



## 基于机器学习的Ti-6Al-4V合金 激光粉末床熔融工艺优化

孙业东<sup>1</sup>, 姜夕义<sup>2</sup>, 李昊卿<sup>2</sup>, 李星辰<sup>2</sup>, 任雪彭<sup>2</sup>, 方晓英<sup>2</sup>

(1. 山东理工大学 信息中心, 淄博 255000;

2. 山东理工大学 机械工程学院, 淄博 255000)

**摘要:** 基于高斯过程回归(GPR)模型, 对激光粉末床熔融Ti-6Al-4V合金的致密度和表面粗糙度观测数据进行了机器学习, 得到了高致密度合金样品的激光功率-扫描速度的工艺优化窗口, 并探讨了激光功率-扫描速度对表面粗糙度的影响。结果表明: 获得高致密( $\geq 99.5\%$ )合金的激光功率-扫描速度工艺窗口呈梨形, 扫描速度比激光功率对致密度影响更大, 且高功率条件下适宜的扫描速度范围较宽。降低激光功率和提高扫描速度会单调增加表面粗糙度, 且在低激光功率和高扫描速度下该影响更显著。同一激光能量密度下打印的合金致密度取决于具体的扫描速度和激光功率, 但表面粗糙度基本相同。优化工艺窗口下样品的表面粗糙度小于 $10\ \mu\text{m}$ 。实验证明GPR预测的优化工艺窗口是可靠的, 该方法可拓展应用到其他合金增材工艺优化设计中。

**关键词:** 激光粉末床熔融; 机器学习; 激光功率; 扫描速度

文章编号: 1004-0609(2022)-10-3085-11

中图分类号: TF11.31

文献标志码: A

**引文格式:** 孙业东, 姜夕义, 李昊卿, 等. 基于机器学习的Ti-6Al-4V合金激光粉末床熔融工艺优化[J]. 中国有色金属学报, 2022, 32(10): 3085-3095. DOI: 10.11817/j.ysxb.1004.0609.2021-41043

SUN Ye-dong, JIANG Xi-yi, LI Hao-qing, et al. Optimization of selective laser powder bed fusion process for Ti-6Al-4V alloy based on machine-learning[J]. The Chinese Journal of Nonferrous Metals, 2022, 32(10): 3085-3095. DOI: 10.11817/j.ysxb.1004.0609.2021-41043

增材制造具有避免切削时的材料损失、生产周期长和无需锻压设备/专用工模具、减少零件连接, 可实现近净成形等诸多优势。激光粉末床熔融(Laser powder bed fusion, L-PBF)作为重要的金属增材制造工艺, 已被大量应用到钛合金、不锈钢、铝合金、镍合金和高熵合金等材料的构件成形中<sup>[1-7]</sup>。如何优化工艺, 提高增材构件的性能, 使之达到甚或优于传统的铸锻件质量是近些年众多研究者致力的目标。针对特定材料, L-PBF工艺参数组合可达无数种, 目前比较通用的做法是通过实验研究和工

艺仿真来确定适合的工艺参数。对于前者, 如果进行所有工艺参数的实验研究, 成本高, 耗时耗力, 况且在可能的工艺空间内无一遗漏地尝试所有的工艺参数, 几乎是不可能的; 对于后者, 即开发多尺度、多物理场L-PBF工艺仿真模型<sup>[8-10]</sup>, 这虽然在一定程度上有助于对L-PBF工艺的筛选, 但仍存在物理模型精准度与计算成本之间的矛盾。

将基于实验以及仿真数据的机器学习方法引入到增材制造工艺优化及性能预测中目前备受人们的关注<sup>[11]</sup>。CHANDRIKA等<sup>[12]</sup>通过不同机器学习算法

基金项目: 国家重点研发计划资助项目(2018YFB1105900)

收稿日期: 2021-05-13; 修订日期: 2021-10-20

通信作者: 方晓英, 教授, 博士, 电话: 18853387667; E-mail: fxy@sdut.edu.cn

包括最近邻法、回归树、多变量适应回归样条曲线法、支持向量回归和高斯过程等方法训练习得激光粉末床熔融的熔池形状,发现小规模数据模式下,高斯过程算法预测得最准确。亓欣波等<sup>[13]</sup>利用线性回归、支持向量机回归和神经网络三种机器学习算法建立了电子束选区熔化工艺参数与密度的关系,发现支持向量回归的模型预测精度最高。LIU等<sup>[14]</sup>利用高斯过程回归法确定了打印全密度(>99%)AlSi10Mg合金的L-PBF的工艺窗口, TAPIA等<sup>[15-16]</sup>利用高斯过程模型预测了增材制造PH 17-4不锈钢的孔隙率以及316L不锈钢的孔隙率和熔池形状。ZHAN等<sup>[17]</sup>基于三种典型的机器学习模型(神经网络、随机森林和支持向量机)预测了不同工艺参数下增材制造316L奥氏体不锈钢的疲劳寿命。BAO等<sup>[18]</sup>利用支持向量机模型研究了缺陷位置、尺寸和形状对激光粉末床熔融Ti-6Al-4V合金疲劳寿命的影响。

目前,绝大多数增材设备厂商对打印特定材料会提供一套优化工艺参数,但工艺窗口过于狭窄。特定应用场合,对L-PBF成形件的宏观结构、微观组织以及各种性能要求有不同的侧重,这种单一或狭窄的工艺空间远远不能满足用户对打印构件形状和性能的要求。拓宽可行的L-PBF工艺窗口,找寻实现某一特定性能或多种性能组合的子工艺窗口显得十分必要。工艺窗口应是根据成形件可测量的特征值来决定或筛选出来的,例如孔隙率、粗糙度、残余应力、熔池几何、晶粒尺寸、凝固胞形状与尺寸等。考虑到其中部分特征属性对性能的影响具有两面性,残余应力、表面残余压应力可以提高疲劳强度,但会降低塑韧性和热稳定性,甚至导致变形。鉴于此,可以将单调损害构件性能、成形后又难于消除且影响程度大的特征作为工艺窗口筛选的一级因素,如孔隙率,因为该值越低对力学性能(强度、塑韧性、疲劳、冲击等)越有利<sup>[19]</sup>,且孔洞一旦形成往往难于清除(尽管可通过后续热等静压来减轻,但因此带来的成本增加和显微组织变化往往是得不偿失)。再比如表面粗糙度,虽然也是该值越低对力学性能越有利,但由于它仅涉及表面,并不波及内部,对于块体构件完全可以通过简单的机加工化来消除或降低影响,因而可以作为二级筛选因素。其他的因素,比如凝固胞尺寸或形状等,

可通过如此地逐级工艺筛选和优化,最后得到某种或多种优异性能的工艺窗口图。

本文拟通过高斯过程回归(Gaussian process regression, GPR)模型<sup>[20]</sup>找出Ti-6Al-4V合金的L-PBF工艺窗口。将L-PBF中最关键的激光功率( $p$ )和扫描速度( $s$ )两个工艺参数作为机器学习的输入,建立这两个工艺参数与孔隙率和表面粗糙度之间的关系,凡是获得孔隙率且粗糙度低于各自的某一临界值的L-PBF工艺( $p$ 和 $s$ )区间作为优化工艺窗口。这种方法也可以移植到其他合金增材工艺优化设计中。

## 1 实验

### 1.1 合金粉末与L-PBF工艺

原料为雾化法制备的Ti-6Al-4V合金粉末,其化学成分列于表1。经SEM观察,粉末球形度较好,存在极少量的卫星粉,其形貌如图1所示。经Matersize-3000激光粒度仪测试粉末粒径分布如图2所示,平均粒径约为32  $\mu\text{m}$ (见图2)。

L-PBF试验是在Solutions125<sup>HL</sup>设备上完成的,整个打印过程通入高纯氩气来防止氧化,基板预热温度为200  $^{\circ}\text{C}$ 。本实验通过改变L-PBF工艺中两个重要的工艺参数:激光功率和扫描速度来研究样品孔隙率和表面粗糙度的变化。表2所示为具体的L-

表1 Ti-6Al-4V合金粉化学成分

Table 1 Powder composition of Ti-6Al-4V (mass fraction, %)

Al	V	C	Fe	O	N	H	Ti
6.36	4.01	0.01	0.18	0.1	0.025	0.002	Bal.

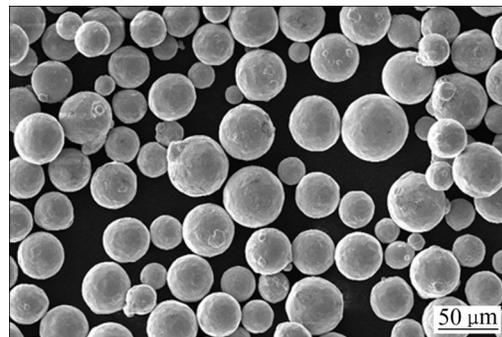


图1 Ti-6Al-4V合金粉末SEM像

Fig. 1 SEM image of Ti-6Al-4V alloy powder

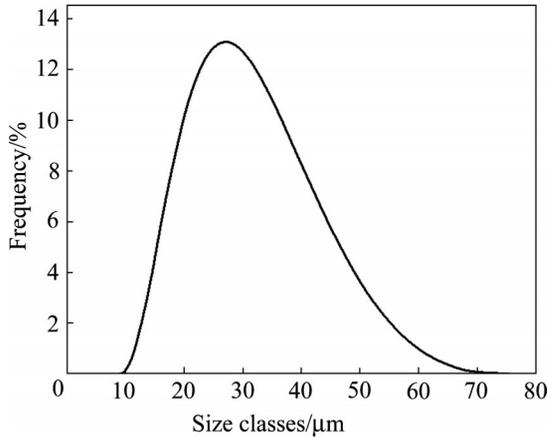


图2 Ti-6Al-4V 合金粉末粒径分布

Fig. 2 Size distribution of Ti-6Al-4V alloy powder

PBF 工艺参数, 所有打印样品的激光功率和扫描速度工艺参数合计 65 种组合。打印过程中层间旋转 67°, 层内为往复式扫描。为提高孔隙观察和表面粗糙度检测效率并排除激光功率和扫描速度之外工艺条件对检测结果的影响, 在同一功率下, 13 组扫描速度(见表 2)连续打印在一起, 样品高度为 10 mm, 每个扫描速度打印区域的宽度为 0.2 mm。最终获得 5 个不同功率下的长条状样品, 具体如图 3 所示, 其中 Z 轴平行于建造方向。

每个 L-PBF 工艺条件对应的激光能量密度可以

通过式(1)计算<sup>[21-22]</sup>:

$$E = \frac{P}{sht} \quad (1)$$

式中:  $E$  为体能量密度( $J/mm^3$ );  $P$  为激光功率( $W$ );  $s$  为扫描速度( $mm/s$ );  $h$  为扫描间距( $mm$ );  $t$  为铺粉层厚度( $mm$ )。

### 1.2 表面粗糙度和缺陷表征

考虑到打印件的 XZ 面普遍比 XY 面粗糙, 选择直接打印后样品的 XZ 面进行粗糙度测试, 使用的仪器为 RTEC INSTRUMENTS 三维轮廓仪, 采用软件 Gwyddion 给出具体表面粗糙度值, 每次测试面积为  $900 \mu m \times 550 \mu m$ , 每个样品测试 3 次以上, 计算得到表面粗糙度的平均值。

采用图像法统计不同 L-PBF 工艺条件下样品的孔隙率( $v$ )。首先对样品表面(YZ)进行常规砂纸打磨, 然后进行振动抛光(Buehler VibroMet 2), 采用 MasterMet 2 非晶体胶体二氧化硅抛光悬浮液, 每个样品表面振动抛光时间 6 h。利用光学显微镜(Optical microscopy, OM)对抛光后样品表面进行孔洞缺陷观察。每个样品随机选取 10 幅图片, 孔隙率采用图像软件(Image J)统计孔洞所占面积比例来确定。致密度( $\rho$ )利用式(2)确定:

$$\rho = 1 - v \quad (2)$$

表2 L-PBF 工艺参数

Table 2 L-PBF processing parameters

L-PBF parameter	Value
Laser Power/W	100, 150, 200, 250, 300
Scanning speed/( $mm \cdot s^{-1}$ )	300, 400, 500, 600, 700, 800, 900, 1000, 1100, 1200, 1300, 1400, 1500
Hatching space/mm	0.12
Layer thickness/mm	0.03

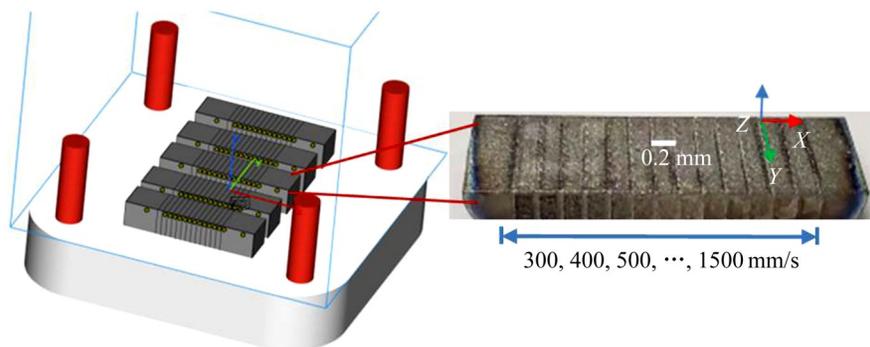


图3 L-PBF 样品的 CAD 模型和打印实物图

Fig. 3 CAD model and typical L-PBFed sample

### 1.3 高斯过程回归

高斯过程回归 (Gaussian process regression, GPR) 是使用高斯过程 (Gaussian process, GP) 对数据进行回归分析的非参数模型, 是基于高斯过程的插值方法<sup>[20]</sup>。高斯过程 (GP) 是有限个具有联合高斯分布的随机变量集合。一个高斯过程由其均值函数和协方差函数确定, 如式(3)和式(4)所示:

$$m(x) = E[f(x)] \quad (3)$$

$$k(x, x') = E\{[f(x) - m(x)][f(x') - m(x')]\} \quad (4)$$

式中:  $x, x' \in R^d$  为任意随机变量。因此一个高斯过程可以定义为:

$$f(x) \sim GP[m(x), k(x, x')] \quad (5)$$

式中:  $x$  为输入向量;  $f$  为函数值。

考虑一个数据集  $X = \{(x_i, f_i) | i = 1, 2, \dots, n\}$ , 数据经预处理, 使其均值为 0。则其观测值的先验分布为: , 观测值和预测值得先验联合分布如式(6)所示:

$$\begin{bmatrix} f \\ f_* \end{bmatrix} \sim N \left( 0, \begin{bmatrix} k(x, x) & k(x, x_*) \\ k(x_*, x) & k(x_*, x_*) \end{bmatrix} \right) \quad (6)$$

式中:  $k(x, x)$  是数据集  $X$  观测点 ( $x$ ) 的协方差矩阵,  $k(x, x_*) = k(x_*, x)^\top$  是观测点 ( $x$ ) 与预测点 ( $x_*$ ) 间的协方差矩阵。由此得出预测值  $f_*$  的后验分布如式(7)所示:

$$f_* | x_*, x, f \sim N(k(x_*, x)k(x, x)^{-1}f, k(x_*, x_*) - k(x_*, x)k(x, x)^{-1}k(x, x_*)) \quad (7)$$

对于本次试验,  $f_*$  为预测回归值(致密度/粗糙度); 输入向量为  $(p, s)$ , 其中  $p$  为打印功率,  $s$  为扫描速度, 则  $f_*$  可以由式(8)给出:

$$\begin{bmatrix} f(p, s) \\ f_*(p_*, s_*) \end{bmatrix} \sim GP(0, k(p, s, p_*, s_*)) \quad (8)$$

式中:  $f(p, s)$  为训练数据集中的观测值;  $f_*(p_*, s_*)$  为预测数据点  $(p_*, s_*)$  的预测值。  $k(p, s, p_*, s_*)$  为训练集的协方差与预测点  $(p_*, s_*)$  的协方差函数, 对应式(4)中的协方差矩阵。

为提高模型的精度和便于计算, 对原始数据进行了如下预处理: 1) 数据“无量纲化”, 即对输入数据(激光功率、扫描速度)作归一化处理, 这样计算时无需考虑输入参数的单位; 2) 将训练数据集中的回归值作标准化处理, 使其均值为零, 即  $m(p, s) = 0$ 。

### 1.4 模型的交叉验证

为了评估模型的性能, 在机器学习过程中, 通常将数据分成两部分, 即训练集和测试集。训练集数据用于训练模型, 测试集数据用于测试模型的精度和稳定性。在实际应用中, 如果测试集数据的数量较小, 对模型的评估会产生较大的偏差。为解决这一问题通常使用  $k$  折交叉验证的方法<sup>[20]</sup>。  $k$  折交叉验证是一个循环验证方法, 即将所有数据 ( $n$  个样本) 随机分成  $k$  份, 其中  $k-1$  份作为训练集, 1 份作为测试集。模型的训练和测试过程进行  $k$  次, 保证每一份数据都作为一次测试集。特别地, 当  $k=n$  时, 称为留一 (Leave-One-Out) 交叉验证, 留一交叉验证可以提高模型的精度, 但会增加计算开销。考虑本文数据规模较小, 采用留一交叉验证的方式。

为定量评估模型性能, 定义平均绝对误差 (Mean absolute error,  $M_{AE}$ ) 来度量模型的精度, 如式(9)所示:

$$M_{AE} = \frac{1}{n} \sum_{i=1}^n |f_{o,i} - f_{p,i}| \quad (9)$$

式中:  $n$  为数据点个数;  $f_{o,i}$  为第  $i$  个数据点的观测值;  $f_{p,i}$  为第  $i$  个数据点的预测值。作为模型精度的评估指标,  $M_{AE}$  越接近于零, 则模型的精度越高。

## 2 结果与讨论

### 2.1 表面粗糙度和致密度的实测结果

经不同激光功率和扫描速度打印样件的  $XZ$  面的典型轮廓形貌如图 4 所示, 最终的表面粗糙度值也示于相应图中。可以看出, 激光功率和扫描速度对粗糙度的影响是单调的, 即功率越小, 扫描速度越大, 表面则越粗糙。

孔洞分布的典型 OM 如图 5 所示, 计算得到的致密度值也在图中给出。激光功率和扫描速度对对孔隙率影响相对复杂, 打印出致密构件的激光功率 ( $p$ )-扫描速度 ( $s$ ) 工艺区间很难直接确定。若要获得优化的激光功率-扫描速度工艺窗口或预测给定工艺 ( $p, s$ ) 条件下的孔隙率和表面粗糙度, 可借助高斯过程回归模型来实现。

### 2.2 致密度的高斯过程回归曲面

不同工艺参数下实测的致密度如图 6 中的黑色点所示, 预测的高斯过程回归曲面和致密度等高线

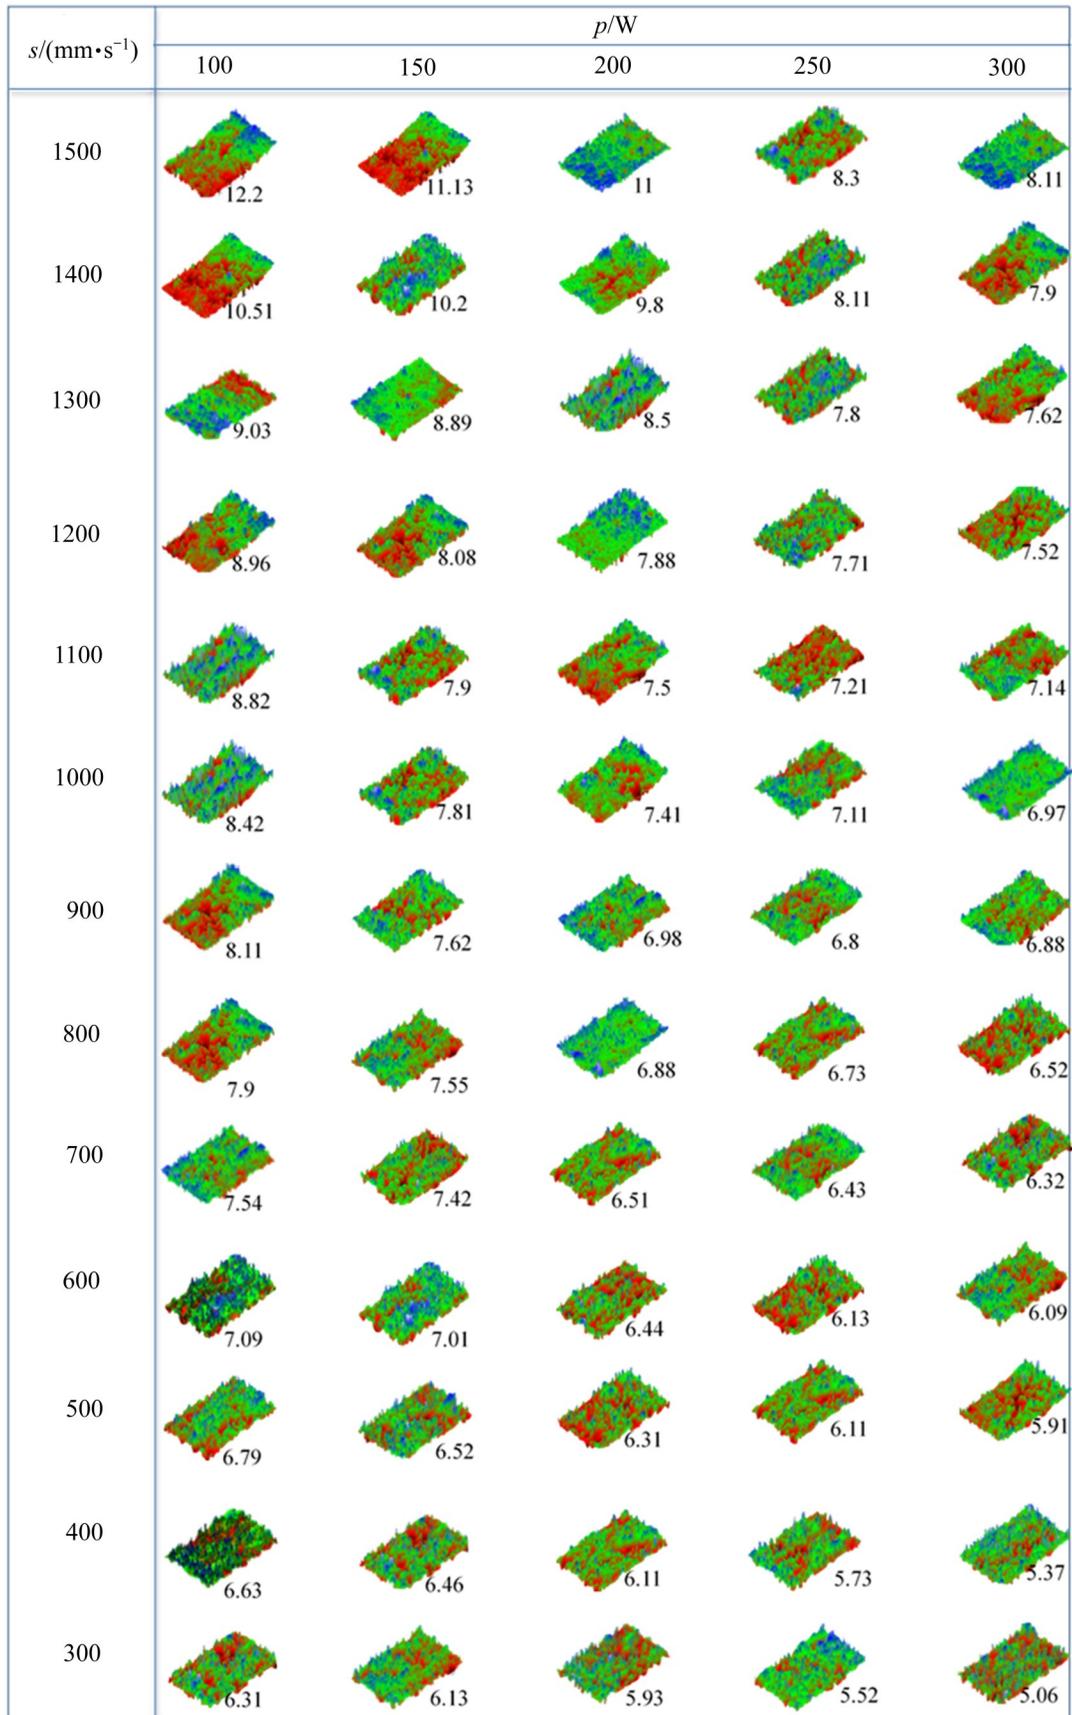


图4 不同L-PBF工艺条件下样品的表面形貌及粗糙度值

Fig. 4 Surface morphologies and roughness values for samples fabricated by different L-PBF parameters

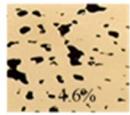
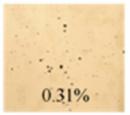
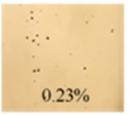
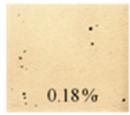
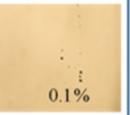
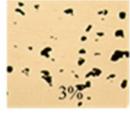
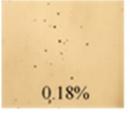
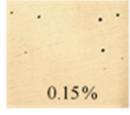
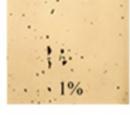
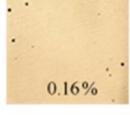
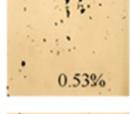
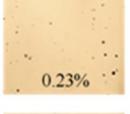
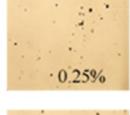
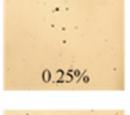
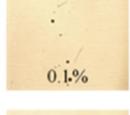
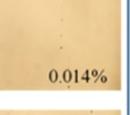
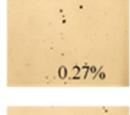
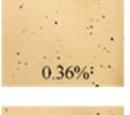
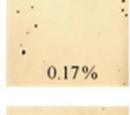
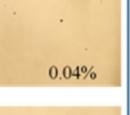
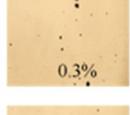
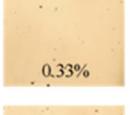
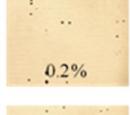
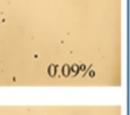
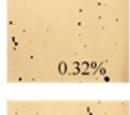
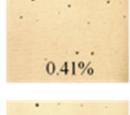
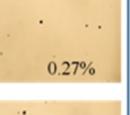
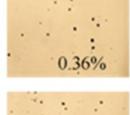
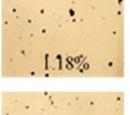
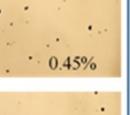
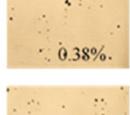
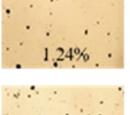
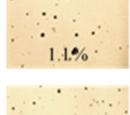
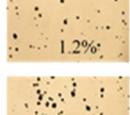
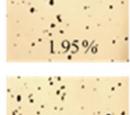
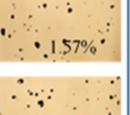
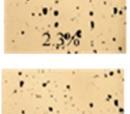
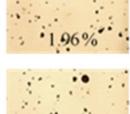
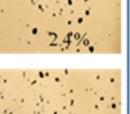
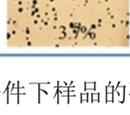
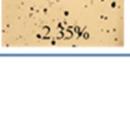
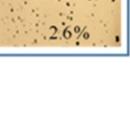
$s/(mm \cdot s^{-1})$	$p/W$				
	100	150	200	250	300
1500	 4.6%	 0.31%	 0.23%	 0.18%	 0.1%
1400	 3%	 0.29%	 0.18%	 0.15%	 0.076%
1300	 1%	 0.2%	 0.21%	 0.16%	 0.015%
1200	 0.53%	 0.23%	 0.28%	 0.17%	 0.008%
1100	 0.25%	 0.25%	 0.35%	 0.1%	 0.014%
1000	 0.27%	 0.26%	 0.36%	 0.17%	 0.04%
900	 0.3%	 0.33%	 0.4%	 0.2%	 0.09%
800	 0.32%	 0.4%	 0.51%	 0.41%	 0.27%
700	 0.36%	 1.16%	 1.18%	 0.5%	 0.45%
600	 0.38%	 1.2%	 1.24%	 1.1%	 1.05%
500	 1.2%	 1.7%	 1.87%	 1.95%	 1.57%
400	 3.1%	 2.2%	 2.3%	 1.96%	 2.4%
300	 3.7%	 2.3%	 2.35%	 2.41%	 2.6%

图5 不同L-PBF工艺条件下样品的孔洞形貌及孔隙率

Fig. 5 Pore morphologies and porosity for samples fabricated by different L-PBF parameters

也同时示于图 6 中。预测结果的标准偏差值如图 7 所示。可以看出, 致密度高于 99% 的区间(红色曲面)处于中间位置, 表明致密度不随打印工艺参数单调变化, 而且该区域在高功率下覆盖的面积明显大于低功率下的面积, 说明高功率下更容易获得致密度高的构件。

该模型预测的标准偏差在激光功率-扫描速度工艺空间的边缘处较大些(见图 7), 特别在高激光功率-高扫描速度处尤其如此。绝大部分预测结果的标准偏差在 0.4 以下。

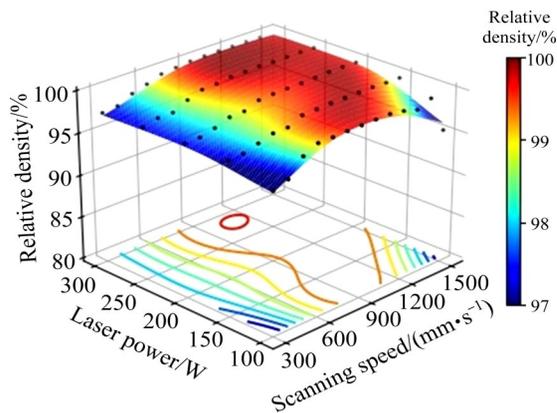


图 6 GPR 模型预测致密度分布曲面  
Fig. 6 Relative density contour based on GPR model

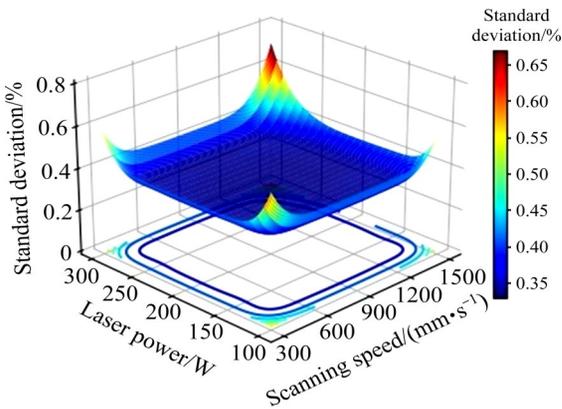


图 7 GPR 模型预测致密度结果的标准偏差  
Fig. 7 Standard errors of predicted relative density based on GPR model

### 2.3 表面粗糙度的高斯过程回归曲面

不同工艺参数下实测的表面粗糙度值如图 8 中的黑色点所示, 预测的高斯回归曲面和表面粗糙度等高线也同时示于图 8 中。由图 8 可以看出, 表面粗糙度随着激光功率降低和扫描速度的增加而单调增加。

预测结果的标准偏差值如图 9 所示。与致密度

预测结果的标准偏差相似, 在激光功率-扫描速度工艺空间的边缘处较大些, 特别在高激光功率-高扫描速度处更加明显。

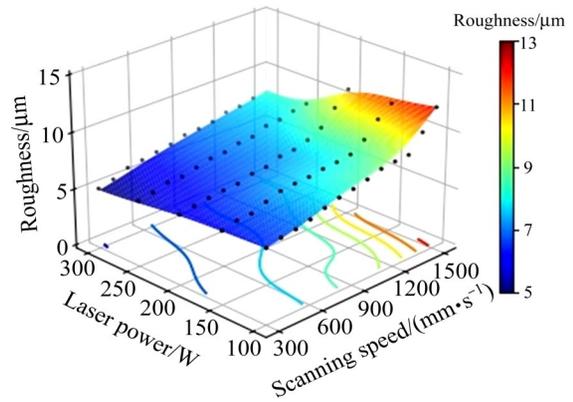


图 8 GPR 模型预测表面粗糙度分布曲面  
Fig. 8 Surface roughness contour based on GPR model

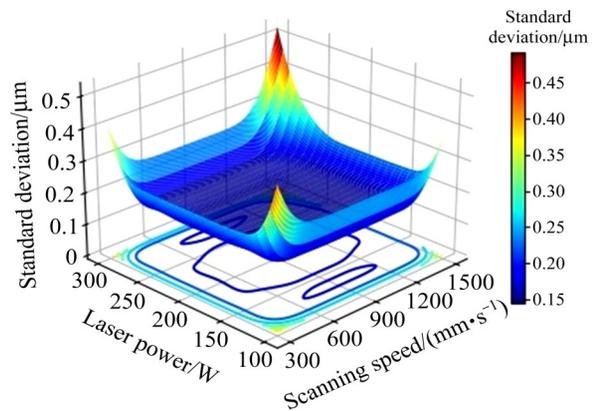


图 9 GPR 模型预测表面粗糙度结果的标准偏差  
Fig. 9 Standard errors of predicted surface roughness based on GPR model

### 2.4 优化的工艺窗口

基于图 6 预测后的致密度分布曲面, 可获得致密度  $\geq 99.5\%$  的致密合金件的工艺优化窗口, 如图 10 中涂浅绿色的区间, 预测的致密度等高线和表面粗糙度等高线分别如图 10 中的红色和蓝色线条所示。可以看出, 在全密度 ( $\geq 99.5\%$ ) 的优化工艺空间内, 得到的打印样品的表面粗糙度不大于 10 μm。该优化的工艺窗口呈梨形, 高功率区面积大于低功率区面积, 表明高功率下对激光扫描速度不太敏感, 更容易获得致密的打印件; 低功率条件下打印则对扫描速度较敏感, 获得高致密件的适宜扫描速度区间较窄。不同打印工艺条件下的激光能密度 ( $J/mm^3$ ) 的等高线如图 10 中的黑色虚线所

示,可以看出,优化工艺窗口对应的能量密度为30~100 J/mm<sup>3</sup>。能量密度过低,即激光功率-扫描速度工艺窗口的右下区,由于未熔合区孔洞增多而使致密度下降<sup>[23]</sup>;能量密度过高,即对应激光功率-扫描速度工艺窗口的左上部,打印时熔池的深度/宽度尺寸比增大,易于形成匙型气孔从而使致密度下降。即使能量密度处于30~100/mm<sup>3</sup>范围内,其打印质量差别也很大。换言之,同一能量密度下,打印质量仍取决于具体的激光功率和扫描速度,比如能量密度同为75 J/mm<sup>3</sup>(用梅花标记的点A、B、C和D处),其预测的致密度分别为100%、99%、98.5%和97.5%。因此,单纯利用能量密度来预测打印件质量是不尽合理的,尤其是当打印参数在大尺度范围内变化时。

值得注意的是,用能量密度来预测表面粗糙度相对可靠,也就是说,使用同一能量密度打印的样件其粗糙度基本一致,比如A、B、C和D四处的表面粗糙度都处于6~7 μm范围内。能量密度较低时,主要对应扫描速度过大或激光功率过低。当扫描速度过大时,会造成半圆柱形熔池长度增加,在Plateau Raleigh毛细作用下,液态金属会被分割成球形液滴形成“球化”效应,在熔池内部表面张力梯度作用下,这些小球一般被拖曳到熔道边缘处,致使表面粗糙<sup>[23]</sup>;当激光功率较低时,也容易造成

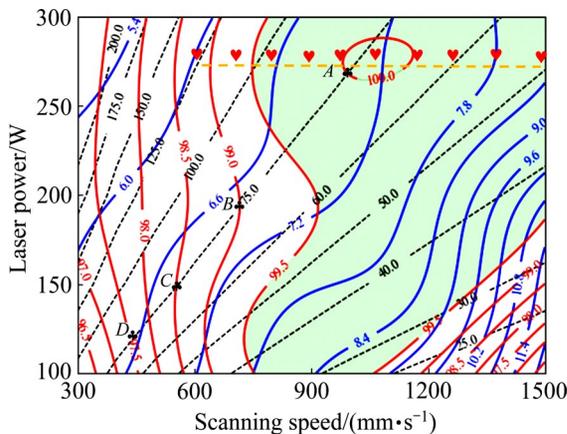


图10 GPR模型预测的激光功率-扫描速度工艺空间

Fig. 10 Predicted laser power and scanning speed process window based on GPR model (Area highlighted by light green represents optimized  $p-s$  process window. Red solid, blue solid and black dotted lines stand for contour lines of relative density, surface roughness and laser energy density, respectively. Values were also labeled in the corresponding contour lines)

熔池长度与深度尺寸比增大,导致Plateau Raleigh毛细失稳现象;且功率较低时,层间未熔颗粒或熔合不良会加剧,直接造成表面粗糙度增加<sup>[24]</sup>。此外,在低激光功率和高扫描速度区间,样品表面粗糙度的等高线变密,表明表面粗糙度受这两个工艺参数的影响加剧。

## 2.5 交叉验证结果

致密度和表面粗糙度的预测数据与实测数据的偏差分别如图11和图12所示,蓝色方点为模型预测数据(误差范围为0.3),红色圆点为观测数据。经交叉验证,致密度观测值与预测值的偏差 $\rho_{MAE}$ 为0.29%,表面粗糙度观测值与预测值的偏差 $R_{MAE}$ 为

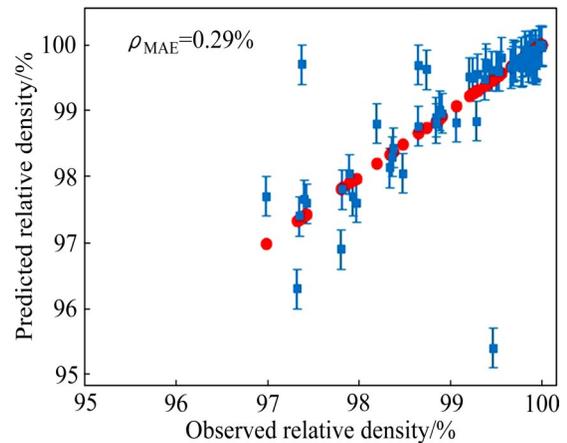


图11 致密度观测值(红色)与GPR预测值(蓝色)的偏差情况

Fig. 11 Deviation between observed (red) and GPR predicted (blue) relative density values

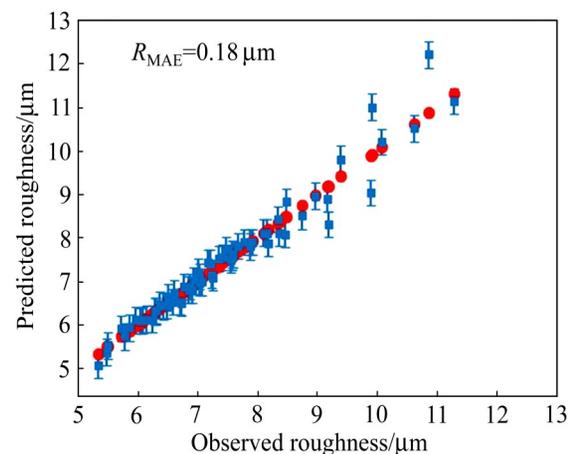


图12 表面粗糙度观测值(红色)与GPR预测值(蓝色)的偏差

Fig. 12 Deviation between observed (red) and GPR predicted (blue) surface roughness values

0.18  $\mu\text{m}$ 。比较而言, 表面粗糙度预测结果与实际观测值吻合得更好。图中误差较大的点对应边缘外推误差。

总的来说, 两种情况下的偏差值都较小, 表明采用的 GPR 模型具有较高精度, 用来预测打印质量(致密度和表面粗糙度)进而确定优化工艺窗口是可靠的。

### 3 实验辅助验证

为了进一步验证激光功率-扫描速度优化工艺区间的可靠性, 对 Ti-6Al-4V 合金粉末在 275 W 功率进行了扫描速度 600~1500 mm/s 的打印验证, 经测定样品的致密度和表面粗糙度如表 3 所示。这 10 个样品在激光功率-扫描速度工艺空间中的对应位置也示于图 10 中, 见图中标注的 10 个红色桃形符号所示。可以看出, 不论致密度还是表面粗糙度都与该模型预测值吻合较好。

表 3 激光功率 275 W 下打印的 Ti6-Al-4V 合金样品的致密度和表面粗糙度

Table 3 Relative density and surface roughness of L-PBFed Ti-6Al-4V alloy samples under laser power of 275 W

Scanning speed/ ( $\text{mm} \cdot \text{s}^{-1}$ )	Relative density/%	Surface roughness/ $\mu\text{m}$
600	98.75	6.4
700	99.3	6.7
800	99.52	6.9
900	99.71	7.1
1000	99.80	7.3
1100	99.89	7.5
1200	99.99	7.9
1300	99.99	8.2
1400	99.92	8.3
1500	99.90	8.4

### 4 结论和展望

基于高斯过程回归模型, 对不同 L-PBF 工艺打印的 Ti-6Al-4V 合金的致密度和表面粗糙度观测数据进行了机器学习, 分析并确定了激光功率-扫描

速度优化工艺窗口。主要结论如下:

1) 提出的高斯过程回归模型可高精度预测不同工艺( $p, s$ )下打印合金的致密度和表面粗糙度, 并明确给出了获得高致密( $\geq 99.5\%$ )打印件的激光功率-扫描速度工艺窗口, 在该窗口下, 表面粗糙度小于 10  $\mu\text{m}$ 。

2) 优化的激光功率-扫描速度工艺窗口呈梨形, 在高激光功率下可选择的扫描速度范围更大, 且打印件致密度对不同工艺参数敏感度不同, 相对激光功率, 对扫描速度更敏感。

3) 同一激光能量密度下打印, 合金样品的致密度仍取决于具体的扫描速度和激光功率, 但其表面粗糙度基本相同。

作为全数字化制造工艺, 增材制造有望利用机器学习等人工智能算法无缝衔接全工艺链上的数据, 包括结构设计、增材工艺、在线检测信息、材料属性、构件组织性能等方面的数据。因此, 通过机器学习, 建立这些数据间内在关系, 高效实现工艺优化、质量控制和产品性能预测评价等是未来增材制造领域重要的研究方向。

### REFERENCES

- [1] SIMONELLI M, TSE Y Y, TUCK C. Effect of the build orientation on the mechanical properties and fracture modes of SLM Ti-6Al-4V[J]. *Materials Science and Engineering A*, 2014, 616: 1-11.
- [2] PHAM M S, DOVGYY B, HOOPER P A. Twinning induced plasticity in austenitic stainless steel 316L made by additive manufacturing[J]. *Materials Science and Engineering A*, 2017, 704: 102-111.
- [3] NORIKO R, WANG W, KHAMIS E, et al. Selective laser melting of AlSi10Mg alloy: Process optimization and mechanical properties development[J]. *Materials and Design*, 2015, 65: 417-424.
- [4] ALENA K, VLADIMIR B, SYLVAIN T. Effect of heat treatment and hot isostatic pressing on the microstructure and mechanical properties of Inconel 625 alloy processed by laser powder bed fusion[J]. *Materials Science and Engineering A*, 2017, 689: 1-10.
- [5] WANG Y, LI R, NIU P, et al. Microstructures and properties of equimolar AlCoCrCuFeNi high-entropy alloy additively manufactured by selective laser melting[J]. *Intermetallics*, 2020, 120: 106746.

- [6] 马如龙, 彭超群, 王日初, 等. 选区激光熔化铝合金的研究进展[J]. 中国有色金属学报, 2020, 30(12): 2773-2788.  
MA Ru-long, PENG Chao-qun, WANG Ri-chu, et al. Progress in selective laser melted aluminum alloy[J]. The Chinese Journal of Nonferrous Metals, 2020, 30(12): 2773-2788.
- [7] 胡泽华, 宋长辉, 刘林青, 等. 镍钛合金激光选区熔化成形技术研究进展[J]. 中国激光, 2020, 47(12): 12020051-12.  
HU Ze-hua, SONG Chang-hui, LIU Lin-qing, et al. Research progress of selective laser melting of nitinol[J]. Chinese Journal of Lasers, 2020, 47(12): 12020051-12.
- [8] LI C, FU C H, GUO Y B, et al. A multiscale modeling approach for fast prediction of part distortion in selective laser melting[J]. Journal of Materials Processing Technology, 2016, 229: 703-712.
- [9] LI C, LIU J F, FANG X Y, et al. Efficient predictive model of part distortion and residual stress in selective laser melting[J]. Additive Manufacturing, 2017, 17: 157-168.
- [10] MUKHERJEE T, ZHANG W, DEBROY T. An improved prediction of residual stresses and distortion in additive manufacturing[J]. Computational Materials Science, 2017, 126: 360-372.
- [11] 曹龙超, 周奇, 韩远飞, 等. 激光选区熔化增材制造缺陷智能监测与过程控制综述[J]. 航空学报, 2021, 42(10): 199-233.  
CAO Long-chao, ZHOU Qi, HAN Yuan-fei, et al. Review on intelligent monitoring of defects and process control of selective laser melting additive manufacturing[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(10): 199-233.
- [12] CHANDRIKA K, FAN Y J, Regression with small data sets: A case study using code surrogates in additive manufacturing[J]. Knowledge and Information System, 2018, 57: 475-493.
- [13] 亓欣波, 李长鹏, 李阳, 等. 基于机器学习的电子束选区熔化成形件密度预测[J]. 机械工程学报, 2019, 55(15): 48-55.  
QIN Xin-bo, LI Chang-peng, LI Yang, et al. Machine learning algorithms on density prediction of electron beam selective melted parts[J]. Journal of Mechanical Engineering, 2019, 55(15): 48-55.
- [14] LIU T Q, WU H K, PAUL M J, et al. Machine-learning assisted laser powder bed fusion process optimization for AlSi10Mg: New microstructure description indices and fracture mechanisms[J]. Acta Materialia, 2020, 201: 316-328.
- [15] TAPIA G, KHAIRALLAH S, MATTHEWS M, et al. Gaussian process-based surrogate modeling framework for process planning in laser powder-bed fusion additive manufacturing of 316L stainless steel[J]. The International Journal of Advanced Manufacturing Technology, 2018, 94(9/12): 3591-3603.
- [16] TAPIA G, ELWANY A, SANG H. Prediction of porosity in metal-based additive manufacturing using spatial Gaussian process models[J]. Additive Manufacturing, 2016, 12: 282-290.
- [17] ZHAN Z, LI H. Machine learning based fatigue life prediction with effects of additive manufacturing process parameters for printed SS 316L[J]. Int J Fatigue, 2021, 142: 105941.
- [18] BAO H Y X, WU S C, WU Z K, et al. A machine-learning fatigue life prediction approach of additively manufactured metals[J]. EngFract Mech, 2021, 242: 107508.
- [19] 吴正凯, 吴圣川, 张杰, 等. 基于同步辐射X射线成像的选区激光熔化Ti-6Al-4V合金缺陷致疲劳行为[J]. 金属学报, 2019, 55(7): 811-820.  
WU Zheng-kai, WU Sheng-chuan, ZHANG Jie, et al. Defect induced fatigue behaviors of selective laser melted Ti-6Al-4V via synchrotron radiation X-Ray tomography[J]. Acta Metallurgica Sinica, 2019, 55(7): 811-820.
- [20] WILLIAMS C K, RASMUSSEN C E. Gaussian processes for machine learning[M]. Cambridge: MIT Press, 2006: 13-19.
- [21] STARR T L, GORNET T J, USHER J S. The effect of process conditions on mechanical properties of laser-sintered nylon[J]. Rapid Prototyping Journal, 2011, 17: 418-423.
- [22] GONG H, RAFI K, GU H, et al. Analysis of defect generation in Ti-6Al-4V parts made using powder bed fusion additive manufacturing processes[J]. Additive Manufacturing, 2014, 1/4: 87-98.
- [23] GUSAROV A, SMUROV I. Modeling the interaction of laser radiation with powder bed at selective laser melting[J]. Physics Procedia, 2010, 5: 381-94.
- [24] DEBROYT, WEI H L, ZUBACK J S, et al. Additive manufacturing of metallic components-process, structure and properties[J]. Progress in Materials Science, 2018, 92: 112-224.

## Optimization of selective laser powder bed fusion process for Ti-6Al-4V alloy based on machine-learning

SUN Ye-dong<sup>1</sup>, JIANG Xi-yi<sup>2</sup>, LI Hao-qing<sup>2</sup>, LI Xing-chen<sup>2</sup>, REN Xue-peng<sup>2</sup>, FANG Xiao-ying<sup>2</sup>

(1. Information Centre, Shandong University of Technology, Zibo 255000, China;

2. School of Mechanical Engineering, Shandong University of Technology, Zibo 255000, China)

**Abstract:** A machine-learning approach based on Gaussian Process Regression (GPR) was proposed to optimize the processing window of laser power and scanning speed in the Ti-6Al-4V alloy fabricated by laser powder bed fusion (L-PBF). The effect of laser power-scanning speed on surface roughness of the samples was investigated as well. The predicted results from the model show that the optimized L-PBF processing window for manufacturing fully dense Ti-6Al-4V alloy with relative density  $\geq 99.5\%$  is pear-shaped. It is suggested that the scanning speed is more influential than laser power in relative density of the L-PBFed alloy, and the wide favorable scanning speed range can be obtained in the case of high laser power. The lower power and high scanning speed tend to increase surface roughness monotonously and the effect become more pronounced as power decreasing and scanning speed increasing. The relative density of the L-PBFed alloy depends on the specific scanning speed and laser power rather than a single energy density value. However, the surface roughness significantly depends on the energy density and the same energy density employed leads to the similar surface roughness. The optimized laser power-scanning speed processing window brings about the highly dense alloy with surface roughness less than  $10\ \mu\text{m}$ . The further experimental evidence proved that the GPR model established in this study is reliable and can be readily applied to the L-PBF process optimization of other metals and alloys.

**Key words:** laser powder bed fusion; machine learning; laser power; scanning speed

---

**Foundation item:** Project(2018YFB1105900) supported by the National Key Research and Development Program of China

**Received date:** 2021-05-13; **Accepted date:** 2021-10-20

**Corresponding author:** FANG Xiao-ying; Tel: +86-18853387667; E-mail: fxy@sdut.edu.cn

(编辑 王 超)