集有 2103 样本),其中分割后的小 图像块标签与采集的显微图像标签保持一致。



3 二 一件环化性反守坂即件衣面向印亚版图称 Fig. 5 Local microscopic images of three parts with different grade of balling degree

#### 2.4.2 深度 CNN 网络结构

用于分类问题的深度 CNN 网络通常由卷积层、 池化层和全连接层组成。如图 6 所示为本文最终的 网络结构图,其中缩小输出特征映射只在池化层,且 卷积层和全连接层的激活函数均为 ReLU 函数,输 出层激活函数为 Softmax 函数。其工作流程是卷积 层通过一组滤波器对输入的图像执行滤波并生成一 组特征映射,然后传递给池化层进行子采样降维,最 后将降采样后的小维度特征传递给全连接层进行分 类并输出图像的类别。当存在多个卷积和池化层 时,会进行多次特征提取和降维。



图 6 部件表面球化程度分类模型示意图

Fig. 6 Schematic diagram of classification model of component surface balling degree

#### 1581

#### 2.4.3 训练方法

深度 CNN 网络采用有监督学习方法进行训练, 包括前向和反向传播两个阶段。前向传播阶段是将 输入图像映射为输出类别向量的过程。当输出预测 类别向量与真实向量不同时,则会将输出误差进行 反向传播,从而迭代更新网络的权重参数。通常应 用于评估 CNN 输出误差的函数为交叉熵损失函数, 其目标是最小化损失,以获得最优的网络参数,毕竟 网络的性能很大程度上取决于训练有素的参数。

#### 3 结果与讨论

本节我们将介绍不同网络结构及参数设置进行 实验的结果。分析环境为 python 3.7.3,且所有实 验均在 windows 系统下拥有 12 × 2.2 GHz Intel I7 – 8750H 处理器以及 NVIDIA GTX 1050Ti GPU 的平 台上运行,其目的是优化 CNN 网络结构及参数,以 获得最高的验证精度,并对新数据产生较低的泛化 误差。

3.1 输入大小

输入图像尺寸是影响 CNN 性能的重要因素,它 同时影响了网络的训练精度和时间。大的输入尺寸 虽然能够提供更多的图像信息,但是同时也需花更 多的时间去学习网络参数,对计算平台的要求也高。 小的输入尺寸能够提高网络速度,但同时也因为图 像压缩造成的特征信息丢失降低网络精度。如表 3 所示,300 × 300 像素的图像是通过 600 × 600 像素 的图像压缩得到的,在相同的网络结构及参数条件 下,其训练速度明显加快,但是其验证精度却仅为 30.5%,远低于 600 × 600 像素图像输入下的精度 74.2%。这是因为在卷积和池化层的作用下,小尺 度的图像特征更容易被频繁的降采样导致特征丢 失。因此,考虑实验精度,在接下来的实验中我们采 用的图像输入尺寸为 600 × 600 像素。

表3 不同图像大小输入所对应的实验参数及结果

1	<u> </u>	<b>P</b>		1	1.	C	1.0	Υ <u></u> .	•	•	•
1.91	h 1	Hyperiment	naramotore	and	roculte	tor	dit	toront	innut	image	C170
1 au	J. J.	LADUITHUIL	Darameters	anu	TOSUIIS	101	un	1010III	mput	Innagu	SILU
		1	1						1	0	

网络参数	模型号	输入大小	时间(h:m:s)	验证精度/%
Epoch:50				
Batchsize:8	1	$600 \times 600 \times 1$	6:00:36	74.2
Learning rate: 0.0001				
Pooling size: $2 \times 2$				
Conv: 3 × 3/16, 3 × 3/32, 3 × 3/64, 3 × 3/128, 3 × 3/256	2	$300 \times 300 \times 1$	1:51:33	30. 5
FC:256,32				

#### 3.2 网络结构层次

如表4所示,我们采用了6和7个卷积层,全连 接层的维度也做了相应的改变以进行对比实验。当 增加一个卷积层时,相比于模型1的74.2%的验证 精度,模型3获得了79.4%的验证精度,但两者运 行时间几乎相同。这主要是因为增加的卷积层具有 更多的卷积核,在一定程度上能够提取到更多的图 像特征,有助于网络的特征识别及分类。但是当进 一步增加卷积层个数时,相比于模型4,模型5的验 证精度则更低,仅为79.5%,唯一的可以解释的原 因是过拟合。随着模型复杂度的增加,其对训练数 据集的拟合性增强,但对验证数据集的性能下降,通 用性变差。如图7(c)、7(d)所示,为模型5的精度 及损失变化图,也证明了模型的过拟合。当改变全 连接层的维度时,模型4获得了比模型3更高的验 证精度,达到了79.7%,但网络的运行时间有所增 加。卷积神经网络中,全连接层是将学到的分布式 特征表示映射到样本标记空间,其维度的增加有助 于特征的组合,提高模型的泛化性能。但是当其维 度进一步增加时,网络运行时间则成比例增加,会给 计算平台带来负担。综上所述,我们最终确定模型 4的结构为深度 CNN 网络的最终结构。

表4 不同网络结构所对应的实验参数及结果

1	'ab. 4	Experimenti	ing paramet	ers and	l results	with	different	network	architectures
---	--------	-------------	-------------	---------	-----------	------	-----------	---------	---------------

网络参数	模型号	网络结构	时间 (h:m:s)	验证精度 /%
Epoch:50	3	Conv: 3 × 3/16, 3 × 3/32, 3 × 3/64, 3 × 3/128, 3 × 3/256, 3 × 3/512 FC: 256, 32	5:57:40	79.4
Batchsize:8 Learning rate:0.0001 Pooling size:2 × 2	4	Conv: 3 × 3/16, 3 × 3/32, 3 × 3/64, 3 × 3/128, 3 × 3/256, 3 × 3/512 FC:512,64	6:27:08	79.7
Input Size: $600 \times 600 \times 1$	5	Conv:3×3/16,3×3/32,3×3/64,3×3/128,3×3/256,3×3/512,3×3/1024 FC:512,64	6 : 39 : 19	79.5





3.3 正则化

如图 7(a)、(b)所示,虽然模型 4 取得了良好的验证精度,但过拟合现象仍然存在。目前,普遍用于缓解和减轻 CNN 网络过拟合问题的方法是L2 正则化和 Dropout。其中,L2 正则化实际上是通过加入一个与原损失函数互相牵制的部分,来抑制过大的权重参数导致的过拟合,而 Dropout 是在网络训练期间随机失活部分神经元,避免模型严重依赖一个或几个神经元的输出。考虑模型 4 存在的过拟合问题,我们将测试 L2 正则化参数 ( $\lambda = 0.01$ )和 Dropout 率( $\gamma = 0.25$ )的不同组合对 CNN 网络泛化性能的影响。如表 5 所示,为具体的实验方案设计及实验结果。其中 Conv | FC 是指在相应的卷积层和全连接层存在 L2 正则化和 Dropout 项。

表 5 L2 正则化参数和 Dropout 率的不同组合所对应的实验参数及结果 Tab. 5 Experimenting parameters and results with different combinations of L2 regularization parameters and Dropout rate

		0 1	-		
网络参数	模型号	L2 正则化(Conv FC)	Dropout(Conv FC)	时间(h:m:s)	验证精度/%
	6	0.01   0.01	0. 25   0. 25	7:27:36	72.3
	7	0.01   0.01	0.25	7:26:11	73.2
	8	0.01   0.01	10.25	6:51:09	79.0
Epoch:50	9	0. 01   0. 01		6:49:46	81.1
Batchsize:8	10	0.01	0. 25   0. 25	7:05:42	79.6
Learning rate:0.0001	11	0.01	0.25	7:04:31	78.9
Pooling size: $2 \times 2$	12	0.01	10.25	6:26:02	79. 2
Input Size: $600 \times 600 \times 1$	13	0.01		6:27:48	79.5
Conv: $3 \times 3/16$ , $3 \times 3/32$ ,	14	0.01	0. 25   0. 25	7:26:12	79. 7
$3 \times 3/64, 3 \times 3/128,$	15	0.01	0.25	7:24:16	82. 1
3 × 3/256,3 × 3/512	16	0.01	10.25	6:48:56	82.6
FC:512,64	17	0.01		6:48:29	81.0
	18		0. 25   0. 25	7:05:40	78.8
	19		0.25	7:03:39	78.5
	20		10.25	6:26:28	79.0

很明显,相比于其他组合,模型15和模型16 获得了较高的验证精度,分别达到了82.1%和 82.6%。如图8(a)、(b)、(c)、(d)所示,相较于 模型4,两者的过拟合问题有所减轻。然而,直到 50个 epoch,两模型均没有收敛,但是模型 15 获得 了更好的拟合效果,虽然其训练时间长且验证精 度比模型 16 稍小。为了达到更好的拟合效果以 及获得更高的精度,模型15 被训练了250个 epoch (模型21),如图8(e)、(f)所示,模型在大约100 个 epoch 才收敛,此时验证精度为 85.6 %。因此, 模型15被选为部件表面球化程度等级识别的最 终模型,其拥有很好的拟合效果,结构如图6所 示,除输入输出层外,拥有6个卷积和池化层,以 及两个全连接层。且在所有的全连接层中使用了  $\lambda = 0.01$ 的 L2 正则项,所有卷积层中使用了  $\gamma =$ 0.25 dropout 项。最后,在测试集上测试了该模型 的泛化性能。如表6所示,为该模型在测试集上 的混淆矩阵,此时识别精度达到了96.4%。





3.4 CNN 网络模型识别效果

虽然最终的 CNN 网络模型在小的图像块测试集 上取得了较高的分类精度,但考虑网络输入是由所采 集的显微图像进行分割得到的,可以预见,在分割处 的球化特征也同时被分割,此时,该特征处的图像像 素彼此间丧失了空间相关性,从而影响 CNN 网络对 球化特征的提取,降低网络的分类精度,出现假阳性 和假阴性,最终影响部件表面整体球化程度的判断。

为此,我们考虑整个部件所采集的全部显微图像,从全局图像块来判断部件表面的球化程度。如表7所示,为实验获得的9个部件的全局预测结果。对于每个部件的所有小图像块,所获得的 CNN 模型的识别准确率在94.1%以上。虽然有部分图像块被错误识别,但是这并不影响部件表面球化程度的整体判断。由表7可知,九个部件均被准确识别,精度达到了100%。很明显,我们所获得的 CNN 模型在 SLM 成型件表面球化程度等级识别问题上具有很好的性能。

#### 表6 CNN 网络在测试集上的混淆矩阵

Tab. 6 Confusion matrix of the final CNN architecture on test dataset

混淆矩阵			य व र ७७		
		轻微球化(0)	中度球化(1)	重度球化(2)	百四平/ %
	轻微球化(0)	627(94.4%)	19(2.9%)	18(2.7%)	94.4
真实标签	中度球化(1)	2(0.3 %)	681(96.0%)	26(3.7%)	96.0
	重度球化(2)	1(0.1%)	10(1.4 %)	719(98.5%)	98.5
精确率/%		99. 5	95.9	94. 2	准确率:96.4

表 7	九个试件在全局图像块上的预测结果

Tab.	7	The	global	prediction	results	of	nine	specimens
------	---	-----	--------	------------	---------	----	------	-----------

试件序号	轻微球化(0)	中度球化(1)	重度球化(2)	预测精度/%	实际标签	预测标签
1	1849	32	27	96.9	0	0
2	1995	2	7	99.6	0	0
3	2061	0	3	99.9	0	0
4	24	1931	85	94. 7	1	1
5	14	53	2105	96.9	2	2
6	2	1988	122	94. 1	1	1
7	9	2160	63	96.8	1	1
8	4	90	2126	95.8	2	2
9	6	91	2267	95.9	2	2

最后,通过采集 SLM 成型过程中试件表面显微 图像,并应用球化程度等级 CNN 分类识别模型,就 能准确获得试件表面球化程度等级。同时根据此时 的工艺条件及球化程度与激光能量密度之间的关联 关系,可以辅助实验及生产人员做出相应的决策,以 获得较高成型质量的成型件。

#### 4 结 论

本文中,鉴于 SLM 成型过程中所出现的球化现 象及其所引起的孔隙缺陷和表面粗糙等成型质量问 题,我们研究了 SLM 成型件表面球化程度表征及球 化程度等级分类识别方法,初步探讨了成型质量逐 层控制的可行性以及深度 CNN 网络框架在 SLM 成 型过程中部件表面球化程度等级自动检测中的应 用。基于实验结果与讨论,可以得出如下结论:

(1)对于没有纹理规律的复杂成型件表面显微 图片,FCN 能够有效的提取出背景中的球化特征。 且根据所提取的球化特征,文中给出的球化程度表 征方法是有效的,并且获得了最优的工艺参数,即激 光功率为150 W,扫描速度为50 mm/s,扫描间距为 0.25 mm,层厚为0.05 mm。在此条件下,两种扫描 方式均获得了表面光洁,熔道轨迹连续,搭接良好, 没有明显球化现象的成型件。 (2)两种扫描方式下,成型件表面球化程度随 激光能量密度变化呈现出相同的变化趋势,即随着 激光能量密度的变化,先增大后减小,再增大再减小 的过程,且在两个极大值点之间存在最优的激光能 量密度 240 J/mm<sup>3</sup>。

(3)通过图像压缩获取小尺寸图像能加速 CNN 网络的训练进程,但是其验证精度远低于原始尺寸 图片精度,这是因为在卷积和池化层的作用下,小尺 度图像特征更容易被频繁的降采样导致特征丢失。 当增加 CNN 网络的卷积层时,卷积核数量的增加在 一定程度上能够提取到更多的球化特征,有助于提 高网络的验证精度,但是当进一步增加卷积层时,随 着模型复杂度的增加,出现过拟合的现象,模型性能 变差。而当增加全连接层的维度时,其训练时间增 长,但验证精度仅提高了 0.38 %,因此,可以认为全 连接层的维度对网络的验证精度影响不大。

(4)在所有的全连接层中使用  $\lambda$  = 0.01 的 L2 正则项以及所有卷积层中使用  $\gamma$  = 0.25 的 dropout 项时,CNN 模型获得了较好的拟合效果,此时在验 证集上的验证精度为 85.6 %,测试集上的识别精度 为 96.4 %。虽然图像分割会影响球化特征的提取, 降低网络的识别精度,但是这并不影响试件表面球

#### 参考文献:

- Guo N, Leu M. Additive manufacturing: technology, applications and research needs [J]. Frontiers of Mechanical Engineering, 2013, 8(3): 215 - 243.
- [2] Shahir Y, Yifei C, Richard B, et al. Investigation on porosity and microhardness of 316L stainless steel fabricated by selective laser melting[J]. Metals, 2017,7(2):64.
- [3] Lopez A, Bacelar R, Pires I, et al. Non-destructive testing application of radiography and ultrasound for wire and arc additive manufacturing [J]. Additive Manufacturing, 2018,21:298-306.
- [4] Maskery I, Aboulkhair N, Corfield M, et al. Quantification and characterization of porosity in selectively laser melted Al-Si10-Mg using X-ray computed tomography[J]. Materials Characterization, 2016, 111;193 – 204.
- [5] Cegan, T, Pagac, M, Jurica, J, et al. Effect of hot isostatic pressing on porosity and mechanical properties of 316L stainless steel prepared by the selective laser melting method[J]. Materials, 2020, 13(19), 4377.
- [6] Salem H, Carter L, Attallah M, et al. Influence of processing parameters on internal porosity and types of defects formed in Ti6Al4V lattice structure fabricated by selective laser melting [J]. Material Science and Engineering: A, 2019, (767):138387.
- [7] Aboulkhair N, Everitt N, Ashcroft I, et al. Reducing porosity in AlSi10Mg parts processed by selective laser melting
   [J]. Additive Manufacturing, 2014, 1 4:77 86.
- [8] Lee Y, Zhang W. Mesoscopic simulation of heat transfer and fluid flow in laser Powder bed additive manufacturing [C]//26th Solid Freeform Fabrication Symposium. 2015.

- [9] Kimura T, Nakamoto T. Microstructures and mechanical properties of A356(AlSi7Mg0.3) aluminum alloy fabricated by selective laser melting [J]. Materials & Design, 2016,89:1294-1301.
- [10] Wu H, Li J, Wei Z, et al. Effect of processing parameters on forming defects during selective laser melting of Al-Si10Mg powder [J]. Rapid Prototyping Journal, 2020, ahead-of-print.
- [11] Qiu Y, Wu J, Chen A, et al. Balling phenomenon and cracks in alumina ceramics prepared by direct selective laser melting assisted with pressure treatment[J]. Ceramics International, 2020, 46(9):13854-13861.
- [12] Zhou X, Liu X, Zhang D, et al. Balling phenomena in selective laser melted tungsten [J]. Journal of Material Processing Technology, 2015, 222:33 - 42.
- [13] Li Z, Kucukkoc I, Zhang D, et al. Optimising the process parameters of selective laser melting for the fabrication of Ti6Al4V alloy [J]. Rapid Prototyping Journal, 2018, 24 (1):150-159.
- [14] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39 (4):640-651.
- [15] Guo M, Gu D, Xi L, et al. Selective laser melting additive manufacturing of pure tungsten: Role of volumetric energy density on densification, microstructure and mechanical properties [J]. International Journal of Refractory Metals and Hard Materials, 2019, 84:105025.
- [16] Shan Wei, Wang Jiangtao, Chen Debao, et al. Human detection in infrared image based on deep convolution neural network[J]. Laser & Infrared, 2020, 50(5):124 130. (in Chinese)
  单巍, 王江涛, 陈得宝, 等. 基于深度卷积神经网络的 红外图像行人检测[J]. 激光与红外, 2020, 50(5): 124 130.