

基于机器学习的激光微纳加工研究:应用和前景

龚伟¹, 赵文华¹, 王心田¹, 李臻¹, 王熠², 赵新景¹, 王晴¹, 王艳辉^{1*}, 王磊¹, 陈岐岱¹¹吉林大学电子科学与工程学院, 集成光电子学国家联合重点室, 吉林 长春 130012;²清华大学精密仪器系, 精密测试技术及仪器国家重点实验室, 北京 100084

摘要 随着人工智能技术的不断发展,激光工业制造的智能化已成为重要趋势。机器学习作为人工智能的主要技术之一,已经在相关领域得到了广泛应用,并促进该领域实现巨大突破,推动下一代激光微纳加工技术的发展。为此,本文综述了机器学习在激光微纳加工领域各工艺过程中的重要应用,包括激光微纳加工参数优化与工艺窗口预测、加工过程的实时监测与控制、加工结果的预测以及辅助物理机制的研究,总结并展望了当前已有的机器学习与激光微纳加工交叉方向的改进方案,以及未来可能出现的机器学习与激光微纳加工交叉技术的进一步应用。

关键词 激光技术; 光学制造; 微纳加工; 过程控制; 人工智能; 机器学习

中图分类号 TB31 文献标志码 A

DOI: 10.3788/CJL230827

1 引言

自激光被发明以来,激光切割^[1-3]、激光清洗^[4-6]、激光钻孔^[7-9]、激光雕刻^[10-12]、激光烧蚀^[13-15]、增材制造^[16-18]和激光焊接^[19-21]等技术就被应用于航空航天、汽车、电子、电池、医疗、3D打印、半导体、传感器和太阳能等领域^[22-24],并随着科技的进步向更精细(由毫米到微米甚至纳米)、更高效(百 mm²/s 处理速度)、随形(三维)、随性(多种材料)的方向发展。激光微纳加工具有无材料选择性、三维加工、快速去除等优点^[25]。但是激光与物质相互作用的复杂物理机制限制了其进一步发展,探究激光与物质相互作用的微观、纳观空间尺度以及纳秒甚至飞秒时间尺度内的物理过程,包括光-物质相互作用、热传导、材料的相变和材料去除等,是推动激光微纳加工技术前进的关键^[26]。

人工智能技术为解决当前激光微纳加工领域面临的瓶颈问题提供了新思路,对于该领域而言是一个重大补充。它通过统计技术和数值算法执行任务,不需要明确的编程和程序指令,能够实现辅助分类、模式识别、预测、系统参数优化以及构建复杂的动力学模型。例如:在不借助激光激发电子、电子-晶格能量传递物理模型的前提下,该技术仅利用神经网络和实验数据便可实现光与物质相互作用物理过程的建模^[27-46];激光微纳加工产品的质量以及特殊结构的产生依赖于激光参数,只有最佳的激光微纳加工参数才能得到理想的加工效果,利用机器学习的分类技术不仅可以大大加速

加工过程中缺陷检测的进程^[47-61],还可以革新传统的依赖于预先设定加工路径的激光微纳加工过程控制方法^[62]。通常情况下,优化特定激光微纳加工任务的主要方法是扫描可用参数空间的子集,并监测激光输出,以获得最佳加工结果。当激光参数较多时(例如,5个参数中的每一个参数均在一定范围内取10个值,总共需要进行10⁵次实验),这将耗费大量的时间和精力。即使找到了最佳参数,微小的制造变化(如激光功率波动或光束形状畸变)也可能导致最终的产品质量低于标准,从而再次带来额外的时间和金钱成本。针对如此高度复杂的系统,基于机器学习的方法能够将繁琐的加工参数优化任务简化。在这些新方法中,人工神经网络是一种高效的方法,已被众多研究人员用来预测指定输入参数范围内的加工过程的各种输出。当模型建立之后,研究人员常常利用优化技术确定最佳的输入控制参数,以便使输出参数最小化或最大化^[27-46]。

这篇综述首先回顾了一些主要的机器学习算法(包括学习算法、优化算法)以及分类任务的主要流程,并讨论了几种深度学习模型(从全连接神经网络到生成对抗神经网络),这些模型已在蛋白质结构设计、语音识别、无人驾驶等领域实现了突破性进展。然后综述了机器学习在激光微纳加工各个工艺过程中的重要应用(如图1所示),并强调了深度神经网络的制定、发展和优势。最后展望了当前已有的激光智能加工改进方案以及未来可能出现的机器学习与激光微纳加工交叉技术的进一步应用。

收稿日期: 2023-05-11; 修回日期: 2023-06-24; 录用日期: 2023-07-11; 网络首发日期: 2023-07-30

基金项目: 吉林省科技发展计划项目国家重点实验室(学科类)重大专项(SKJ202302012)、国家自然科学基金(61827826, 62175086, 62131018)、吉林省科技发展计划基金(20220101107JC)、吉林省教育厅基金(JJKH20221003KJ)

通信作者: *yanhuiwang@jlu.edu.cn

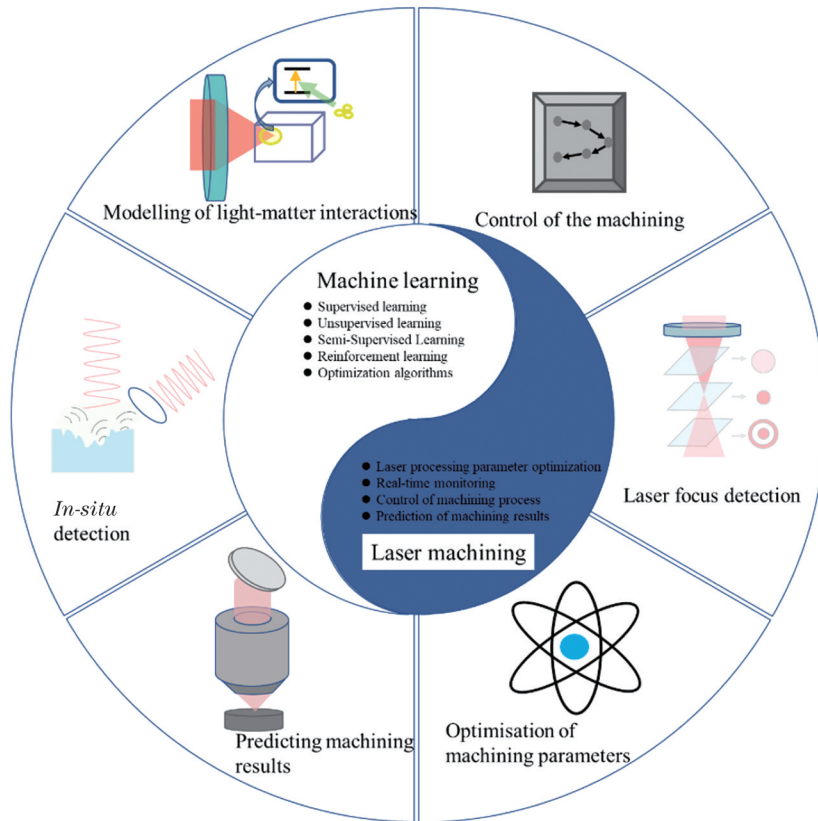


图 1 常用的机器学习算法及其在激光微纳加工各工艺流程中的应用

Fig. 1 Commonly used machine learning (ML) algorithms and their application in various processes of laser micro/nano machining

2 机器学习简述

机器学习本质上是一种通过计算来近似或模仿人类识别模式与经验学习的能力^[63],数据、算法、模型是机器学习的三个要素^[64]。机器学习的流程是先将现实中的任务抽象为数据,通过选取合适的模型从数据集(一般称为训练集)中自动地归纳特征或逻辑,然后对模型进行优化,最后根据优化后的模型对新数据进行预测^[65]。当需要分析的数据集太复杂(包含大量特征)而无法进行人工分析时,机器学习尤其有用。除此之外,该技术还能使机器通过不断“学习”来提高自身性能并做出最优决策。简而言之,机器学习就是让机器获得“自我学习”的能力^[64]。

常用的机器学习算法可以分为监督学习、无监督学习、半监督学习以及强化学习^[66]。除了这些学习算法之外,现有的激光智能加工研究还使用了优化算法,其中常用的有遗传算法(GA)、粒子群优化算法(PSO)等,其目的是按照特定算法搜索优化空间,以找到最优解。

监督学习:本质上来说就是从已有的数据集中学习输入与输出之间的映射关系,从而发现两者之间存在的隐藏关系。也就是说,每一个数据样本都对应一个“标签”,这也是这一模型被称为“监督学习”的原因。基于这一特性,监督学习常常被用来建立激光微纳加工过程所涉及的物理模型,实现高保真计算建模、辅助光与物质相互作用物理机制研究以及激光微纳加工参

数优化^[27-46]。

无监督学习:在激光微纳加工过程中常常存在缺陷,基于监督学习的分类算法可以很好地分类已知缺陷,但因模型内禀的算法限制无法做到对未知的缺陷类型进行分类。无监督学习可以很好地解决这一问题。当数据样本都没有对应“标签”时,无监督学习模型也可以从数据集中聚类出数据类型,从而做到分类^[51-52]。

强化学习:强化学习模型的核心思想是交互与评价,算法的每一次决策都会通过人为定义的价值函数进行评价,这样的评价机制决定了模型参数的优化方向,从而使模型能够做出最优的决策。基于强化学习的激光微纳加工系统能面对异常情况做出最佳决策,进而实现激光微纳加工的自动化控制,不仅能提升加工系统的反馈控制能力,还能自我优化出合适的路径规划策略^[62]。

半监督学习^[54]:在监督学习模型的训练过程中,训练样本是至关重要的,不仅需要大量样本,还需要对这些样本进行人工标记。在激光微纳加工领域,训练样本的获取过程极为费时,而半监督学习模型可以结合少量标记数据与大量未标记数据,通过归纳学习的方法来推断数据的正确标签,这一模型大大促进了机器学习在激光微纳加工领域应用的可行性。

在众多模型中最值得一提的是深度学习模型。该模型旨在让计算机从数据中学习经验,并根据层次化的概念体系来理解世界,而每个概念则通过与某些相

对简单的概念之间的关系来定义。层次化的概念让计算机通过构建较简单的概念来学习复杂概念。如果绘制出这些概念之间的相互关系图,就可以得到一张层次很“深”的图(类似于神经元的连接),其典型的代表是神经网络模型^[67]。根据通用近似定理^[68-69],一个神经网络如果具有线性输出层和至少一层具有任何一种“非线性”性质的激活函数(例如 logistic、sigmoid 激活函数)的隐藏层,只要给予网络足够数量的隐藏单元,它就可以以任意精度来近似任何一个从有限维空间到另一个有限维空间的 Borel 可测函数。神经网络的导数也可以以任意精度来近似函数的导数^[70],简单地说就是,神经网络可以近似从任何有限维离散空间映射到另一个有限维离散空间的任意函数。

深度学习是机器学习模型的一个重要分支,泛化性好的模型能够在未曾参与训练的新数据集(测试集)上表现良好,而不仅仅是在训练集上表现优秀。通常情况下,人们在训练集上训练模型,并计算其误差度量(即训练误差),然后不断迭代更新模型参数(这个寻找最佳参数的过程被称为优化)以达到最小化训练误差的目的。机器学习和优化之间的不同之处是:优化旨在使模型的训练误差最小化,而机器学习的目标是在此基础上(通常采用正则化策略,以增大训练误差为代价来减小测试误差)使模型的泛化误差(也称为测试误差)尽可能小。总体而言,机器学习由模型表示、优化和模型评估三部分组成,即:将实际问题转化为待解决的模型,利用优化算法求解模型,使用验证或测试数据评估模型。迭代执行这三个步骤,通常可以得到理想的模型。这样的模型可以解决许多问题,例如激光微纳加工过程中激光参数到加工参数的映射^[27-46]、加工结果的预测^[71-73]、物理过程的反演问题^[74-80]等。

根据网络结构的不同,深度神经网络主要分为以下四类:

1) 全连接神经网络(FCNN)。其结构相当简单,由输入层、隐含层、输出层构成,主要应用于预测和分类问题。

2) 卷积神经网络(CNN)。它是深度学习的代表算法之一。CNN 仿照生物的视觉和知觉机制构建而成,可以进行监督学习和非监督学习,其隐含层的卷积核可以对图像和音频数据进行特征提取。

3) 循环神经网络(RNN)。其特点是具有记忆性,参数共享并且图灵完备,对于具有序列特性(时间顺序、逻辑顺序等)的数据非常有效,能挖掘数据中的时序信息和语义信息。

4) 深度生成模型。该模型不是用来确定条件分布和决策边界的,而是用来描述输入和输出的联合分布,并以概率生成的方式优化某个目标。它与前面的模型不同,不是用于对数据进行预测、分类,而是用于生成数据。

分类流程:在激光微纳加工过程的缺陷检测中,常常会遇见因异常情况而出现的加工缺陷,针对不同

的缺陷需要做出不同的反馈,这是一个典型的分类任务。在机器学习分类任务的解决范式中,需要通过特征提取技术对输入进行特征提取,然后将得到的特征输入到分类器中进行分类。在这个任务中,存在着传统方法和深度学习两种不同的特征提取方式。传统方法主要通过人工设计特征,然后将其输入到分类器中;而深度学习方法则采用卷积核的方式实现特征的提取,这种特征不具有可解释性。虽然近些年已出现了相关的神经网络的可解性研究,但它们大都研究局部可解性,即研究输入的某一部分对分类结果的影响。激光智能加工中常用的深度学习模型和分类流程如图 2 所示。

通常情况下,上述类型的机器学习算法和模型可以解决现有的许多问题。本综述介绍了大部分机器学习方法,包括传统的机器学习方法以及使用人工神经网络的深度学习。虽然深度学习算法正在成为许多任务的最有效方法,但在许多情况下,传统方法仍然是最佳选择。当然,模型并不是最重要的因素,最重要的是针对不同的任务选择合适的模型。即使使用相同的模型,也需要根据具体情况进行适当调整。因此,接下来将介绍不同模型适用的任务。

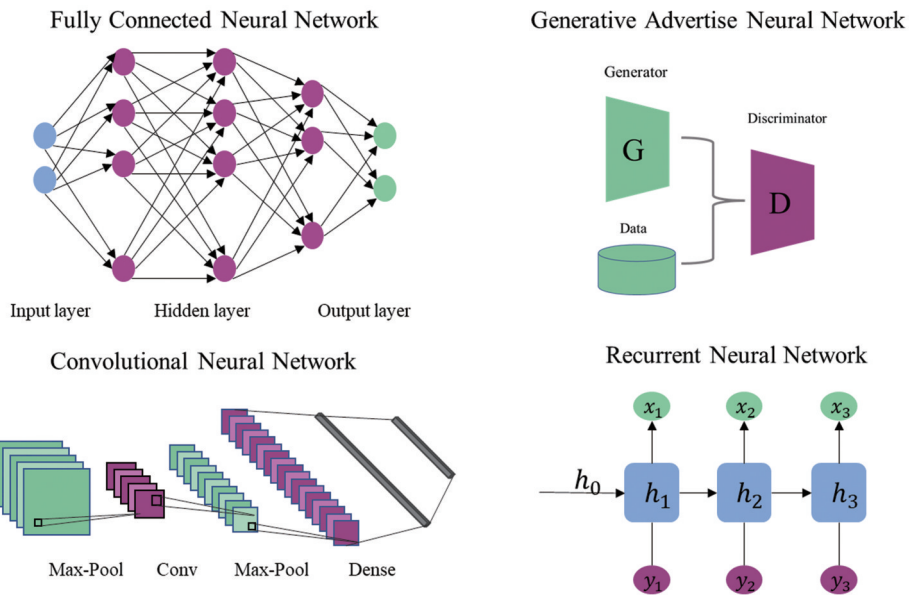
3 机器学习在激光微纳加工各工艺流程中的应用

激光微纳加工是一种精密加工技术,通过控制激光光束的聚焦位置,可以在微米和纳米尺度下进行高效的加工和制造。为了获得最佳的工艺效果,研究人员需要对加工参数进行优化,并预测适宜的工艺窗口。然而,工艺效果与许多参数之间存在复杂的相关性,通常需要耗费大量的时间和金钱成本来确定最佳的参数组合。利用神经网络建立工艺效果与加工参数之间的映射关系可以大大缩短这一过程,有助于加快工艺优化过程,降低成本,同时为精密加工领域的进一步研究和发展提供了重要启示。

3.1 激光微纳加工参数优化与工艺窗口预测

一个典型的例子是激光冲击钻孔工艺参数优化^[36]。Nakhjavani 等^[36]使用功率为 400 W、波长为 1.06 μm 的 Nd:YAG 激光在 2.5 mm 厚的 EN3 软钢板上进行钻孔,氧气被用作辅助气体。为了得到两种不同优化目标(分别是孔口直径、孔口圆度和锥角最小以及孔口直径最大、孔口圆度和锥角最小)下所对应的激光参数(后续称为最佳输入参数,即峰值功率、脉冲宽度、脉冲频率、脉冲数、辅助气体压力和焦平面位置),图 3 所示的神经网络被用于建立激光参数与加工参数的映射。经过训练达到收敛后,模型可以快速地根据输入参数给出对应的输出参数(所需时间远远小于 1 ms),从而产生大量的十分接近实际实验的数据。然后,在大量预测数据的基础上,Nakhjavani 等根据遗传算法筛选出了最佳输入参数,这种方法远比没有采用优化算法而靠人为设

Model



Classification process




图 2 激光智能加工中常用的深度学习模型和分类流程

Fig. 2 Deep learning models generally used in laser intelligent machining and classification process

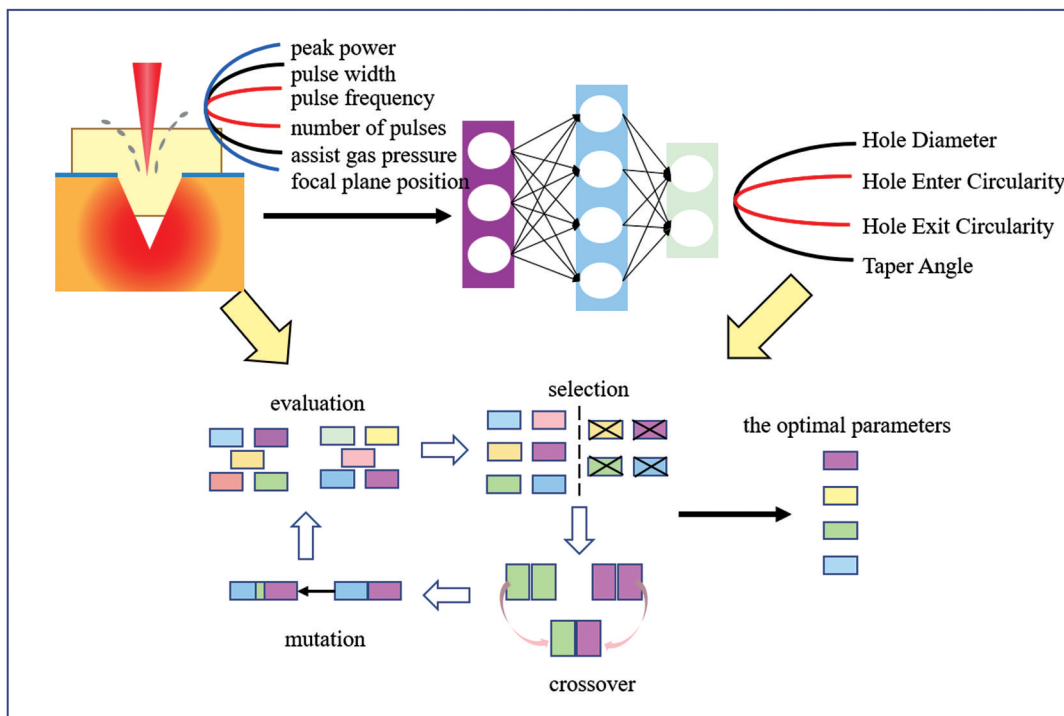


图 3 通过全连接神经网络和遗传算法优化激光冲击钻孔工艺参数

Fig. 3 Optimization of laser impact drilling process parameters by fully connected neural networks and genetic algorithms

定简单规则判断最优参数的方法更具有效性。

虽然遗传算法非常具有前景,但其基于基本算子(如交叉率和变异率)进行迭代,所以这些参数的选择会严重影响解的品质。目前,这些参数的选择大部分依靠

经验,因此需要仔细设计。遗传算法的另一个主要缺点是收敛速度相对较慢,要得到较精确的解需要较多的训练时间。表 1 总结了目前激光微纳加工研究中常用的用于优化激光加工参数的一些机器学习算法的特点。

表 1 用于激光微纳加工参数优化的机器学习算法

Table 1 Machine learning algorithms used to optimize laser micro/nano machining process parameters

Process	Input parameter	Model	Output parameter	Optimization goal	Optimization algorithm	Ref.
Laser percussion drilling	Peak power, pulse width, pulse frequency, the number of pulse, assist gas pressure and focal plane position	ANN	Hole diameter, hole enter circularity, hole exit circularity, and taper angle	Maximized or minimized	Genetic algorithm	[36]
CO ₂ keyhole laser welding of medium carbon steel butt weld	Welding speed, laser power, shielding gas and the focal position	ANN	Actual penetration depth, melting area width and the width of the heat-affected zones	Maximized or minimized	Manual evaluation	[27]
CO ₂ laser cutting of aluminum alloy	Laser power, welding speed and gas pressure	ANN	Surface roughness, kerf width and kerf taper	Minimized	Particle swarm optimization and genetic algorithm	[29]
CO ₂ laser cutting	Laser power and feed rate	Regression analysis	Kerf width, surface roughness, striation frequency and the size of heat-affected zone	Minimized	Manual evaluation	[32]
The laser welding of aluminum alloys	Laser power, welding speed, and wire feed rate	ANN	Tensile strength of the weld	Maximized	Genetic algorithm	[33]
Fiber laser cutting stainless steel	Laser power, cutting speed, gas pressure, defocus	Generalized regression neural network	Kerf width and surface roughness	Minimized	Non-dominated sorting genetic algorithm	[42]
Laser bending	Laser power, spot diameter, pulse duration and scanning speed	ANN	Bending angle	Maximized	Teaching-learning-based optimization algorithm	[34]

3.2 加工过程的实时监测与控制

原位监测和反馈控制一直被认为是推进激光微纳加工最需要的技术之一。然而,目前工艺流程的实时监控能力有限,在很大程度上仍是开环的。虽然成像装置可以在加工过程中提供可视化图像,但它们缺乏自动分析能力。因此,利用机器学习实时处理和分析加工过程中遇到的各种异常问题,很可能成为机器实时控制系统的一种重要功能,这将会使机器具备智能化能力。

3.2.1 激光参数的识别

激光微纳加工过程中第一个需要考虑的问题是,激光输出或后续光束输送系统的不稳定性,即激光参数会随温度、湿度、材料改性的变化而变化,从而会影响加工质量。为此,在通用的激光微纳加工方案中,必须对加工光路和成像光路的激光参数进行实时监测。加工光路用于调控激光的各种参数(包括光斑坐标、激光能量、偏振等),成像光路用于收集激光在样品上加工的实时图像,辅助研究人员对加工结果进行分析。机器学习有着同时精确检测多个激光微纳加工参数的

潜力,为激光微纳加工过程的监控提供了一个通用和集成的解决方案。

Xie 等^[81]展示了 CNN 在检测光束平移和旋转方面的应用,以及其在薄膜激光微纳加工中的精确控制。在整个研究过程中,Xie 等通过 CNN[如图 4(b)所示]建立了光斑图像与光斑位移距离、旋转角度之间的映射关系,同时通过激光微纳加工后的样品图像预测了穿透薄膜所需的脉冲数。图 4(a)展示了用 CNN 预测加工任务的整个流程。图 4(c)和图 4(d)表明,光束平移距离即使小于相机像素,CNN 也可以实现精确检测。最后,Xie 等还展示了一种通过图像旋转和平移来实现数据增强的方法,这种方法显著地减少了训练神经网络所需的实验数据量。

此外,利用神经网络监测激光功率和偏振同样重要。Kwon 等^[82]将深度神经网络应用于激光选区熔化,研究了 6 种激光功率下熔池图像的分类模型,即通过激光微纳加工过程的熔池图像实时预测出对应的激光功率。他们采用该神经网络对 13200 张测试图像进

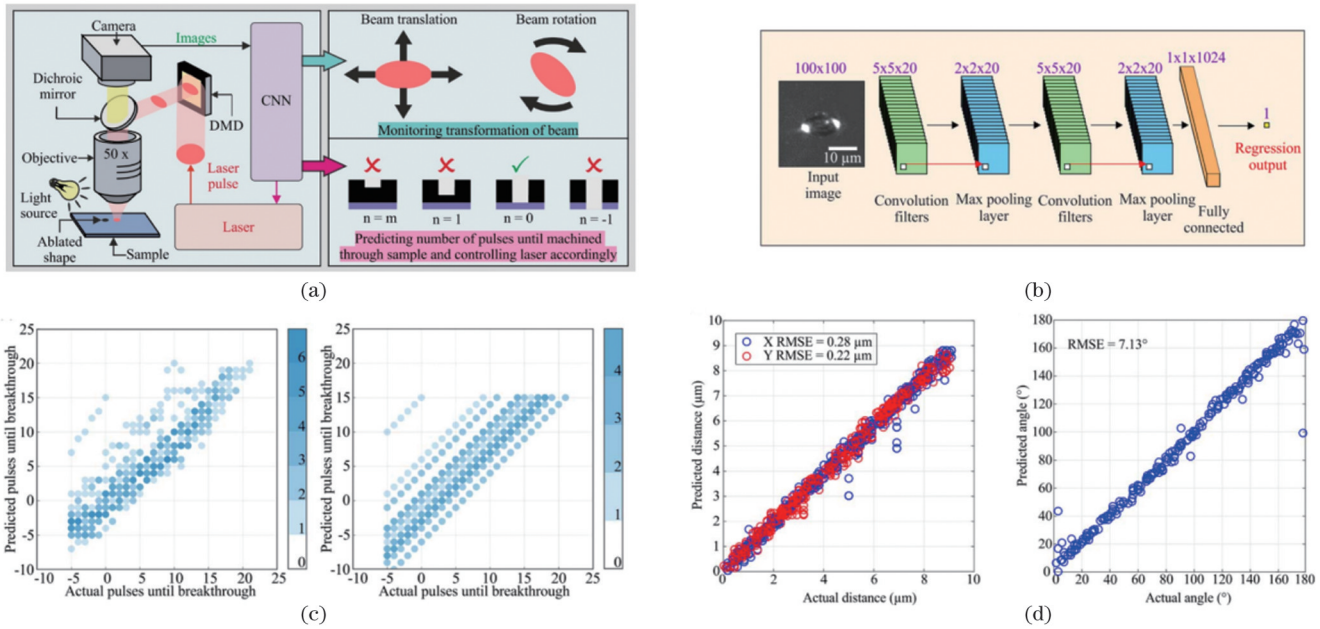


图4 机器学习应用于激光参数识别^[81]。(a)利用CNN实现闭环反馈的实验装置示意图;(b)CNN结构;(c)CNN预测薄膜突破前的剩余脉冲数;(d)CNN预测激光平移和旋转
 Fig. 4 Machine learning applied to laser parameter recognition^[81]. (a) Schematic of experimental setup for real-time closed-loop feedback realized by convolutional neural network (CNN); (b) CNN architecture; (c) CNN predicting the remaining number of pulses until breakthrough of a thin film; (d) predicting a beam transformation (translation and rotation) by CNN

行了分类,错误率低于1.1%。周期和直径可调的超表面能够在正交偏振态下实现任意组合的高性能颜色变换, Yang等^[83]通过残差卷积网络建立了超表面颜色变

化与入射偏振角之间的映射。如图5(a)所示。图5(b)展示了超表面是由周期和直径可调的纳米柱构成的。图5(c)显示了网络结构和分类结果。

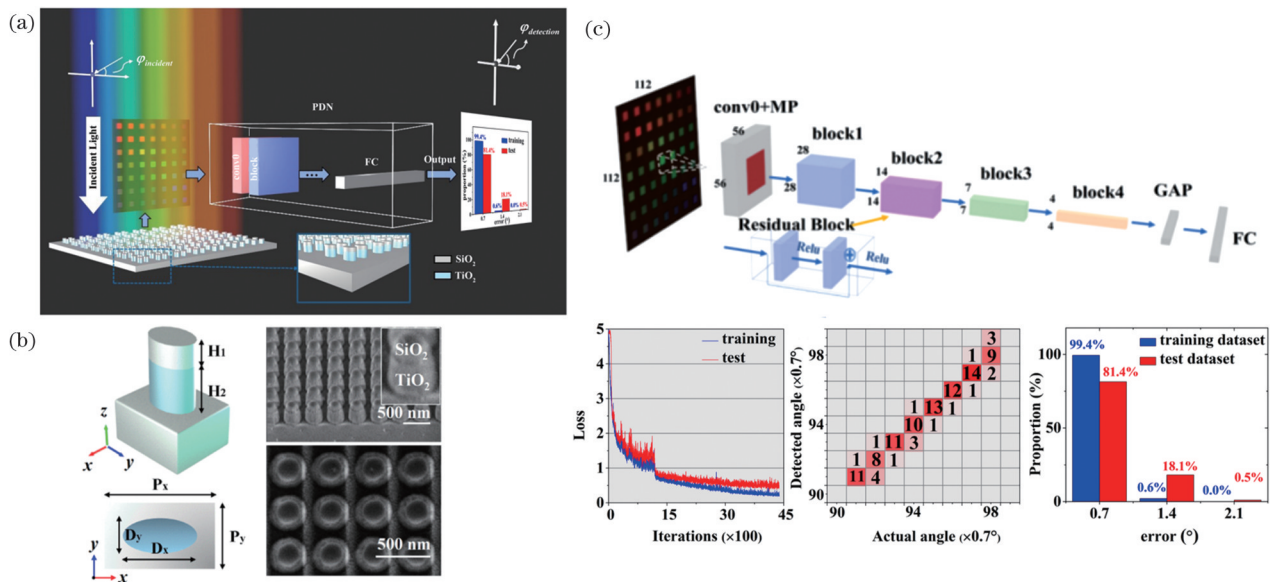


图5 机器学习应用于激光偏振检测^[83]。(a)通过色度检测偏振角原理图;(b)纳米柱示意图;(c)CNN预测偏振角度的准确性
 Fig. 5 Machine learning applied to laser polarization detection^[83]. (a) Schematic of colorimetric polarization-angle detection; (b) schematic of the nanopillar; (c) prediction accuracy of polarization angle by CNN

上述研究表明神经网络为解决激光参数优化问题提供了一种新的范式。只有对加工产品的视觉观察进行系统监控才能实现反馈控制,使制造精度得到提升,这也是激光微纳加工实现智能化的前提。

3.2.2 加工过程的实时监测

机器学习技术的应用还扩展到了激光增材制造领

域,例如激光选区熔化[SLM,也被称为激光粉末床熔融(L-PBF)]、激光选区烧结(SLS)、定向能沉积(DED)等。通过设计不同的人工智能方案介入激光增材制造过程,可以实现更高的制造质量。目前,增材制造工艺主要存在的质量问题是各种加工缺陷,如裂纹、分层、变形、表面粗糙、未熔合、气孔、工艺不稳定

(锁眼、球化)等。这些缺陷通常来自每层材料的沉积过程,可能从一个层传播到后续层,导致整个制造流程失败。因此,如果能实时监测制造过程中出现的缺陷,并将缺陷位置进行定位、分类,就能很好地增强激光微纳加工过程中的反馈控制。

相关研究表明机器学习技术已能够胜任激光增材制造过程中的缺陷分类任务^[47-61]。机器学习在激光增材制造缺陷检测的应用中主要分为两类。其中一类是增材制造过程中采用最广泛的进程监控方法,即:基于光学检测,将各种相机和传感器捕捉到的羽流、飞溅、熔池等表面图像作为输入。为了使模型具有更高的分类精度,光电二极管和高温计可以提供补充信息。由于图像具有较高的特征维数,很难进行分类,而机器学习能很好地处理高维特征分类问题,所以机器学习在激光增材制造进程的监控中越来越受欢迎。其中一个典型的例子是 Scime 等^[51]在 L-PBF 增材制造过程中的缺陷检测研究。L-PBF 中的许多重要缺陷与熔池本身的大小及其出现的时间尺度有关。为了探讨在原位

检测中熔池与后续所形成的缺陷之间的关系,Scime 等利用计算机视觉技术中常用的 SIFT (scale-invariant feature transform) 特征和 BoW (bag-of-words) 技术手工提取了熔池的特征,然后将特征数据进行无监督学习,将熔池自动分成了 50 个不同的类型,每一种熔池很可能变成相应的缺陷。由于非原位和原位形态之间存在联系^[84],因此可以利用监督学习[Scime 等采用的是支持向量机(SVM)模型]对熔池图像进行分类,从而通过原位特征推测最终形成的缺陷类型。Scime 等还利用这项技术对粉末扩散过程中的异常进行了检测和分类,这表明将传统机器学习方法用于缺陷检测具有一定的可行性^[52]。

相当多的研究表明,除了传统的机器学习方法外,深度学习也能参与 L-PBF 的缺陷分类。目前,多孔性缺陷是阻碍 L-PBF 技术广泛应用的主要因素,它是由输入过多激光能量而形成的不稳定的蒸气凹陷区(锁孔)导致的。Ren 等^[85]开发了一种检测随机锁孔孔隙生成事件的方法。他们从热成像序列[图 6(a)]中

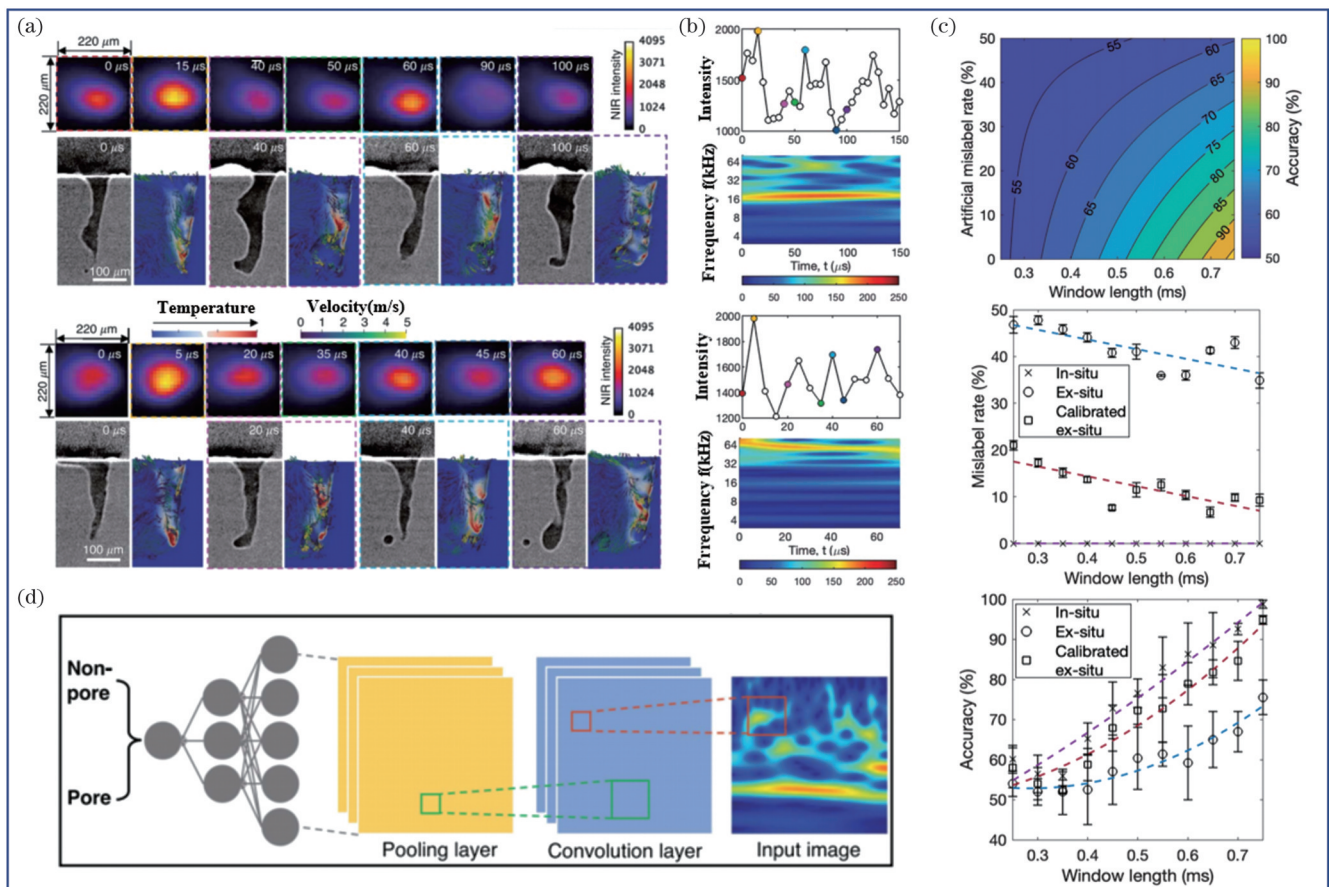


图 6 机器学习实时检测 L-PBF 中小孔生成的流程与结果^[85]。(a) 本征锁孔振荡和微扰锁孔振荡的热成像、高速 X 射线图像和相应的多物理仿真图; (b) 从热成像序列中提取的锁眼周围平均光发射强度的时间序列信号; (c) 机器学习检测孔隙的错标率和准确率随窗口长度的变化; (d) 用于分类“无孔”和“有孔”的神经网络的结构

Fig.6 Machine learning detecting flow and results of pore generation during L-PBF^[85]. (a) Thermal images, high-speed X-ray images and corresponding multiphysics simulation of intrinsic keyhole oscillation and perturbative keyhole oscillation; (b) time-series signal of the average light emission intensity around the keyhole extracted from thermal images series; (c) mislabeled rate and accuracy of machine learning detecting pore as a function of scalogram window length; (d) architecture of the proposed network for classifying “non-porous” and “porous”

提取小孔区域平均光发射强度的典型时间序列信号 [如图 6(b) 所示], 将其进行小波变换后输入到图 6(d) 所示的 CNN 中, 并利用 X 射线成像实现了高度准确的数据标记。图 6(c) 展示了该方法对 L-PBF 中小孔生成检测的准确性。这种方法实现了 100% 的检测准确度, 并且具有亚毫秒量级的时间分辨率。

为检测金属粉末在激光选区熔化过程中出现的缺陷, Caggiano 等^[58] 提出了一种基于深度卷积神经网络 (DCNN) 的机器学习方法。该方法针对 SLM 逐层处理过程中获取的图像进行分析, 通过自动的图像特征学习和特征融合实现了 SLM 缺陷状态相关模式的识

别。在该研究中, 由于 SLM 工艺的有序性, 粉末层和零件切片通过粉末重铺和激光扫描交替产生, 这意味着由工艺条件不当导致的缺陷 [如图 7(a) 所示] 会表现在两层的表面图案中。所以 Caggiano 等并不是简单地利用单个 DCNN [如图 7(d) 所示] 进行分类, 而是用两个 DCNN 并行处理激光扫描和粉末重铺时的图像, 最终预测了缺陷的类型并将预测结果 [如图 7(b) 所示] 与其他分类方法的结果进行了比较 [如图 7(c) 所示]。该研究证实了深度学习检测方法检测 SLM 工艺缺陷的有效性, 为自适应 SLM 工艺控制和零件质量保障提供了依据。

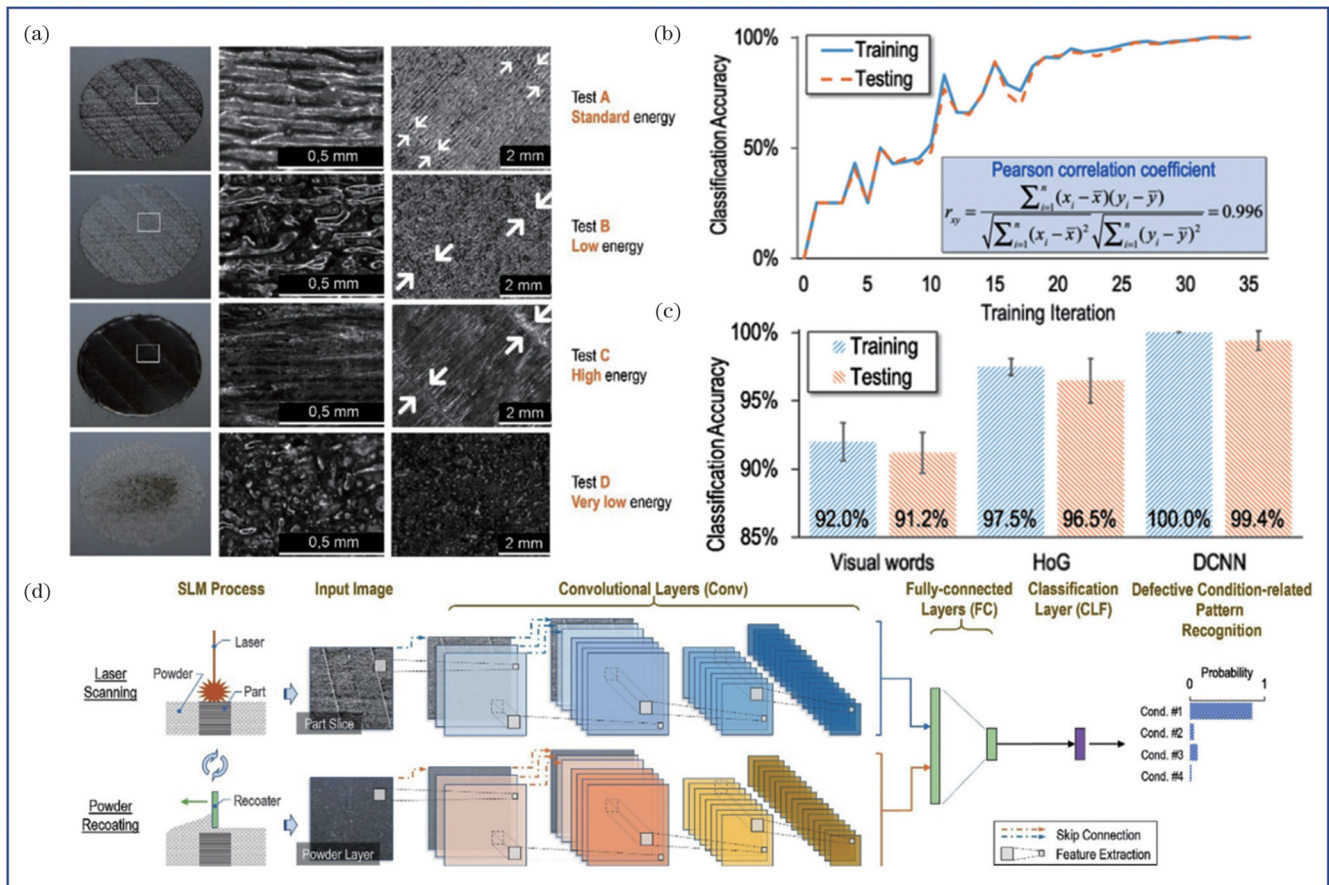


图 7 双流 DCNN 用于识别由不适当 SLM 工艺条件引起的缺陷^[58]。(a) 缺陷的显微镜图; (b) 分类准确率随迭代次数的变化; (c) DCNN、HoG 以及视觉词汇的性能比较; (d) 双流神经网络结构

Fig. 7 Bi-stream DCNN for recognition of defects induced by improper SLM process conditions^[58]. (a) Microscope view of defects; (b) variation of classification accuracy with the number of iteration; (c) performance comparison among DCNN, HoG and Visual words; (d) bi-stream DCNN architecture

在大量的激光增材制造缺陷检测研究中, 研究人员使用了不同的分类方法, 且都实现了缺陷检测任务, 但不同分类方法的性能不同。Zhang 等^[47] 对比了支持向量机 (SVM) 和 CNN 分类方法对熔池、羽流和飞溅图像的分类准确率。Ye 等^[49] 采用自适应深度置信网络对 SLM 过程中出现的 5 种熔化状态进行了分类, 并将其与多层感知机 (MLP)、CNN 方法的分类结果进行了比较。Okaro 等^[54] 利用半监督学习将 L-PBF 过程中出现的缺陷分为“有缺陷”和“可接受”。总的来说,

基于深度学习的分类方法的准确率高于传统的分类方法, 而且在其中引入无监督学习是很有必要的。这是因为监督学习需要花费大量的时间进行标注, 虽然监督学习可对已知缺陷进行准确分类, 但其对于未知缺陷往往认为是没有缺陷, 而无监督学习则可以发现未知缺陷与没有缺陷在数据高维空间上的区别。

在 L-PBF 技术进行 3D 打印过程中, 通常需要在成形板上铺一层薄薄的金属粉末, 粉末厚度通常为 20~120 μm 。在粉末层铺开, 用一束或多束激光选

择性地将粉末熔化,熔融粉末冷却凝固后形成 3D 零件的 2D 切片形状。激光微纳加工完成后,降低成形板,使另一层粉末沉积在粉末床上,重复进行这个过程,直到零件完成打印。许多重要的缺陷[如图 8(a)所示]

以及 L-PBF 制造过程的整体可靠性和稳定性,都与粉末扩散过程中出现的异常直接相关。因此,Scime 等^[53]提出使用迁移学习将 AlexNet CNN 应用于粉层异常分类问题。与 Scime 等之前研究中使用的人工选

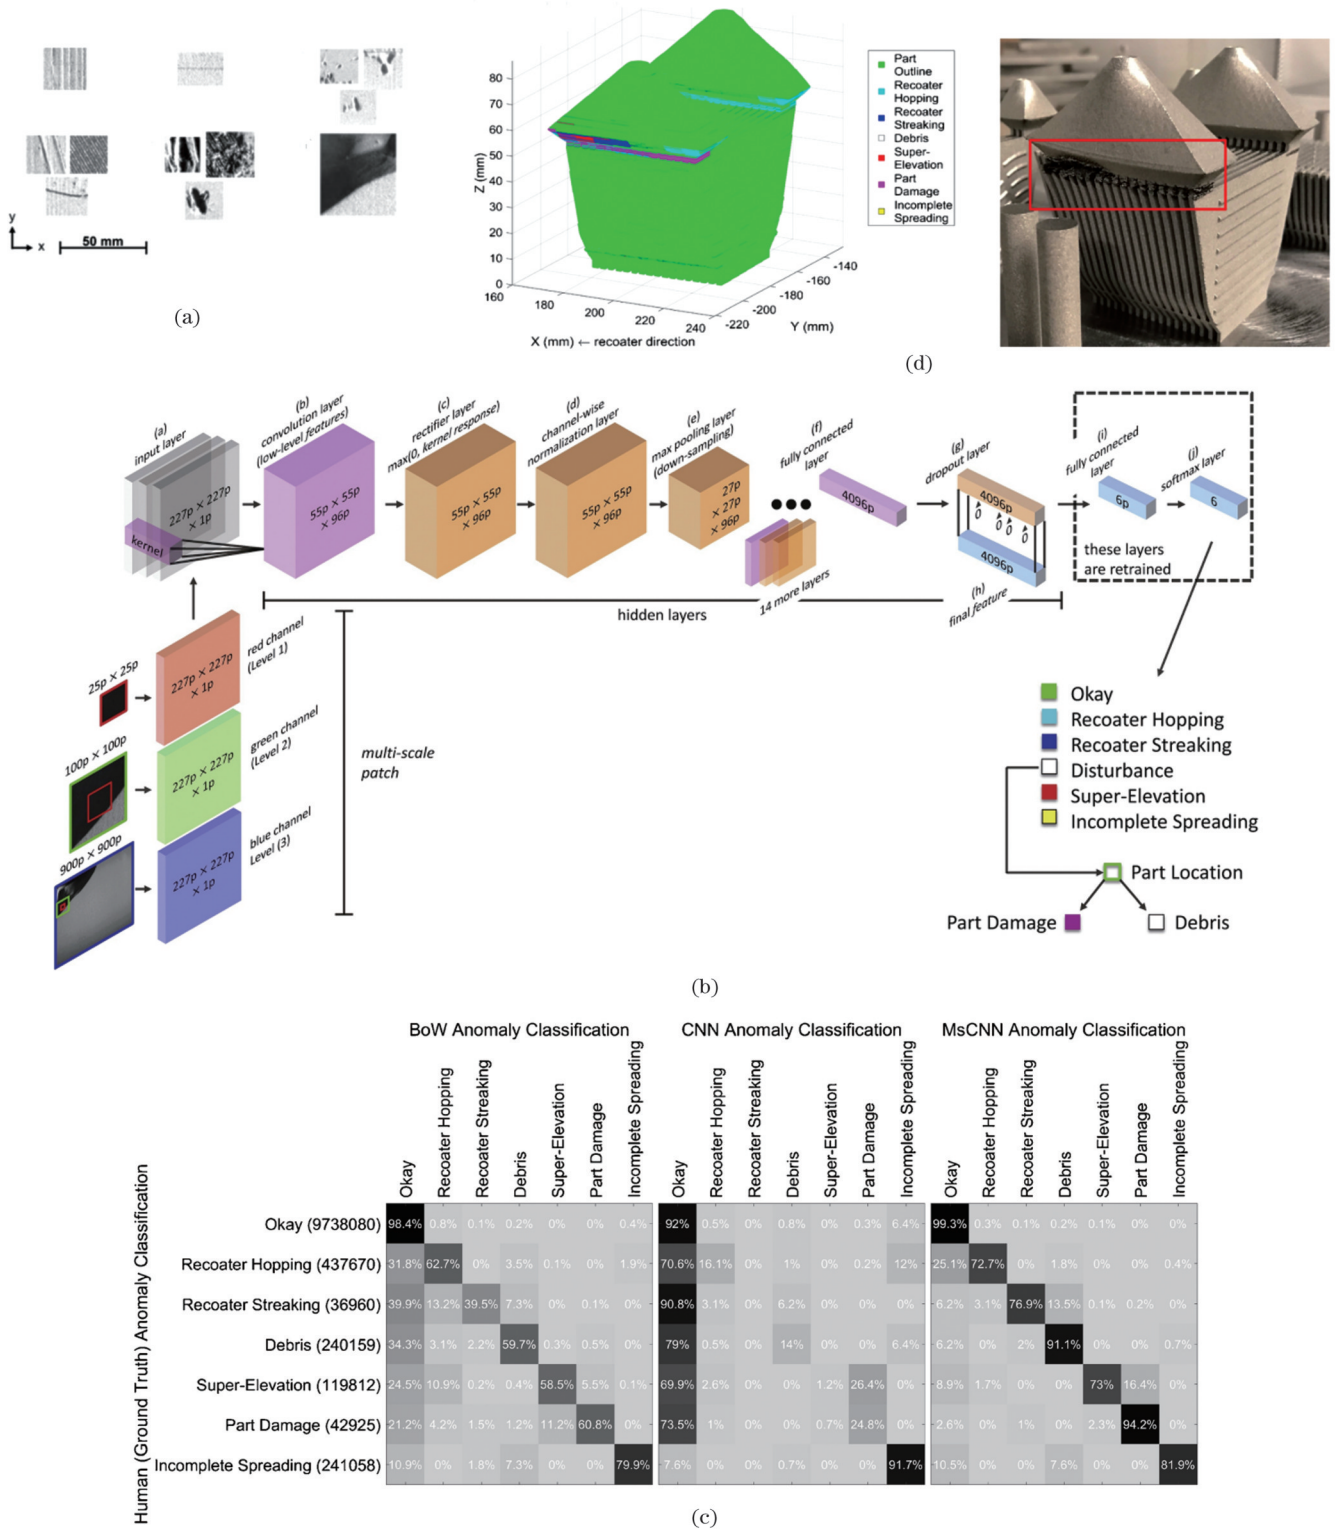


图 8 多尺度 CNN(MsCNN)用于识别由不当 L-PBF 工艺条件引起的缺陷^[53]。(a)选取的 6 种不同粉层异常类型的典型实例; (b)多尺度 CNN 结构; (c)Bow、CNN 和 MsCNN 方法的性能比较; (d)用 L-PBF 打印的热交换器及其 3D 渲染图
Fig.8 MsCNN for recognition of defects induced by improper L-PBF process conditions^[53]. (a) Representative examples of the six different powder bed anomaly classes chosen by the authors; (b) MsCNN architecture; (c) performance comparison among Bow, CNN and MsCNN; (d) heat exchanger printed with L-PBF and its 3D rendering image

择的特征提取方法相比,该方法消除了人为偏差,同时提高了总体分类精度和异常检测的保真度。有趣的是, AlexNet CNN 的输入数据还被配置成由多种尺度的图像组成(Scime 等称之为 MsCNN),即不同尺度的粉层区域,如图 8(b)所示。这种方法能够消除图像尺度对异常分类的影响。最终的 MsCNN 的测试结果显示,总体准确率以及异常检测和异常区分的准确率分别为 97%、85% 和 93%,如图 8(c)所示。此外, Scime 等发现使用 CNN 分析包含多尺度信息的数据的实例非常少,这表明 MsCNN 在激光增材制造领域有着巨大的未开发潜力。

除了缺陷的分类,找到缺陷所处的具体位置也很重要。Scime 等^[50]开发了一种新的 CNN 体系结构——动态分割 CNN(即 DSCNN),实现了跨越三种技术(激光聚变、黏结剂喷射和电子束聚变)的加工过程中的缺陷定位。从各研究中的机器学习模型性能测试结果中可以看出,基于光学的缺陷检测有着很高的准确率,这些研究对于激光增材制造中所遇到的瓶颈与困难的破解具有一定的启发意义。

另一类是基于声学的检测。虽然基于声学的异常检测的研究并不多,但是现有的声学传感器具有较高的灵敏度和相对低的成本,同时它们还可以提供更高的时间分辨率,可以更准确地跟踪缺陷的位置。此

外,与二维图像数据或三维层析成像数据相比,一维声学数据的处理速度更快,所以声学信号的异常检测具有一定优势。然而,对于许多增材制造工艺来说,特别是在惰性气氛环境下的激光金属增材制造工艺,背景噪声很明显,会混入到制造过程产生的信号中,导致检测的精确度降低。而机器学习技术能很好地过滤噪声,便于在高维数据空间进行数据挖掘。因此,基于机器学习的智能监控可以提供更好的解决方案。

Shevchik 等^[61]探讨了利用声发射进行质量监测的可行性,并将声发射传感器与机器学习相结合。首先, Shevchik 等通过调整工艺参数使工件内部形成不同孔隙率[孔隙率分别为 $(1.42 \pm 0.85)\%$ 、 $(0.3 \pm 0.18)\%$ 和 $(0.07 \pm 0.02)\%$]的气孔,如图 9(a)所示,并在此基础上确定零件的质量(差、中、高)。在制造过程中,他们使用光纤布拉格光栅传感器[如图 9(b)所示]记录粉末床增材制造过程中的声波信号。然后,利用小波变换从所有信号中提取声学特征——窄频带的相对能量。最后,采用基于谱的 CNN 对不同质量的声学特征进行区分,分类结果如图 9(c)所示。结果显示,该方法对高、中、差工件质量的分类准确率分别高达 83%、85% 和 89%。该研究证明了利用声传感器进行质量监测的可行性。

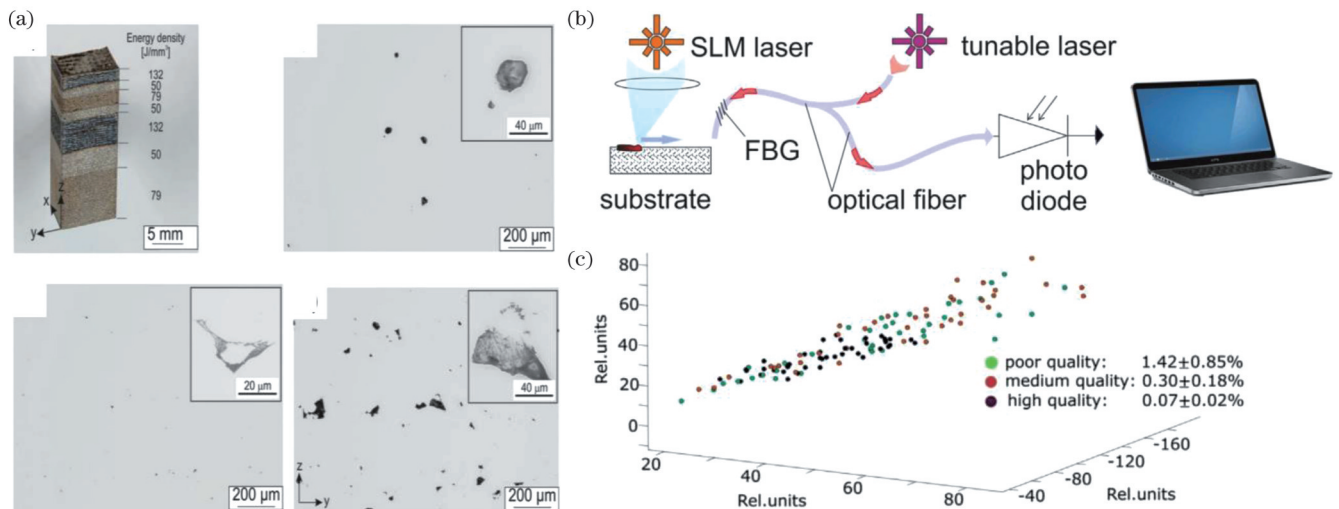


图9 利用声音信号分类不适当SLM工艺条件引起的缺陷^[61]。(a)三种激光能量密度下产生的缺陷的光学显微镜横截面图像;(b)声音检测系统装置示意图;(c)分类结果

Fig. 9 Classification of defects caused by improper SLM process conditions using acoustic signals^[61]. (a) Optical microscopy cross-section images of defects produced with three laser energy densities; (b) scheme of the sound detection system; (c) classification results

Ye 等^[59]提出了一种新的 SLM 零件内部缺陷的检测方法。他们对麦克风进行灵活设置,收集制造过程中产生的声学信号,然后将声学信号输入到深度置信网络(DBN)框架中进行缺陷检测。该算法采用简化的分类结构,无须进行信号预处理和特征提取。实验结果表明:利用声学信号进行质量监测是可行的。DBN 方法在不进行信号预处理的情况

下,可以在 5 种熔化状态下实现较高的缺陷检出率。

上述这些研究表明,机器学习已经深入结合到了各类激光微纳加工工艺的缺陷检测中,极大地提高了加工的反馈控制能力,但是这项工作也面临着极大的挑战,原位检测准确率、实时性、对未知异常是否能正确处理等都制约着它的发展。

3.2.3 加工过程控制

在激光图案化加工过程中,激光器会按照预先设定的程序,沿着预设的轨迹进行加工。其中常规的例子是光栅扫描,在该方法中,预期的激光微纳加工图案被数字化为二值图像,像素点用于标记工件上激光微纳加工的确切位置,激光束逐个扫描每一行像素,根据像素的二进制值打开和关闭激光。尽管光栅扫描方法能很好地完成图案化加工,但盲目执行预定的加工路径可能会导致严重的错误。因为激光位置的漂移或者

平台的振动都会损害最终的产品质量。Xie 等^[62]提出了一种新的激光微纳加工方法,利用强化学习(RL)对激光微纳加工过程进行控制和监督。如图 10(b)所示,Xie 等在“虚拟环境”下故意将选定的激光脉冲相对于其预定位置进行偏移,结果显示:RL 系统能够观察到加工轨迹发生的微小差异,并自动纠正了加工错误。这表明 RL 系统对于这种形式的干扰具有鲁棒性。图 10(c)表明 RL 系统不仅能够纠正加工异常,还能够加工任意复杂形状图案。

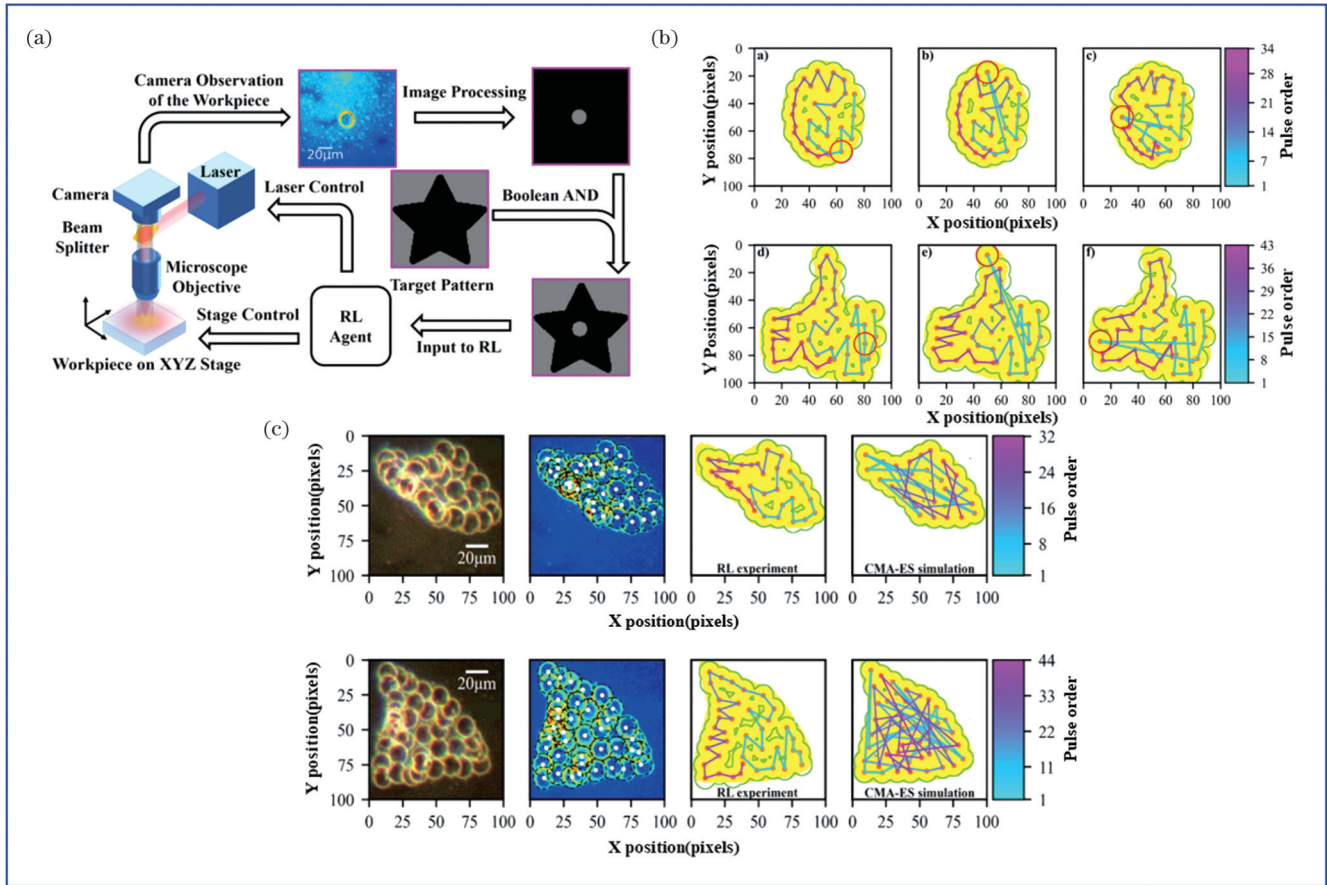


图 10 机器学习应用于激光微纳加工过程控制^[62]。(a)实验原理图;(b)机器学习算法实现加工过程中的自我修正;(c)机器学习实现任意图案的加工

Fig. 10 Machine learning applied to laser micro/nano machining process control^[62]. (a) Schematic of the experiment; (b) self-correction during processing by machine learning; (c) arbitrary patterns processing by machining learning

3.3 激光微纳加工结果的预测

激光微纳加工的众多工艺中常常包含多个流程,如果某个工艺过程出错,就会导致整个前序努力白费。即使加工流程一切正常,也需要通过一些观测手段(例如 SEM)对最终加工结果进行观察,以完成对微区的成分分析、材料断裂原因分析、事故原因分析以及工艺合理性判定等。综上所述,在加工开始之前建立预测模型将会提高良品率。

前面章节已提到激光微纳加工过程建模会涉及多个物理过程,具有较高的复杂性,导致人们很难快速、精确地预测加工结果。一般来说,人们通过数值模拟建立数学模型进而对激光微纳加工结果进行预

测^[86-89],建模过程中常常需要考虑电子-光子相互作用、热传导等复杂的物理过程。这种数值模拟的方法常常会耗费研究人员大量的精力,得到的结果也常常不尽如人意,无法用于实验。

Mills 等^[71]提出了一种新颖的方法,颠覆了传统的先加工后分析的理念。该方法通过神经网络实现加工前就能预测加工结果。具体过程如图 11(a)所示,主要分为实验和神经网络两部分。在实验部分,Mills 等将数字微镜器件(DMD)作为二元强度空间光调制器,对飞秒激光脉冲进行空间整形,其中 DMD 图案为一幅 1024×1024 的黑白二元图像,像素点的白与黑分别对应有无激光,经过 DMD 调制的脉冲激光在化学镍

镜的表面进行加工。在神经网络部分, Mills 等使用条件对抗生成网络(cGAN, 对抗生成网络的一种变体)根据 DMD 图案自动生成对应激光脉冲加工样品的扫

描电子显微镜(SEM)图像。

图 11(b)和图 11(c)展示了该研究的一系列结果。Mills 等通过神经网络预测出了不同 DMD 图案(分别




图 11 利用对抗生成网络预测激光微纳加工结果^[71]。(a)利用生成对抗网络预测加工结果的原理图;(b)预测结果与实验结果的对比;(c)神经网络预测结果显示了加工极限距离的存在

Fig. 11 Predicting laser processing results using adversarial generative networks^[71]. (a) Scheme of predicting processing results using generative adversarial networks; (b) comparison of predicted and experimental results; (c) neural network predicted results show the existence of processing limit distance

是不同宽度的线、矩形结构和环结构)对应的 SEM 图。随着设计加工宽度的不断缩小,实际加工宽度会逐渐趋近于衍射极限,Mills 等所训练的人工智能模型也预测到了这一加工极限的存在。

虽然利用 cGAN 预测出的 SEM 图可以有效观察各种固态物质表面超微结构的形态,但是缺乏深度信息。Heath 等^[73]延续上述工作,实现了对暴露在各种

空间形状激光下的样品结构深度分布的建模。可以从图 12(c)所示的预测结果中清楚地看到,神经网络可以准确地预测激光微纳加工微纳结构的深度、宽度、横截面轮廓,甚至是通过分析方法难以预测的特征,如毛刺高度、深度变化和平均深度。基于以上结果,Heath 等还研究了激光光斑直径与加工深度之间的关系。

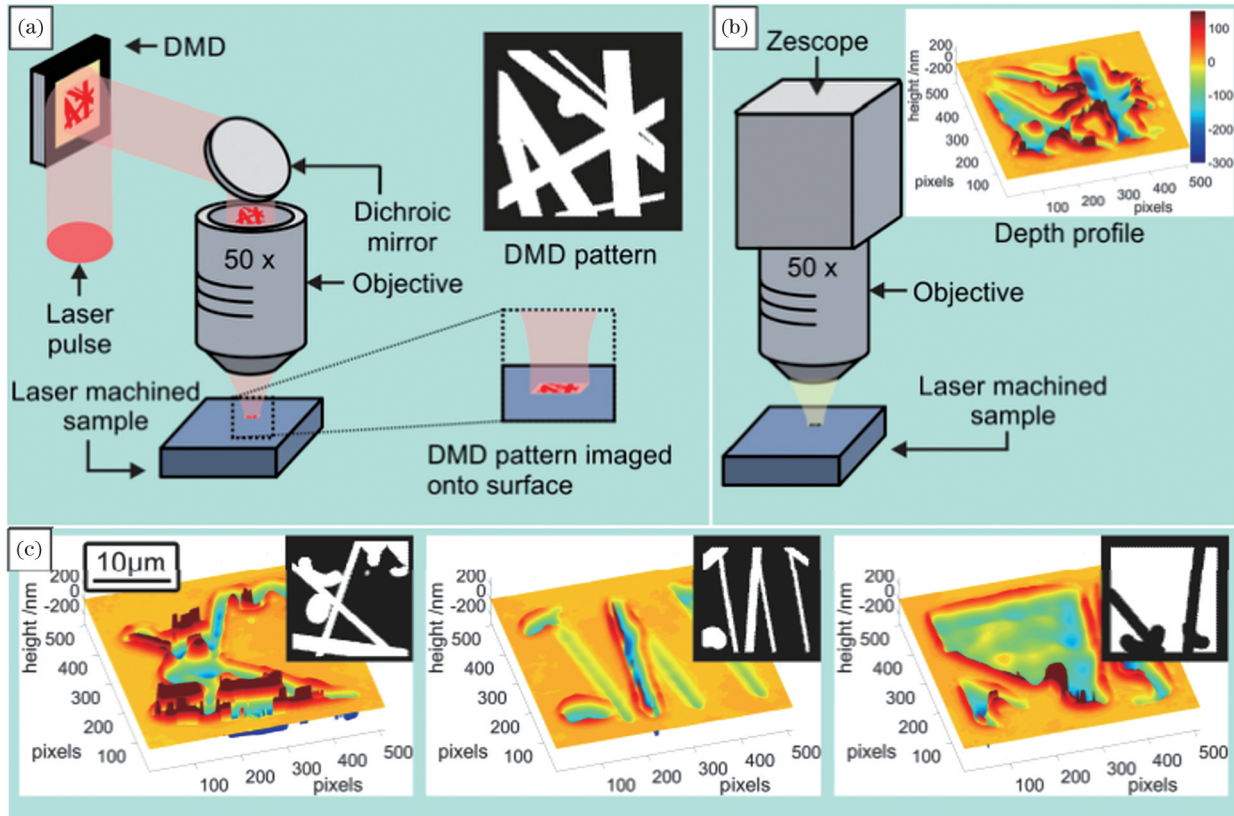


图 12 利用深度学习实现激光微纳加工三维表面形貌预测^[73]。(a)激光微纳加工装置示意图;(b)样品表征方法示意图;(c)训练数据集示例

Fig. 12 Prediction of 3D surface topography for laser machining using deep learning^[73]. (a) Schematic of the laser machining setup; (b) illustration of the sample characterization method; (c) examples from the training data set

神经网络已经被证明了其可以代替传统观察手段的能力;然而,使用神经网络来模拟这一过程的反向过程是具有一定挑战性的,因为在激光微纳加工过程中,样品可能暴露在多个脉冲下,衍射效应意味着任何特定的样品外观都可能由大量的光束形状变化产生的,只有在第一个激光脉冲到达之前,表面才会均匀光滑。在第一次脉冲作用之后,样品会发生一些变化,对于后续脉冲的光场传播来说,麦克斯韦方程组的边界条件发生了改变。因此,后续脉冲对样品形貌的影响是不断变化的。McDonnell 等^[72]利用上述提到的 cGAN 作为辅助网络来辅助初级神经网络(即深度剖面到 DMD 模式)的训练。这种使用模拟实验的神经网络来辅助训练第二个神经网络的技术是令人兴奋的,它表明了神经网络具有对复杂物理系统建模的潜力。

综上,神经网络已在预测激光微纳加工结果方面展示出了卓越的能力,从激光强度 DMD 图案到 3D 表面的转换通常只需要 250 ms。同时,这种方法除了可以应用在预测激光微纳加工结果外,在其他领域(例如光刻掩模板的设计)也有巨大的应用潜力。

3.4 辅助激光微纳加工物理机制的研究

激光微纳加工涉及多个物理过程,包括非线性光吸收、电离、电子-电子散射、电子-光子散射、热传导等,这些物理过程都涉及微观粒子,在建立物理模型时,需要考虑量子力学假设,而这一假设本身建立在波函数统计诠释上,会导致一个无法解决的问题,即不确定性,也就是说粒子的位置和动量无法同时被精确测量。所以,Déziel 等^[87]在建立激光诱导等离子体激发的物理模型时,采用麦克斯韦分布来描述热平衡状态下具有处于某个能级 E 的载流子数量分布。而采用神

神经网络的方法与上述有相似之处——学习数据统计特征,所以采用神经网络预测加工结果具有重要意义。通过训练神经网络理解激光微纳加工产生的数据,除了可用于物理系统的建模外,还可能发现人类尚未发现的物理定律。

Zhang 等^[90]尝试利用长短期记忆神经网络[如图 13(b)所示]预测了直接能量沉积过程中的熔池温度分布。采用直接能量沉积对材料进行加工时,熔池温度分布对于估计金属材料的显微组织、孔隙率和力学性能至关重要。为了准确预测熔池温度分布,常常需要使用解析方法建立物理模型,但是随着时间的推移,材料体积和质量的变化,以及潜在的热物理过程的不确定性,会使解析解不可靠。此外,使用数值模拟方

法(例如有限元分析)也会由于缺乏对熔池形成过程的认识(如粉末和基底反射引起的热损失)而导致数值模拟不准确。为此,Zhang 等提出了一种基于数据驱动的神经网络建模方法并用其来估计熔池温度在 DED 过程中的实时变化。图 13(c)展示了模型预测结果和实验结果的比较。该方法的核心思想是利用 LSTM 这种特殊的循环神经网络(RNN)来建立不同工艺条件与熔池温度之间的映射关系。传统的神经网络在处理训练数据时,输入序列之间没有反馈连接,而熔池温度具有因果特性,即后续时刻的温度与前序时刻的温度有关,所以 Zhang 等使用 LSTM 模型来建模这种时间序列数据,利用状态值作为内存单元来保存对前序数据的记忆。

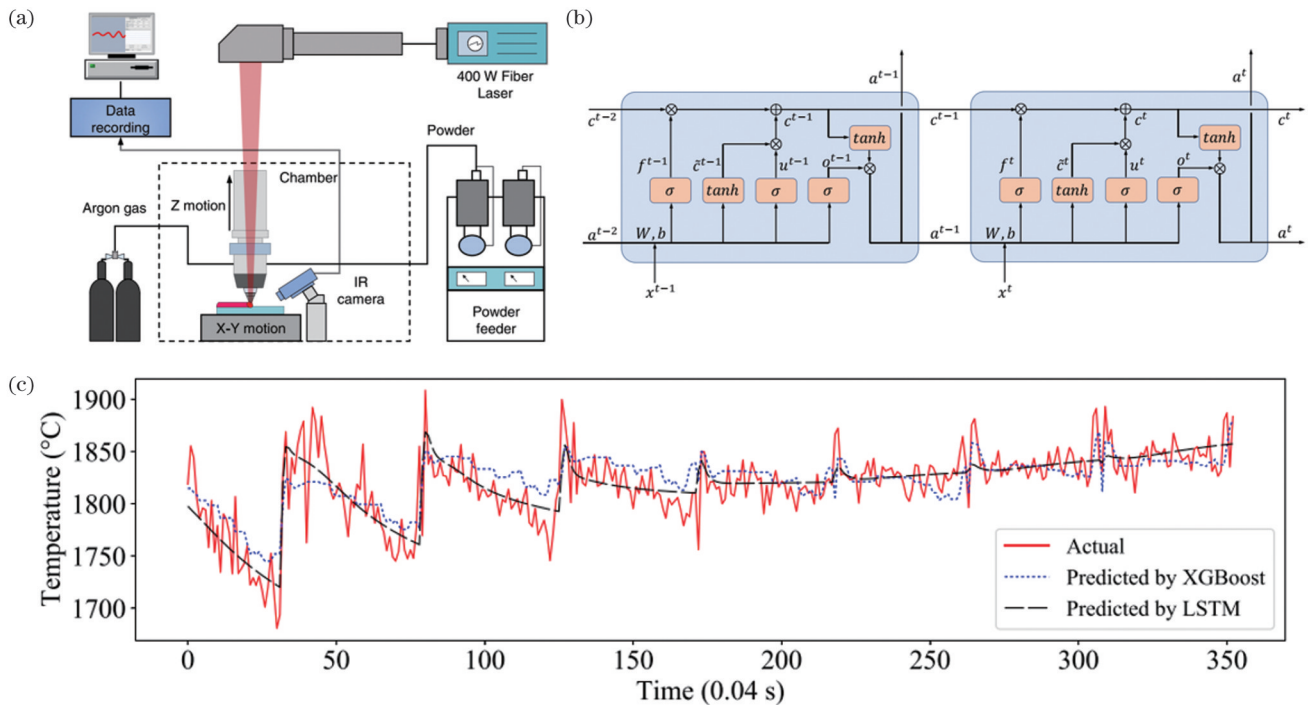


图 13 利用 LSTM 预测定向能量沉积熔池温度^[90]。(a) LENS 450XL 系统原理图; (b) 典型的 LSTM 单元结构图; (c) 熔池温度实验结果与预测结果的比较

Fig. 13 Prediction of melt pool temperature in directed energy deposition using LSTM^[90]. (a) Schematic diagram of the LENS 450XL system; (b) diagram of a typical LSTM; (c) comparison of experimental and predicted melt pool temperatures

虽然基于数据驱动的神经网络建模方法取得了一定进展,但建模过程需要大量的数据样本,致使建模存在一定难度。Zhu 等^[91]尝试使用物理信息神经网络来预测 DED 过程中的熔池温度和熔池流体动力学。物理信息神经网络是最近几年出现的新的神经网络模型,与传统的基于数据驱动的网络不同,它通过增加物理方程来约束网络的训练。这种基于物理的学习过程除了能够减少所需训练样本的数量之外,还能够提供求解物理过程反问题的新思路,具体细节可以参考 Karniadakis 等^[74-80]的报道。

4 总结与展望

激光微纳加工的整个工艺流程非常复杂,样品质

量取决于许多因素,包括激光稳定性、激光与材料的相互作用、加工系统的稳定性和材料特性等。目前,物理模型、数值模拟和试错方法等虽然被广泛应用于激光微纳加工过程的设计和优化,但随着加工过程复杂性的增加,对高稳定性、抗干扰性、可调性和自适应控制的需求不断提高,这些方法已经接近瓶颈,而具有“自我学习”和归纳推理能力的机器学习技术在这一领域取得了重大进展。接下来将讨论未来可能的研究方向和需要克服的挑战。

首先,基于机器学习的激光微纳加工是一个交叉方向,包含激光微纳加工与人工智能两个大领域。近些年来,激光微纳加工的工艺技术相较于人工智能技术发展相对缓慢,想要推动激光微纳加工研究的发展,

不断地跟进人工智能技术发展是一个不错的选择。例如,在分类任务中,常常把特征直接输入到神经网络中进行训练,从神经网络的角度看,每一个特征对神经网络的影响都是同等重要的。从认知科学的角度看,这种做法是不对的,因为人类大脑在处理信号时,总是会忽略一些不太重要的信号,而去重点分析那些重要的信号,这被称为注意力机制^[92]。在神经网络中,注意力机制是人们在机器学习模型中嵌入的一种特殊结构,用来自动学习和计算输入数据对输出数据的贡献,让模型自己学习如何分配自己的注意力,即为输入信号加权,以突出重要特征对下游模型或模块的影响。这两年曝光度极高的BERT^[93]、GPT^[94]、Transformer^[95]等模型都采用了注意力机制,大大提升了模型的性能。对于生成模型,基于Diffusion模型^[96]的图像生成能力已经远远超过了GAN模型,目前已被广泛应用于AI绘画,而且绘画作品的水平在很大程度上超过了人类。据笔者所知,这些性能更好的模型并未被应用于激光微纳加工领域,所以采用更先进的人工智能模型可能会解决现有部分工作存在的问题。

其次,神经网络方法是数据驱动的,因此模型的泛化性和准确率直接与可用的数据量有关。一些领域已经建立了自己的大数据集,如图像识别领域的ImageNet、光学字符识别领域的MNIST、自然语言处理领域的SQuAD、视频分类领域的YouTube-8M。神经网络在这些领域展示了它的强大能力,相比之下,激光微纳加工领域缺乏公开的数据集,收集训练数据代价高昂。鉴于这种困境,建立当前的小样本训练模型是非常必要的。除此之外,还可以采用生成模型的方法来实现数据增强,这一方法能够随机生成与训练数据非常相似的新数据,从而人为地扩大数据集。这种方法可以参考Shrivastava等^[97]的相关工作。

最后,深度学习虽然是一种非常有用的机器学习模型,但因其“黑盒子”的特性,使用者无法有效控制神经网络,更无法理解网络中到底发生了什么,导致模型性能很难进一步提升。因此,为了提升模型性能,深度学习的可解释性研究也是必要的,但全局的可解释性(解释神经网络每个神经元学到了什么,从而理解神经网络为何对整个输入空间有效)几乎很难实现,现有的主要工作是局部可解释性研究,即研究为什么神经网络将特定的图片判定为某一类,只关注输入空间中在这个图片周围的很小区域^[98]。这种方法可以加深使用者对模型的理解,提升预测模型的性能,从而更好地完成激光微纳加工任务。

随着人工智能技术的不断发展,基于数据、模型、算法、算力的科学研究成为了新的范式。以机器学习技术为代表的人工智能技术已经开始为激光微纳加工的各个阶段赋能,未来有望革新激光微纳加工的工艺流程,形成“人工智能驱动的科学研究的”新模式。

参 考 文 献

- [1] Moradi M, Mehrabi O, Azdast T, et al. Enhancement of low power CO₂ laser cutting process for injection molded polycarbonate [J]. *Optics & Laser Technology*, 2017, 96: 208-218.
- [2] Schulz W, Becker D, Franke J, et al. Heat conduction losses in laser cutting of metals[J]. *Journal of Physics D: Applied Physics*, 1993, 26(9): 1357-1363.
- [3] Choudhury I A, Shirley S. Laser cutting of polymeric materials: an experimental investigation[J]. *Optics & Laser Technology*, 2010, 42(3): 503-508.
- [4] Rauh B, Kreling S, Kolb M, et al. UV-laser cleaning and surface characterization of an aerospace carbon fibre reinforced polymer[J]. *International Journal of Adhesion and Adhesives*, 2018, 82: 50-59.
- [5] Shi T Y, Wang C M, Mi G Y, et al. A study of microstructure and mechanical properties of aluminum alloy using laser cleaning [J]. *Journal of Manufacturing Processes*, 2019, 42: 60-66.
- [6] Park H K, Grigoropoulos C P, Leung W P, et al. A practical excimer laser-based cleaning tool for removal of surface contaminants[J]. *IEEE Transactions on Components, Packaging, and Manufacturing Technology: Part A*, 1994, 17(4): 631-643.
- [7] Salonitis K, Stourmaras A, Tsoukantas G, et al. A theoretical and experimental investigation on limitations of pulsed laser drilling[J]. *Journal of Materials Processing Technology*, 2007, 183(1): 96-103.
- [8] Gautam G D, Pandey A K. Pulsed Nd: YAG laser beam drilling: a review[J]. *Optics & Laser Technology*, 2018, 100: 183-215.
- [9] Hwang D J, Choi T Y, Grigoropoulos C P. Liquid-assisted femtosecond laser drilling of straight and three-dimensional microchannels in glass[J]. *Applied Physics A*, 2004, 79(3): 605-612.
- [10] Yue Y F, Kurokawa T. Designing responsive photonic crystal patterns by using laser engraving[J]. *ACS Applied Materials & Interfaces*, 2019, 11(11): 10841-10847.
- [11] Uh J, Lee J S, Kim Y H, et al. Laser engraving of micro-patterns on roll surfaces[J]. *ISIJ International*, 2002, 42(11): 1266-1272.
- [12] Lahoz R, de la Fuente G F, Pedra J M, et al. Laser engraving of ceramic tiles[J]. *International Journal of Applied Ceramic Technology*, 2011, 8(5): 1208-1217.
- [13] Ravi-Kumar S, Lies B, Zhang X A, et al. Laser ablation of polymers: a review[J]. *Polymer International*, 2019, 68(8): 1391-1401.
- [14] Preuss S, Demchuk A, Stuke M. Sub-picosecond UV laser ablation of metals[J]. *Applied Physics A*, 1995, 61(1): 33-37.
- [15] Vogel A, Venugopalan V. Mechanisms of pulsed laser ablation of biological tissues[J]. *Chemical Reviews*, 2003, 103(2): 577-644.
- [16] Scotti G, Matilainen V, Kanninen P, et al. Laser additive manufacturing of stainless steel micro fuel cells[J]. *Journal of Power Sources*, 2014, 272: 356-361.
- [17] Zhu Y Y, Li J, Tian X J, et al. Microstructure and mechanical properties of hybrid fabricated Ti-6.5Al-3.5Mo-1.5Zr-0.3Si titanium alloy by laser additive manufacturing[J]. *Materials Science and Engineering: A*, 2014, 607: 427-434.
- [18] Leung C L A, Marussi S, Towrie M, et al. The effect of powder oxidation on defect formation in laser additive manufacturing[J]. *Acta Materialia*, 2019, 166: 294-305.
- [19] Akman E, Demir A, Canel T, et al. Laser welding of Ti6Al4V titanium alloys[J]. *Journal of Materials Processing Technology*, 2009, 209(8): 3705-3713.
- [20] Cao X J, Jahazi M, Immarrigeon J P, et al. A review of laser welding techniques for magnesium alloys[J]. *Journal of Materials Processing Technology*, 2006, 171(2): 188-204.
- [21] Hong K M, Shin Y C. Prospects of laser welding technology in the automotive industry: a review[J]. *Journal of Materials Processing Technology*, 2017, 245: 46-69.
- [22] Samant A N, Dahotre N B. Laser machining of structural ceramics: a review[J]. *Journal of the European Ceramic Society*, 2009, 29(6): 969-993.
- [23] Yang L L, Wei J T, Ma Z, et al. The fabrication of micro/nano

- structures by laser machining[J]. *Nanomaterials*, 2019, 9(12): 1789.
- [24] Meijer J, Du K, Gillner A, et al. Laser machining by short and ultrashort pulses, state of the art and new opportunities in the age of the photons[J]. *CIRP Annals*, 2002, 51(2): 531-550.
- [25] Gattass R R, Mazur E. Femtosecond laser micromachining in transparent materials[J]. *Nature Photonics*, 2008, 2(4): 219-225.
- [26] Negarestani R, Sundar M, Sheikh M A, et al. Numerical simulation of laser machining of carbon-fibre-reinforced composites [J]. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 2010, 224(7): 1017-1027.
- [27] Zhong Y G, Xue K, Shi D Y. An improved artificial neural network for laser welding parameter selection and prediction[J]. *The International Journal of Advanced Manufacturing Technology*, 2013, 68(1): 755-762.
- [28] Velli M C, Tsibidis G D, Mimidis A, et al. Predictive modeling approaches in laser-based material processing[J]. *Journal of Applied Physics*, 2020, 128(18): 183102.
- [29] Vagheesan S, Govindarajulu J. Hybrid neural network-particle swarm optimization algorithm and neural network-genetic algorithm for the optimization of quality characteristics during CO₂ laser cutting of aluminium alloy[J]. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 2019, 41(8): 1-15.
- [30] Teixidor D, Grzenda M, Bustillo A, et al. Modeling pulsed laser micromachining of micro geometries using machine-learning techniques[J]. *Journal of Intelligent Manufacturing*, 2015, 26(4): 801-814.
- [31] Wang R J, Li X H, Wu Q D, et al. Optimizing process parameters for selective laser sintering based on neural network and genetic algorithm[J]. *The International Journal of Advanced Manufacturing Technology*, 2009, 42(11): 1035-1042.
- [32] Rajaram N, Sheikh-Ahmad J, Cheraghi S H. CO₂ laser cut quality of 4130 steel[J]. *International Journal of Machine Tools and Manufacture*, 2003, 43(4): 351-358.
- [33] Park Y W, Rhee S. Process modeling and parameter optimization using neural network and genetic algorithms for aluminum laser welding automation[J]. *The International Journal of Advanced Manufacturing Technology*, 2008, 37(9): 1014-1021.
- [34] Omidvar M, Fard R K, Sohrabpoor H, et al. Selection of laser bending process parameters for maximal deformation angle through neural network and teaching-learning-based optimization algorithm [J]. *Soft Computing*, 2015, 19(3): 609-620.
- [35] Olabi A G, Casalino G, Benyounis K Y, et al. An ANN and Taguchi algorithms integrated approach to the optimization of CO₂ laser welding[J]. *Advances in Engineering Software*, 2006, 37(10): 643-648.
- [36] Nakhjavani O B, Ghoreishi M. Multi criteria optimization of laser percussion drilling process using artificial neural network model combined with genetic algorithm[J]. *Materials and Manufacturing Processes*, 2006, 21(1): 11-18.
- [37] McDonnell M D T, Arnaldo D, Pelletier E, et al. Machine learning for multi-dimensional optimisation and predictive visualisation of laser machining[J]. *Journal of Intelligent Manufacturing*, 2021, 32(5): 1471-1483.
- [38] Li K S, Ma Z Y, Fu P, et al. Quantitative evaluation of surface crack depth with a scanning laser source based on particle swarm optimization-neural network[J]. *NDT & E International*, 2018, 98: 208-214.
- [39] Huang Y, Liu Y, Zhu G L. Parameter optimization of laser scribing technics of 30Q130 grain-oriented silicon steel based on genetic neural network[J]. *Applied Mechanics and Materials*, 2010, 37/38: 844-848.
- [40] Günther J, Pilarski P M, Helfrich G, et al. First steps towards an intelligent laser welding architecture using deep neural networks and reinforcement learning[J]. *Procedia Technology*, 2014, 15: 474-483.
- [41] Ghosal S, Chaki S. Estimation and optimization of depth of penetration in hybrid CO₂ laser-MIG welding using ANN-optimization hybrid model[J]. *The International Journal of Advanced Manufacturing Technology*, 2010, 47(9): 1149-1157.
- [42] Ding H, Wang Z C, Guo Y C. Multi-objective optimization of fiber laser cutting based on generalized regression neural network and non-dominated sorting genetic algorithm[J]. *Infrared Physics & Technology*, 2020, 108: 103337.
- [43] Dhara S K, Kuar A S, Mitra S. An artificial neural network approach on parametric optimization of laser micro-machining of die-steel[J]. *The International Journal of Advanced Manufacturing Technology*, 2008, 39(1): 39-46.
- [44] Zhang Y Q, Chen W Z, Zhang X D, et al. Synthetic evaluation and neural-network prediction of laser cutting quality[J]. *Proceedings of SPIE*, 2005, 5629: 237-246.
- [45] Ciurana J, Arias G, Ozel T. Neural network modeling and particle swarm optimization (PSO) of process parameters in pulsed laser micromachining of hardened AISI H13 steel[J]. *Materials and Manufacturing Processes*, 2009, 24(3): 358-368.
- [46] Biswas R, Kuar A S, Biswas S K, et al. Artificial neural network modelling of Nd: YAG laser microdrilling on titanium nitride – alumina composite[J]. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 2010, 224 (3): 473-482.
- [47] Zhang Y J, Hong G S, Ye D S, et al. Extraction and evaluation of melt pool, plume and spatter information for powder-bed fusion AM process monitoring[J]. *Materials & Design*, 2018, 156: 458-469.
- [48] You D Y, Gao X D, Katayama S. WPD-PCA-based laser welding process monitoring and defects diagnosis by using FNN and SVM [J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(1): 628-636.
- [49] Ye D S, Hsi Fuh J Y, Zhang Y J, et al. *In situ* monitoring of selective laser melting using plume and spatter signatures by deep belief networks[J]. *ISA Transactions*, 2018, 81: 96-104.
- [50] Scime L, Siddel D, Baird S, et al. Layer-wise anomaly detection and classification for powder bed additive manufacturing processes: a machine-agnostic algorithm for real-time pixel-wise semantic segmentation[J]. *Additive Manufacturing*, 2020, 36: 101453.
- [51] Scime L, Beuth J. Using machine learning to identify *in situ* melt pool signatures indicative of flaw formation in a laser powder bed fusion additive manufacturing process[J]. *Additive Manufacturing*, 2019, 25: 151-165.
- [52] Scime L, Beuth J. Anomaly detection and classification in a laser powder bed additive manufacturing process using a trained computer vision algorithm[J]. *Additive Manufacturing*, 2018, 19: 114-126.
- [53] Scime L, Beuth J. A multi-scale convolutional neural network for autonomous anomaly detection and classification in a laser powder bed fusion additive manufacturing process[J]. *Additive Manufacturing*, 2018, 24: 273-286.
- [54] Okaro I A, Jayasinghe S, Sutcliffe C, et al. Automatic fault detection for laser powder-bed fusion using semi-supervised machine learning[J]. *Additive Manufacturing*, 2019, 27: 42-53.
- [55] Khanzadeh M, Chowdhury S, Tschopp M A, et al. *In-situ* monitoring of melt pool images for porosity prediction in directed energy deposition processes[J]. *IISE Transactions*, 2019, 51(5): 437-455.
- [56] Jafari-Marandi R, Khanzadeh M, Tian W, et al. From *in-situ* monitoring toward high-throughput process control: cost-driven decision-making framework for laser-based additive manufacturing [J]. *Journal of Manufacturing Systems*, 2019, 51: 29-41.
- [57] Grasso M, Demir A G, Previtali B, et al. *In situ* monitoring of selective laser melting of zinc powder via infrared imaging of the process plume[J]. *Robotics and Computer-Integrated Manufacturing*, 2018, 49: 229-239.
- [58] Caggiano A, Zhang J J, Alfieri V, et al. Machine learning-based image processing for on-line defect recognition in additive manufacturing[J]. *CIRP Annals*, 2019, 68(1): 451-454.
- [59] Ye D S, Hong G S, Zhang Y J, et al. Defect detection in selective

- laser melting technology by acoustic signals with deep belief networks[J]. The International Journal of Advanced Manufacturing Technology, 2018, 96(5): 2791-2801.
- [60] Wu H X, Yu Z H, Wang Y. Real-time FDM machine condition monitoring and diagnosis based on acoustic emission and hidden semi-Markov model[J]. The International Journal of Advanced Manufacturing Technology, 2017, 90(5): 2027-2036.
- [61] Shevchik S A, Kenel C, Leinenbach C, et al. Acoustic emission for *in situ* quality monitoring in additive manufacturing using spectral convolutional neural networks[J]. Additive Manufacturing, 2018, 21: 598-604.
- [62] Xie Y H, Praeger M, Grant-Jacob J A, et al. Motion control for laser machining via reinforcement learning[J]. Optics Express, 2022, 30(12): 20963-20979.
- [63] Jordan M I, Mitchell T M. Machine learning: trends, perspectives, and prospects[J]. Science, 2015, 349(6245): 255-260.
- [64] Mitchell T M. Machine learning[M]. New York: McGraw-Hill, 1997.
- [65] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [66] Zhou Z H. Machine Learning[M]. Singapore: Springer Singapore, 2021.
- [67] Goodfellow I, Bengio Y, Courville A. Deep learning[M]. Cambridge: The MIT Press, 2016.
- [68] Cybenko G. Approximation by superpositions of a sigmoidal function[J]. Mathematics of Control, Signals and Systems, 1989, 2(4): 303-314.
- [69] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators[J]. Neural Networks, 1989, 2(5): 359-366.
- [70] Hornik K, Stinchcombe M, White H. Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks[J]. Neural Networks, 1990, 3(5): 551-560.
- [71] Mills B, Heath D J, Grant-Jacob J A, et al. Predictive capabilities for laser machining via a neural network[J]. Optics Express, 2018, 26(13): 17245-17253.
- [72] McDonnell M D T, Grant-Jacob J A, Praeger M, et al. Identification of spatial intensity profiles from femtosecond laser machined depth profiles via neural networks[J]. Optics Express, 2021, 29(22): 36469-36486.
- [73] Heath D J, Grant-Jacob J A, Xie Y H, et al. Machine learning for 3D simulated visualization of laser machining[J]. Optics Express, 2018, 26(17): 21574-21584.
- [74] Zhang D K, Guo L, Karniadakis G E. Learning in modal space: solving time-dependent stochastic PDEs using physics-informed neural networks[J]. SIAM Journal on Scientific Computing, 2020, 42(2): A639-A665.
- [75] Sirignano J, Spiliopoulos K. DGM: a deep learning algorithm for solving partial differential equations[J]. Journal of Computational Physics, 2018, 375: 1339-1364.
- [76] Sheng H L, Yang C. PFNN: a penalty-free neural network method for solving a class of second-order boundary-value problems on complex geometries[J]. Journal of Computational Physics, 2021, 428: 110085.
- [77] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational Physics, 2019, 378: 686-707.
- [78] Raissi M, Karniadakis G E. Hidden physics models: machine learning of nonlinear partial differential equations[J]. Journal of Computational Physics, 2018, 357: 125-141.
- [79] Mao Z P, Jagtap A D, Karniadakis G E. Physics-informed neural networks for high-speed flows[J]. Computer Methods in Applied Mechanics and Engineering, 2020, 360: 112789.
- [80] Karniadakis G E, Kevrekidis I G, Lu L, et al. Physics-informed machine learning[J]. Nature Reviews Physics, 2021, 3(6): 422-440.
- [81] Xie Y H, Heath D J, Grant-Jacob J A, et al. Deep learning for the monitoring and process control of femtosecond laser machining[J]. Journal of Physics: Photonics, 2019, 1(3): 035002.
- [82] 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.
- [83] Yang B, Ma D N, Liu W W, et al. Deep-learning-based colorimetric polarization-angle detection with metasurfaces[J]. Optica, 2022, 9(2): 217-220.
- [84] Scime L, Beuth J. Melt pool geometry and morphology variability for the Inconel 718 alloy in a laser powder bed fusion additive manufacturing process[J]. Additive Manufacturing, 2019, 29: 100830.
- [85] Ren Z S, Gao L, Clark S J, et al. Machine learning-aided real-time detection of keyhole pore generation in laser powder bed fusion[J]. Science, 2023, 379(6627): 89-94.
- [86] Balling P, Schou J. Femtosecond-laser ablation dynamics of dielectrics: basics and applications for thin films[J]. Reports on Progress in Physics, 2013, 76(3): 036502.
- [87] Déziel J L, Dubé L J, Varin C. Dynamical rate equation model for femtosecond laser-induced breakdown in dielectrics[J]. Physical Review B, 2021, 104(4): 045201.
- [88] Gruzdev V E, Komolov V L, Przhibel'skiĭ S G. Ionization of nanoparticles by supershort moderate-intensity laser pulses[J]. Journal of Optical Technology, 2014, 81(5): 256-261.
- [89] Stoian R. Volume photoinscription of glasses: three-dimensional micro- and nanostructuring with ultrashort laser pulses[J]. Applied Physics A, 2020, 126: 1-30.
- [90] 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.
- [91] Zhu Q M, Liu Z L, Yan J H. Machine learning for metal additive manufacturing: predicting temperature and melt pool fluid dynamics using physics-informed neural networks[J]. Computational Mechanics, 2021, 67(2): 619-635.
- [92] Chaudhari S, Mithal V, Polatkan G, et al. An attentive survey of attention models[J]. ACM Transactions on Intelligent Systems and Technology, 2021, 12(5): 53.
- [93] Joshi M, Chen D Q, Liu Y H, et al. SpanBERT: improving pre-training by representing and predicting spans[J]. Transactions of the Association for Computational Linguistics, 2020, 8: 64-77.
- [94] Radford A, Narasimhan K, Salimans T, et al. Improving language understanding by generative pre-training[EB/OL]. [2023-02-03]. <https://gwern.net/doc/www/s3-us-west-2.amazonaws.com/d73-fdc5ffa8627bce44dca2fc012da638ffb158.pdf>.
- [95] Touvron H, Cord M, Douze M, et al. Training data-efficient image transformers & distillation through attention[EB/OL]. (2020-12-23)[2023-02-03]. <https://arxiv.org/abs/2012.12877>.
- [96] Dhariwal P, Nichol A. Diffusion models beat GANs on image synthesis[EB/OL]. (2021-05-11)[2023-02-03]. <https://arxiv.org/abs/2105.05233>.
- [97] Shrivastava A, Pfister T, Tuzel O, et al. Learning from simulated and unsupervised images through adversarial training[C] //2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2242-2251.
- [98] Zhou B L, Khosla A, Lapedriza A, et al. Learning deep features for discriminative localization[C] //2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2921-2929.

Machine Learning for Laser Micro/Nano Manufacturing: Applications and Prospects

Gong Wei¹, Zhao Wenhua¹, Wang Xintian¹, Li Zhenze¹, Wang Yi², Zhao Xinjing¹,
Wang Qing¹, Wang Yanhui^{1*}, Wang Lei¹, Chen Qidai¹

¹*College of Electronic Science & Engineering, State Key Lab of Integrated Optoelectronics, Jilin University,
Changchun 130012, Jilin, China;*

²*Department of Precision Instrument, State Key Lab of Precision Measurement Technology & Instruments,
Tsinghua University, Beijing 100084, China*

Abstract

Significance Since laser was invented, laser processing has completely transformed technologies such as cutting, cleaning, drilling, engraving, ablation, additive manufacturing, and welding. Laser technologies are used in a wide range of applications including aerospace, automotive, electronics, batteries, medical, 3D printing, semiconductors, sensors, and solar energy. With the development of technology, laser micro/nano processing is developing in the direction of finer (from millimeter to micron or even nanometer), more efficient (processing speed of hundreds of square millimeters per second), conformal (three-dimensional), and random (multiple materials). However, due to the complexity of the physical mechanism of the interaction between laser and matter, its further development is restricted, accurate modeling cannot be achieved, and there are still obvious deficiencies in processing quality and conformal processing.

Artificial intelligence technology provides a new idea to solve the bottleneck problem in the current laser processing field, and has a significant supplementary effect on laser micro/nano processing. It performs tasks through statistical techniques and numerical algorithms, without explicit program instructions, and can realize prediction, optimization of processing parameters and construction of complex dynamic models. For example, neural networks is used to model the physical process of laser-matter interaction without the physical model. Machine learning-based classification technology has significantly accelerated the intelligent process of defect detection in laser processing, and significant innovation has been achieved in the traditional laser processing process control method that relies on pre-defined processing paths.

Progress With artificial intelligence technology development, laser industrial manufacturing intelligence has become an important trend. Machine learning, as one of the main artificial intelligence technologies, is widely used in related fields, promoting a significant breakthrough and demonstrating specific potential to drive the next generation of ultrafast laser processing technology. This study therefore reviews key machine learning applications in various processes in the laser-micro and nano-processing field. This includes laser processing parameter optimization and process window prediction, real-time monitoring and control of the processing process, processing results prediction, and the investigation of auxiliary physical mechanisms. It summarizes and anticipates future applications and currently available improvement solutions where machine learning and laser processing are expected to intersect.

Conclusions and Prospects Firstly, intelligent laser micro/nano machining is an interdisciplinary direction, encompassing the two major fields of laser micro/nano processing and artificial intelligence. In recent years, the technological advancement of laser micro/nano processing has been relatively slow compared to that of artificial intelligence. Therefore, to promote the development of laser micro/nano processing research, it's a good choice to continuously keep up with the advancements in artificial intelligence. Secondly, because the neural network approach is data-driven, model generalizability and accuracy are directly related to the amount of available data. The model generation method enables data augmentation and the random generation of new data that is extremely similar to the training data, thus artificially expanding the dataset. Finally, although deep learning is an extremely useful machine learning model, its "black box" nature prevents users from effectively controlling the neural network, hence, this has created doubts including skepticism regarding the "black box" concept. Consequently, artificial intelligence technology represented by machine learning technology has begun to empower all stages of laser micro/nano processing. In the future, it is expected to bring innovation to the process of laser micro/nano processing and form a new model of "artificial intelligence-driven scientific research".

Key words laser technique; optical fabrication; micro/nano fabrication; process control; artificial intelligence; machine learning