激光粉末床熔融增材制造过程中碲化铋热电功率因数的预测激光粉末床熔融增材制造

Ankita Agarwal* Tanvi Banerjee* Joy Gockel† Saniya LeBlanc‡ Joe Walker§ John Middendorf §

摘要

增材制造（AM）过程（如激光粉末床熔融）通过逐层铺展并融化粉末，直至形成自由形状零件，从而实现物体的制造。为了改善增材制造过程中所涉及材料的性能，有必要根据工艺条件预测材料表征属性。在热电材料中，功率因数用于衡量材料将热转换为电能的效率。尽管此前的研究已使用各种技术预测不同热电材料的材料表征属性，但尚未探索利用机器学习模型预测增材制造过程中碲化铋（Bi2Te3）的功率因数。这一点十分重要，因为Bi2Te3是低温应用中的标准材料。作为概念验证，我们使用增材制造Bi2Te3过程中涉及的制造工艺参数数据以及采集的原位传感器监测数据，训练不同的机器学习模型，以预测其热电功率因数。我们采用监督式机器学习技术，使用80%的数据进行训练、20%的数据进行测试，并进一步利用置换特征重要性方法，识别出最适合预测该材料功率因数的重要工艺参数和原位传感器特征。随机森林、AdaBoost分类器和装袋分类器等集成方法在预测功率因数方面表现最佳，其中装袋分类器模型达到了最高90%的准确率。此外，我们还发现了排名前15的工艺参数和原位传感器特征，可用于表征功率因数等材料制造属性。进一步优化这些特征，有望最大限度地提高热电材料的功率因数，并改善采用该材料制造的产品质量。

关键词—增材制造、粉末床熔融、碲化铋、机器学习、热电材料

1 引言

增材制造（AM）是一种通过逐层构建来制造物体的过程。增材制造过程可分为不同类型，其中一种是激光粉末床熔融类型（PBF-LB），该过程能够以最少的浪费，在一次制造过程中创建具有所需几何形状和复杂度的零件 [1]。在这一过程中，热电材料粉末可以通过激光束融化并熔合，以形成新的物体。这些材料的制造步骤决定了产品的整体质量，以及将热转换为电能的效率 [2]。因此，预测这种效率的衡量指标（称为功率因数）对于确定制造过程中涉及的重要参数发挥着重要作用。这些参数和测量结果可以从工艺参数以及增材制造过程中由层析成像和偏振测量等原位传感器捕获的图像中收集，并可用于材料表征。

增材制造过程涉及激光功率、激光移动速度、扫

功率因数等于塞贝克系数的平方乘以电导率。人

*Wright State University（agarwal.15@wright.edu, tanvi.banerjee@wright.edu）
†Colorado School of Mines，joygockel@mines.edu
‡The George Washington University，sleblanc@email.gwu.edu
§Open Additive, LLC（jwalker@openadditive.com, jmiddendorf@openadditive.com）

热电偶和热电发电机的效率与热电材料的功率因数成　参数对零件质量的影响，[15] 以增材制造过程中采集

除工艺参数外，利用原位传感器对粉末逐层沉积

PBF-LB 最常用于金属、陶瓷和聚合物，直到最

- RQ1：我们能否构建一个机器学习模型，利用

- RQ2：在该材料的增材制造过程中，哪些工艺

近年来，人工智能数据驱动方法已被用于发现高

2 相关工作

科学实验和仿真方法一直是增材制造中用于工艺参数

尽管早期研究人员已探讨了在增材制造过程中，针对不同热电材料的各种任务，如何利用工艺参数和监测数据实施机器学习方法的重要性，但他们并未收集Bi_2Te_3的原位传感器监测层数据。此外，尚未有人在PBF-LB过程中利用工艺参数和监测层数据建立机器学习模型，来预测这种热电材料将热转化为电能的效率。因此，我们通过利用其PBF-LB增材制造过程中的工艺参数，以及通过层析成像和偏振测量采集的原位传感器数据，预测Bi_2Te_3的功率因数等材料属性，从而填补了文献中的这一空白。本研究选择Bi_2Te_3，因为它是唯一公认的低温（最高 ≈150 °C）应用 [24] 热电标准参考材料。此外，它也是唯一可商业购得的原材料。

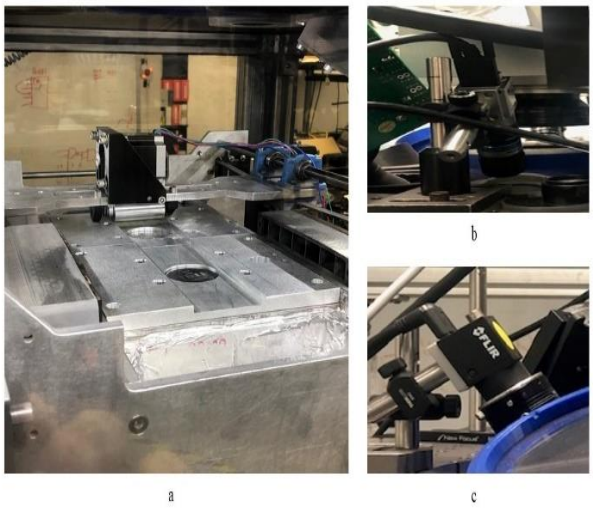

图 1：使用 PBF-LB 对 Bi_2Te_3 进行增材制造过程，展示了 (a) 激光粉末床熔融设备，(b) 层析成像传感器，(c) 偏振测量传感器

3 方法

3.1 数据采集

3.1.1. 激光粉末床熔融设备

增材制造过程由激光功率、激光移动速度、扫描道间距、层厚度和激光焦点等工艺参数控制。在 PBF-LB 制造过程中，可为每个试样单独指定这些参数。PBF-LB过程首先使用滚筒将粉末料仓中的粉末铺展到粉末床上。由于颗粒形状和尺寸不规则，需要使用反向旋转的滚筒式铺粉器，以便将粉末均匀铺展成层，覆盖在成形板上。随后，能量源（激光）按照指定的扫描道图案融化粉末床上的材料。接着，成形平台下降，并重复这一过程，直至达到所需厚度。此次研究中，试样由 OpenAdditive 设施内的一台定制 PBF-LB 设备制造 [1]。设备还安装了过程监测传感器，用于采集原位传感器数据。制造过程的整体流程如图 1 所示。

3.1.2 试样制备

采用基于既有经验[4]选定的工艺参数范围，通过 PBF-LB 制备了 Bi_2Te_3 试样。共使用 PBF-LB 成功制造了 220 个试样。因此，每个试样均按层逐层制备。PBF-LB 所采用的工艺变量包括激光功率、激光速度、扫描道间距，层厚度、光斑尺寸和扫描策略。试样所采用的激光功率包括 10 W、12 W、13 W、14 W、16 W、18 W、19 W、20 W、22 W、24 W、25 W 和 30 W。所采用的激光速度为 300 mm/s、350 mm/s、400 mm/s、450 mm/s、500 mm/s 和 700 mm/s。所采用的扫描道间距包括 0.01 mm、0.02 mm、0.025 mm 和 0.0375 mm。试样的层厚度为 0.1 mm 或 0.15 mm。激光焦点决定了激光束在试样表面的光斑尺寸。所采用的两种光斑尺寸分别为 30 µm（聚焦于表面）和 257 µm（离焦）。

3.1.3 原位传感器

PBF-LB 过程监测的大多数方法至少使用一种传感器。我们聚焦于 OpenAdditive 提供的两种模态：偏振测量和热层析成像。每种模态均由一台离轴相机采集，因此我们获得了一幅校准图像，用于计算单应性矩阵，从而将图像的相机透视校准为俯视图。校准后，将每个层图像裁剪至各试样的内部区域。这 15 个裁剪区域使用 Lanczos4插值上采样或下采样至 64 x 64 像素。

(a) 热层析成像

热层析成像由一台配备 Sony IMX226 CMOS传感器的 Basler acA4024-29um相机采集，该相机配有近红外（750-1000 nm）和中性密度滤光镜片。相机配置为长曝光（250 ms）和低帧率（4 Hz），分辨率为 2000 x

[1] https://openadditive.com/

2500 分辨率。传感器存在若干噪声像素，因此需要使用围绕热像素的中值窗口卷积对图像进行清理。每个试样都有一套独特的工艺参数集，会影响焊接过程中的能量。这会影响相机工作波长范围内光子的发射。有时，传感器未经过校准，无法处理全部发射范围；当过多的发射使传感器响应达到最大值时，纹理细节会随之被冲淡。这种传感器模态中的纹理可能非常有用，因为已知有多种现象会出现在热层析成像中。这些现象包括白色彗星（飞溅）、暗斑（缺粉）、暗线（铺粉器条纹或跳动）以及亮边（分层）。热层析成像数据由每个试样在每一层的热图组成。

(b) 偏振测量

偏振测量数据通过每层拍摄两张图像采集：一张在铺粉后拍摄，另一张在粉末融化后拍摄；因此无需进行汇编。偏振测量数据由一台配备 Sony IMX226 CMOS传感器的 Basler acA4024-29um相机采集，该相机在铺展粉末层后和粉末融化后拍摄成形区域的单色图像，分辨率为 2456 x 2052。铺粉后的图像可显示粉末铺展的均匀性，以及前一层的材料是否凸出并进入下一层。熔化后的图像可能揭示粉末铺展对熔化材料的影响。它们还记录了每一层的情况，因此可利用这些数据交叉验证其他过程监测数据中的缺陷。偏振测量的铺粉后数据由每层各试样的粉末铺展图像组成，而偏振测量的熔化后数据则由每层各试样的熔化粉末图像组成。铺粉后和熔化后的图像均包含对应的偏振角和线偏振度图像。

3.2 图像处理与特征工程

为了利用原位传感器数据构建机器学习模型，需要先处理通过这些传感器采集的原始图像，并将其工程化为特征。为此，使用了直方图均衡化以及图像滤波器，例如用于去模糊的维纳滤波器和用于清理图像的中值滤波。随后，使用 Python OpenCV软件包[2]为试样的每一层提取了以下特征：

断层成像传感器特征：像素强度的平均值、中位数、最大值、最小值、标准差，以及表面粗糙度。

偏振测量传感器特征：1. 铺粉后特征

（基于铺粉后采集的偏振测量数据构建的特征）：i. 偏振角（AoP）：像素强度的平均值、中位数、最大值、最小值、标准差以及表面粗糙度。ii. 线偏振度（DoLP）：像素强度的平均值、中位数、最大值、最小值、标准差以及表面粗糙度。2. 熔化后特征（基于激光扫描后采集的偏振测量数据构建的特征）：i. 偏振角（AoP）：像素强度的平均值、中位数、最大值、最小值、标准差以及表面粗糙度。ii. 线偏振度（DoLP）：像素强度的平均值、中位数、最大值、最小值、标准差以及表面粗糙度。

3.3 数据集准备

制造试样时，采集了该试样每一层的原位传感器数据。制造特定试样的各层时，工艺参数保持不变。此外，每个试样制造完成后，都会测量其异位材料表征输出数据，即 77°C 下的功率因数 $mW/m\ K^2$。本研究分析了 117 个试样的数据。我们将每个试样的每一层视为一个独立数据点。因此，对试样各层采集的原位传感器数据进行特征工程后，我们将对应于试样每一层的原位传感器特征值，与相应的工艺参数值和 77°C 下的功率因数 $mW/m\ K^2$，一同添加到数据集中；对于特定试样的所有层，这些值均相同。

将增材制造原位传感器监测数据、工艺参数和功率因数与试样的每一层相结合后，我们共获得 3,157 个样本点，用于分析和构建机器学习模型。对于特定试样，其每一层的工艺参数和功率因数值相同，但原位传感器特征值各不相同。图 2 展示了整体框架，其中涵盖了从数据采集、图像处理和特征工程，到利用工艺参数和原位传感器特征构建预测性机器学习模型以预测功率因数的各个步骤。

[2] https://pypi.org/project/opencv-python/

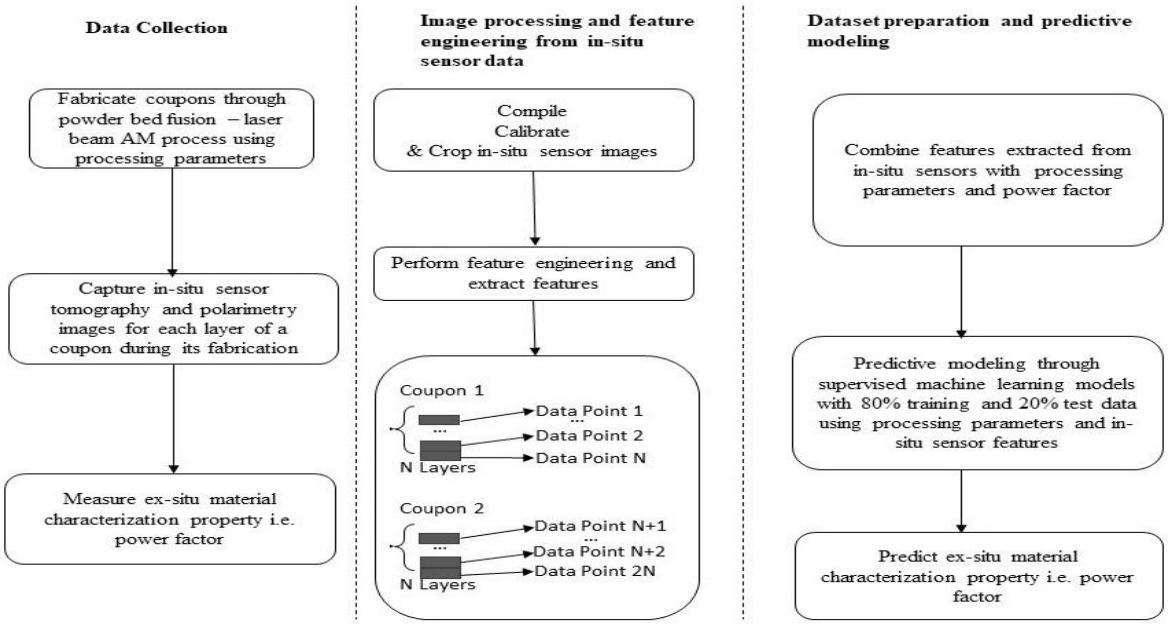

图　　2：利用工艺参数和原位传感器数据预测功率因数的框架

3.4 机器学习模型

我们按照复杂度递增的顺序，试验了四类机器学习模型，利用工艺参数和原位传感器特征预测一种称为功率因数的材料属性：1）线性模型；2）非线性核模型；3）自助法（集成）模型；以及 4）神经网络。线性模型包括朴素贝叶斯、逻辑回归和线性支持向量机（SVM）；非线性模型则选用了多项式核支持向量机和径向基函数支持向量机。我们采用决策树、随机森林、装袋分类器或自助聚合器，以及AdaBoost分类器作为集成模型，并采用多层感知机作为神经网络模型。由于用作目标变量预测因子的各项参数取值范围不同，我们对工艺参数和原位传感器特征进行了特征缩放（标准化），将其归一化至 0 到 1 的范围。随后，我们按照 80:20 的训练与测试比例划分数据集。随机抽取的数据集中的 80% 用于训练机器学习模型，其余 20% 用于测试机器学习模型的性能。我们使用 Python scikit-learn库[3]实现了这些模型。

朴素贝叶斯分类器是一种概率分类器，它基于贝叶斯定理，并采用强的“朴素”特征间独立性假设。逻辑回归根据一个或多个自变量的线性组合来估计事件发生的概率。支持向量机采用最大间隔方法，在 n 维输入变量空间中，通过适当的超平面将两类观测数据点分开。我们使用三种核函数实现了支持向量机。线性支持向量机用于线性可分的数据。多项式核支持向量机使用多项式函数将数据映射到高维空间，从而使各类别能够由超平面分开。同样，当各类别无法线性分开时，则使用径向基函数核支持向量机（径向基函数核支持向量机）。

决策树采用基于规则的方法或树状模型，根据应用于自变量的条件对输出进行分类。随机森林是一种用于分类的集成学习方法，它在训练时通过构建大量决策树来工作。我们将模型中的决策树数量设为 50。类似地，AdaBoost分类器和装袋分类器也属于集成学习方法。在 AdaBoost算法中，会依次训练一系列模型。首先训练第一个模型，该模型在预测时会产生一些错误。接下来的模型会更加关注前一个模型中预测错误的数据点

[3] https://scikit-learn.org/stable/

，并为这些数据点赋予更高的权重。这样，一系列模型便组合起来进行单次预测。我们将估计器数量设为50，并在此时终止提升法。装袋法是一种基于决策树的自助聚合集成元估计器，它从同一训练集中有放回地生成随机样本。随后，在每个随机样本上并行训练一个模型。最后，将所有这些模型的结果合并。如果目标变量是类别型，则对不同模型的结果进行多数投票。反之，如果目标变量是数值型，则计算所有模型结果的平均值。我们将估计器数量设为 50，以实施装袋法。多层感知机是一种人工神经网络，由三层节点组成：输入层、隐藏层和输出层，用于预测输出。

功率因数的取值是连续的，因此我们根据中位数将其分为高、低两类。低于中位数的功率因数值归为 0 （低功率因数），高于中位数的值归为 1 （高功率因数）。为了分析机器学习方法的性能，我们采用准确率、F1分数、精确率、召回率和受试者工作特征曲线下面积（ROC AUC）作为性能指标。

3.5 特征选择

为了筛选出对预测功率因数有重要作用的特征，我们采用了置换特征重要性技术。置换特征重要性定义为：在其他特征保持不变的情况下，随机打乱单个特征的取值后，模型得分的下降幅度。这样做是为了打破该特征与目标之间的关系。模型得分的下降幅度反映了模型对该特征的依赖程度。我们使用 Python scikit-learn库[5]实现了置换特征重要性技术。

4 结果

表1展示了不同机器学习方法在使用工艺参数和原位传感器特征预测功率因数时的性能结果，这些方法按模型复杂度从低到高排列。可以看出，与其他机器学习方法相比，随机森林、AdaBoost分类器和装袋法等集成方法在预测功率因数方面表现最佳，准确率最高。

使用置换特征重要性技术选出的用于预测功率因数的顶级工艺参数和原位传感器特征及其

表1：使用工艺参数和原位特征，采用不同机器学习方法预测功率因数的性能指标，按模型复杂度从低到高排列。最佳模型（装袋分类器）的结果以粗体突出显示。

分类模型	P	R	F1	AUC	Acc.
朴素贝叶斯	0.72	0.72	0.72	0.77	0.72
逻辑回归	0.68	0.68	0.68	0.76	0.68
线性支持向量机	0.68	0.68	0.68	0.75	0.68
多项式核支持向量机	0.68	0.67	0.67	0.75	0.67
径向基函数核支持向量机	0.68	0.68	0.68	0.75	0.68
决策树	0.88	0.88	0.88	0.97	0.88
随机森林	0.89	0.89	0.89	0.97	0.89
AdaBoost分类器	0.88	0.88	0.88	0.88	0.88
装袋分类器	**0.90**	**0.90**	**0.90**	**0.98**	**0.90**
多层感知机	0.74	0.73	0.73	0.79	0.73

注：P：精确率，R：召回率，F1：F1分数，AUC：受试者工作

特征重要性评分和标准差如表2所示。特征选择的结果表明，在预测功率因数时，工艺参数比原位传感器参数更为重要。此外，研究发现，与断层成像传感器特征相比，偏振测量传感器特征在预测功率因数方面更为重要。

5 讨论

本研究在利用Bi_2Te_3材料对试样进行PBF-LB增材制造过程中，确定最适合预测热电材料功率因数的机器学习模型方面发挥了作用。研究发现，基于集成的模型最适合表征Bi_2Te_3这类材料的热电材料性能。该发现与早期研究结果一致：这些研究使用基于集成的分类方案，利用以逐层图像形式获取的原位传感器数据，在增材制造过程中检测缺陷 [25] ，并且表明没有任何单一工艺参数能够决定材料性能。

集成学习适用于为基于样本的数据构建机器学习模型，例如在增材制造过程中收集的数据。这样，当构建过程中采用次优工艺参数而出现异常点时，模型的整体准确率所受影响会较小。这一点很重要，因为我们事先并不知道这些值是什么，而且希望创建稳健的机器学习模型，以学习影响制造过程的“弱特征”。具体而言，当影响热学和电学性质的工艺参数超过两三个时，就会出现这种情况。模型可以使用随机抽取的数据点进行训练，也可以反复抽取异常数据点，并在训练过程中赋予它们更高的权重。

[5] https://scikit-learn.org/stable/modules/permutation_importance.html

表2：前15项重要特征及其平均重要性得分和标准差

S. No.	特征	平均得分和标准差
1.	激光焦点（毫米）	0.142 +/- 0.007
2.	功率（W）	0.070 +/- 0.005
3.	速度（mm/s）	0.052 +/- 0.008
4.	铺展后偏振测量 AoP 粗糙度	0.033 +/- (
5.	层（mm）	0.030 +/- 0.004
6.	熔化后偏振测量 AoP 粗糙度	0.029 +/- 0.006
7.	扫描间距（mm）	0.026 +/- 0.002
8.	铺粉后偏振测量 AoP 标准差	0.017 +/- 0.005
9.	层析成像粗糙度	0.014 +/- 0.003
10.	融化后偏振测量线偏振度标准差	0.013 +/- 0.004
11.	融化后偏振测量偏振角标准差	0.012 +/- 0.005
12.	偏振测量铺粉后线偏振度最大值	0.012 +/- 0.004
13.	层析成像中位数	0.011 +/- 0.004
14.	层析成像平均值	0.010 +/- 0.003
15.	偏振测量熔化后偏振角中位数	0.010 +/- 0.004

注：AoP：偏振角，DoLP：线偏振度，std：标准差，max：最大值，

这样也能降低模型的偏差和方差 [26]。工艺参数在预测功率因数方面发挥着重要作用，但由于这些值在试样的每一层都保持不变，利用从原位传感器采集的图像进行特征工程，也能揭示逐层监测数据，从而深入了解制造过程和材料的热电性能。粗糙度就是这样一种通过原位传感器数据测得的特征。研究发现，在粉末铺展和熔化过程中，根据层析成像和偏振测量数据得到的表面粗糙度，是预测 Bi_2Te_3 功率因数的重要特征。因此，如果粗糙度值超过某个阈值，可能就需要中止制造过程，因为材料性能可能不合格，并会对用该材料制造的部件产生不利影响。在增材制造过程中被确定为重要特征的层析成像中位数和层析成像平均值表明，减少热成像图中的亮斑或暗斑，并找到合适的激光功率以降低孔隙率，是十分重要的。最后，铺展和熔化粉末后，偏振测量数据中像素强度的标准差表明，应根据这些偏差调整采用 Bi_2Te_3 制造的物体部件的设计或几何形状 [27]。这些最适于预测功率因数的参数还可以进一步优化，以最大限度地提高功率因数，增强热电材料发电或泵热的能力。

由于样本量较小，为增材制造过程设计机器学习模型存在自身的局限性和挑战。未来可以实施少样本学习等技术 [28]，以应对样本量较低的限制。此外，本研究依赖于传感器所采集图像的精确率和质量。整合来自多个传感器的数据可以揭示逐层制造工艺中的重要模式。

6 结论

为了提高通过 PBF-LB 激光束粉末床熔融增材制造制备的热电材料产品质量，能够预测该材料的重要特性——功率因数至关重要。本研究采用监督式机器学习技术，利用制造过程中涉及的工艺参数以及采集的原位传感器数据，构建机器学习模型来预测 Bi_2Te_3 的功率因数。我们发现，装袋法等集成方法在预测 Bi_2Te_3 的功率因数方面表现最佳，准确率达到 90%。此外，我们筛选出工艺参数和原位传感器特征中的前 15 个特征，用于表征材料的功率因数等制造特性；这些特征还可进一步优化，以最大限度地提高该热电材料的功率因数。

资助致谢

作者衷心感谢美国能源部提供的资助（奖项编号

1010413）。

致谢

作者感谢 Wright State University 的硕士生 Alexander H. Greoger 和博士生 Amanuel Alambo 在图像处理和机器学习算法的初步开发中提供的协助。

参考文献

[1] K. V. WONG 和 A. HERNANDEZ，《增材制造综述》，ISRN机械工程，（2012），第 1–10 页。[2] H. Z HANG、D. HOBBIS、G. S. NOLAS 和 S. LEBLANC，《粉末碲化铋的激光增材制造》，Journal of Materials Research，33（23）（2018），第 4031–4039 页。[3] C. OZTAN、B. ŞIŞIK、R. WELCH 和 S. LEBLANC，《激光加工热电材料 Bi2Te3 的工艺-微观结构关系》，《电子材料前沿》，2（2022）。[4] H. ZHANG 和 S. LEBLANC，《碲化铋热电材料的激光增材制造工艺开发》，《材料工程与性能杂志》，31（8）（2022），第 6196–6204 页。

[5] C. OZTAN、R. WELCH 和 S. LEBLANC，《块体热电结构的增材制造：综述》，Energies，15（9）（2022），3121。[6] R. WELCH、D. HOBBIS、A. J. BIRNBAUM、G. NOLAS 和 S. LEBLANC，激光加工过程中形成的纳米和微米结构：硒掺杂碲化铋，Advanced Materials Interfaces，8（15）（2021），2100185。[7] M. GRASSO、A. REMANI、A. DICKINS、B. M. COLOSIMO 和 R. K. LEACH，《金属粉末床熔融的原位测量与监测方法：最新综述》，Measurement Science and Technology，32（11）（2021），112001。[8] H. S. KIM、W. LIU、G. CHEN、C.-W. CHU 和 Z. REN，《热电优值与能量转换效率之间的关系》，美国国家科学院院刊，112（27）（2015），第 8205–8210 页。[9] A. EL-DESOUKY、M. CARTER、M. A. ANDRE、P. M. BARDET 和 S. LEBLANC，《用于能量转换器件的半导体热电材料快速加工与组装》，Materials Letters，185（2016），第 598–602 页。[10] N. BATISTA、J. CRANDALL、A. EL DESOUKY、S. LEBLANC、S. WANG 和 J. YANG，《选择性激光熔化用热电材料的粉末冶金表征》，载于 TechConnect Briefs，4（2017），第 166–169 页。[11] C. WANG、X. TAN、E. LIU 和 S. B. TOR，《通过选择性电子束熔化增材制造的 316L不锈钢部件的工艺参数优化与力学性能》，Materials & Design，147（2018），第 157–166 页。[12] G. TAPIA、S. KHAIRALLAH、M. MATTHEWS、W. E. KING 和 A. ELWANY，《用于激光粉末床熔融增材制造 316L不锈钢工艺规划的基于高斯过程的代理建模框架》，The International Journal of Advanced Manufacturing Technology，94（9–12）（2018），第 3591–3603 页。[13] B. KAPPES、S. MOORTHY、D. DRAKE、H. GEERLINGS 和 A. STEBNER，《利用机器学习优化 Inconel 718 激光粉末床熔融的增材制造参数》，The Minerals, Metals & Materials Series，（2018），第 595–610 页。[14] W. ZHANG、A. MEHTA、P. S. DESAI 和 C. F. HIGGS III，《机器学习支持的金属增材制造（AM）粉末铺展工艺图》，载于国际固态自由成形制造研讨会，得克萨斯州奥斯汀，2017。[15] A. DOUARD、C. GRANDVALLET、F. POURROY 和 F. VIGNAT，《机器学习应用于增材制造的一个示例》，载于 IEEE工业工程与工程管理国际会议（IEEM），2018[16] A. GARG、J. S. L. LAM 和 M. M. SAVALANI，《一种用于建立增材制造过程中开口孔隙率函数关系的新型计算智能方法》，The International Journal of Advanced Manufacturing Technology，80（1-4），（2015），第 555 页

–565.

[17] Y. ZHANG、G. S. HONG、D. YE、K. ZHU 和 J. Y. H. FU，粉末床熔融增材制造过程监测中熔池、羽流和飞溅信息的提取与评估，《Materials & Design》，156（2018），第458–469页。[18] L. SCIME 和 J. BEUTH，利用机器学习识别激光粉末床熔融增材制造过程中表征缺陷形成的原位熔池特征，《增材制造》，25（2019），第151–165页。[19] M. GRASSO、V. LAGUZZA、Q. SEMERARO 和 B. M. COLOSIMO，选择性激光熔化的过程监测：通过图像数据分析进行缺陷的空间检测，《制造科学与工程学报》，138（5）（2017）。[20] J. Z. JACOBSMUHLEN、J. ZUR JACOBSMUHLEN、S. KLESZCZYNSKI、G. WITT 和 D. MERHOF，激光束熔化过程中表面图像中隆起区域的检测，载于《IECON 2015——IEEE工业电子学会第41届年会》，2015年[21] M. KHANZADEH、S. CHOWDHURY、M. A. TSCHOPP、H. R. DOUDE、M. MARUFUZZAMAN 和 L. BIAN，定向能量沉积过程中用于孔隙率预测的熔池图像原位监测，《IISE汇刊》，51（5）（2019），第437–455页。[22] D. CHERNYAVSKY、J. VAN DEN BRINK、G. PARK、K. NIELSCH 和 A. THOMAS，利用机器学习预测的可持续热电材料，《高级理论与模拟》，5（11）（2022），2200351。[23] Y. GAN、G. WANG、J. ZHOU 和 Z. SUN，通过高通量第一性原理计算和机器学习预测层状 IV-V-VI族半导体的热电性能，《npj计算材料》，7（1）（2021）。[24] R. R. MONTGOMERY 和 J. E. BENKSTEIN，NIST标准参考物质（SRM）2018年目录，2018年[25] C. GOBERT、E. W. REUTZEL、J. PETRICH、A. R. NASSAR 和 S. PHOHA，应用监督式机器学习，利用高分辨率成像检测金属粉末床熔融增材制造过程中的缺陷，《增材制造》，21（2018），第517–528页。[26] X. XIAOYU、J. BENNETT、S. SAHA、Y. LU、J. CAO、W. K. LIU 和 Z. GAN，金属增材制造中成形态力学性能的基于机理的数据驱动预测，《npj计算材料》，7（1）（2021），第86页。[27] K. ÖZSOY、B. AKSOY 和 O. K. M. S
尺寸精
报》，
R. ZAF ILI，可解释的基于概念的原型网络用于少样本学习，载于《2022年IEEE国际图像处理会议》（ICIP），法国波尔多，2022年。