基于声学信号和深度学习的激光定向能量沉积原位裂纹和钥孔气孔检测

Lequn Chen [a, b]、**Xiling Yao** [c, *]、**Chaolin Tan** [a]、**Weiyang He** [d]、**Jinlong Su** [a]、**Fei Weng** [c]、**Youxiang Chew** [a]、**Nicholas Poh Huat Ng** [b]、**Seung Ki Moon** [b, **]

[a] 先进再制造与技术中心（ARTC），A*STAR，3 Cleantech Loop，637143，新加坡 [b] 南洋理工大学机械与航空航天工程学院，639798，新加坡 [c] 新加坡制造技术研究院（SIMTech），A*STAR，5 Cleantech Loop，636732，新加坡 [d] 南洋理工大学电气与电子工程学院，639798，新加坡

摘要： 裂纹和匙孔气孔是激光定向能量沉积（LDED）制备合金时产生的有害缺陷。激光-材料相互作用声可能包含有关裂纹扩展和气孔形成等复杂物理事件的信息。然而，由于环境噪声以及信号内容复杂，基于声学的监测在 LDED 中鲜少受到关注。本文提出一种新颖的 LDED 基于声学的原位缺陷检测策略。本研究的主要贡献是开发了一套原位声学信号去噪、特征提取和声音分类流程，并将卷积神经网络（CNN）用于在线缺陷预测。研究使用显微镜图像识别部件中裂纹和匙孔气孔的位置，并将这些缺陷位置与声学信号进行时空配准。研究提取并分析了与无缺陷区域、裂纹和匙孔气孔对应的各种声学特征，分析方式包括时域、频域及时频表示。CNN 模型利用激光-材料相互作用声的梅尔频率倒谱系数（MFCC）进行训练，以预测缺陷发生情况。研究将该 CNN 模型与使用去噪声学数据集和原始声学数据集训练的各种经典机器学习模型进行了比较。验证结果表明，使用去噪数据集训练的 CNN 模型表现最佳，其总体准确率（89%）、匙孔孔隙预测准确率（93%）和 ROC 曲线下面积得分（98%）均为最高。此外，训练好的 CNN 模型可部署到自主开发的软件平台中，用于在线质量监测。据我们所知，这是首项在 LDED 过程中结合声学信号与深度学习进行原位缺陷检测的研究。

关键词： 增材制造；激光定向能量沉积；声学信号处理；卷积神经网络；深度学习；原位缺陷检测。

* 通讯作者：电子邮箱：yaox@outlook.com （X. Yao）skmoon@ntu.edu.sg（S.K. Moon）

1. 引言

激光定向能量沉积（LDED）增材制造（AM）工艺利用聚焦激光束熔化金属粉末或丝材，并逐层沉积以形成所需几何形状。过去十年间，凭借制造灵活性、减少废料、表面改性和修复等独特优势，LDED 在航空航天、国防、海洋与海上工业中受到广泛关注 [1]–[4]。尤其是与激光粉末床熔融（LPBF）和材料挤出等其他金属增材制造技术相比，LDED 适合以更高生产率和更低成本制造大型金属部件 [5]。尽管已取得诸多成果，LDED 在质量一致性和工艺重复性方面仍面临重大挑战。为确保增材制造生产顺利进行，必须对工艺进行原位监测并在线检测异常 [6]；然而，快速熔化和凝固过程中发生的复杂熔池动力学使这一任务颇具挑战。许多缺陷（如开裂、孔隙、层间分层等）和机械性能（如硬度、抗拉强度、延展性等）只能通过破坏性检测进行观察和评估。由于工艺处于极高温环境，大多数现有无损检测（NDT）方法仍不适用于在线监测。

基于视觉的原位监测是近年来激光增材制造中最受欢迎的监测策略之一。可使用同轴视觉相机或红外（IR）热像仪监测熔池形貌和温度特征，这些特征能够反映熔化、冷却和热传递状态 [7]–[9]。例如，Gonzalez-Val等人 [10] 使用高速中波红外（MWIR）相机监测定向能量沉积工艺中的熔池。他们开发了一种卷积神经网络模型，从原始图像中提取质量指标，并据此量化稀释程度和预测缺陷点。同样，Grasso等人 [11] 通过红外成像监测锌粉选择性激光熔化（SLM）过程中的能量与材料相互作用。他们从红外图像中提取特征，并进行统计分析，以检测不稳定熔化状态。Smoqi等人 [12] 使用同轴高温计获取熔池热图像，并从中提取熔池特征，例如峰值温度和轮廓面积。随后将这些特征反馈至闭环控制器，通过减少局部热积累来提高微观组织均匀性。文献 [11]–[13]还展示了类似的基于视觉的熔池过程控制方法和自适应质量提升方法。除熔池监测外，视觉传感器还可用于在线表面缺陷检测 [16]–[18], 、表面粗糙度监测，或增材制造构件的沉积道几何预测 [19]–[23]。例如，Li等人 [16]针对电弧增材制造（WAAM），开发了一种基于视觉的实时表面缺陷（如表面气孔、夹渣、沟槽等）检测方法，采用了YOLO算法。

最近，研究人员基于激光线扫描和原位点云处理，为LDED开发了一种表面缺陷识别方法 [24]。后续研究还证明，视觉传感器具备在加工过程中修正缺陷的能力 [25] ，从而实现自适应质量提升。

尽管基于视觉的监测解决方案已经达到一定的工业应用成熟度，但其实施通常耗时且成本高昂。需要对激光位移传感器或深度相机进行校准，以确保对零件表面几何 [26]的准确测量。各种视觉传感器的感知能力也存在显著差异。对于红外热像仪，需要进行发射率校准，以确保温度读数准确。这尤其困难，因为金属发射率会随温度、波长、材料相态及许多其他因素而变化[27]。无法精确测量熔池周围的实际温度分布[28]。此外，传感器集成的困难也限制了视觉传感器的使用。同轴视觉传感器的安装需要定制化的激光头设计，而离轴熔池监测则需要进行图像变换，其可靠性和准确性较低。对于工业终端用户而言，在传感精度、传感器价格和传感器集成复杂度之间进行权衡，确实是首要考虑因素。

相比之下，基于声学的监测方法具有独特优势，例如传感器配置灵活、动态响应快且硬件成本较低。在激光粉末床熔融和 LDED 中，激光与材料相互作用产生的声学信号可能包含有关复杂物理现象的信息，例如熔化、凝固、裂纹扩展和孔隙生长 [29]。此外，监测装置无需对增材制造设备进行任何改装。这些优点使声学监测对增材制造领域尤具吸引力。尽管针对激光增材制造中声学监测的研究有限，但声学监测已广泛用于检验焊接质量，例如熔深 [30], 孔隙率和裂纹 [31]。然而，由于增材制造是一个逐层成形且几何结构复杂的过程，与缺陷形成相关的声学信号比焊接过程中的复杂得多。

近期研究揭示了激光粉末床熔融过程中基于声学的监测方法 [32]-[35], 该方法在预测孔隙浓度方面取得了有希望的成果 [36], 能够对不同材料和缺陷类型（未熔合、匙孔、球化等）进行分类 [37], 利用半监督学习识别工艺错误[38], 并应用迁移学习评估不同材料的质量 [39]。这些应用通过低成本麦克风或光纤布拉格光栅传感器实现，传感器采集原始声学信号，并直接将其用于训练机器学习模型。在激光粉末床熔融过程中，由于存在保护气体流、铺粉和送粉系统，噪声可能会对声学信号产生显著影响。由于激光与粉末之间的相互作用发生在较小尺度上，嘈杂的腔室环境可能会影响原位工艺中的声学信号

监测。然而，在激光粉末床熔融中，激光扫描期间铺粉器和粉末输送系统并不运动，因此噪声主要来自保护气体流动、粉末流动和激光-材料相互作用。这使得激光-材料相互作用声难以分析。针对LDED中声学监测这一挑战的研究报道寥寥无几。例如，Hossain等人[40]开发了一种基于换能器的传感装置，将其安装在零件的基板上，并在定向能量沉积工艺期间采集声发射（AE）信号。研究采用统计方法验证了AE信号与定向能量沉积工艺零件质量之间的相关性。然而，所提出的传感器设置缺乏灵活性，仍需进一步研究。Prieto等人近期开展的研究[41] 也表明，使用麦克风声学信号检测定向能量沉积工艺中的裂纹是可行的，但该研究仍处于概念验证阶段。Gaja和Liou[42] 以及Hauser等人[43]也报道了LDED中类似的AE监测研究。尽管以往研究主要集中于声学信号分析、特征提取和监测，但我们的研究通过将声学降噪和特征与深度学习相结合，用于LDED过程中的缺陷分类，为该领域增添了一个新颖的研究方向。

为此，本文提出了一种创新的原位缺陷检测策略，利用麦克风和深度学习检测 LDED 中的缺陷。本研究的主要创新在于开发了一套原位声学信号去噪、特征提取和激光-材料相互作用声分类流程，并将先进的卷积神经网络（CNN）纳入其中。为实现原位监测，本文开发了一个基于机器人操作系统（ROS）的软件平台，用于执行声学信号处理和深度学习流程，并实时预测缺陷发生情况。本文采用声学去噪技术清理原始声学数据，其中包含机器移动、防护气体流动和粉末流动产生的噪声。随后，从时域、频域及时频表示中提取关键声学特征。利用激光-材料相互作用声的梅尔频率倒谱系数（MFCC）特征训练 CNN 模型，使其能够区分无缺陷状态、裂纹状态和匙孔气孔状态下的声音。本文将该 CNN 模型与多个基于去噪和原始声学数据集训练的经典机器学习（ML）模型进行了比较。验证结果表明，基于去噪数据集训练的 CNN 模型表现最佳，其总体准确率最高（89%），匙孔孔隙预测准确率最高（93%），ROC-AUC 分数最高（98%）。据我们所知，这是首项将声学信号与深度学习结合用于 LDED 过程原位缺陷检测的研究，可识别包括裂纹和匙孔气孔在内的特定位置缺陷。

本文其余部分的结构如下。第2节概述所提出的

用于通过深度学习进行原位缺陷检测的框架。第3节介绍了实验程序、数据集准备、软件架构，以及所提出的声学信号去噪技术、关键声学特征的提取和用于缺陷分类的卷积神经网络与机器学习模型的训练细节。第4节讨论了模型性能评估和验证的结果。最后，第5节总结了该研究的主要发现，并对LDED过程中的原位声学监测提出了进一步的工作方向。

2. 深度学习 基于学习的声学原位缺陷检测框架

图 1 展示了所提出的基于声学的原位缺陷检测框架概览，该框架由原位声学去噪、特征提取和激光-材料相互作用声分类流程组成。首先，应用信号去噪技术来清理含噪的 LDED 声音。第 3.3 节详细介绍了声学信号去噪及其结果。随后，从去噪声学信号中提取时域、频域及时频表示（倒谱域）中的关键声学特征。第 3.4 节对特征相关性及其与 LDED 缺陷之间的联系进行了定量研究和讨论。接下来，训练卷积神经网络模型和多种传统机器学习模型，将 LDED 声音分为三类：无缺陷、裂纹和匙孔气孔。以梅尔频率倒谱系数特征作为输入的卷积神经网络模型表现最佳（在所有模型中总体准确率达到 ~89%），并已集成到用于在线缺陷检测的软件中。第 3 节介绍系统设置、实验程序、数据集描述以及所提出的缺陷检测框架中各个步骤的详细信息。

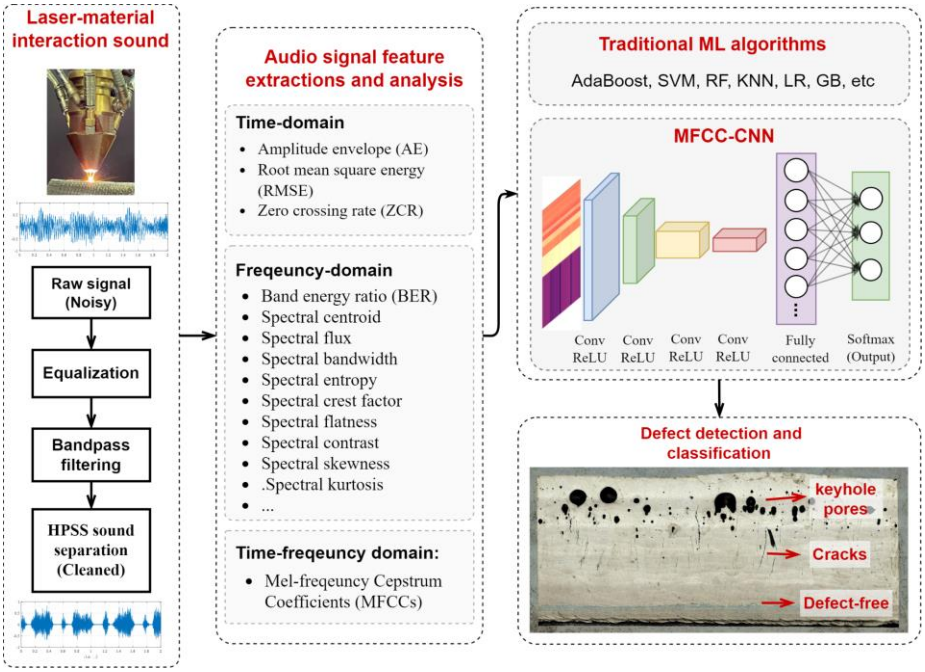

图 1。通过声学信号处理和深度学习实现的原位缺陷检测框架概览。

3. 方法

3.1 实验程序和原始声学数据集

图 2 展示了本研究所用的机器人激光定向能量沉积原位声学监测系统。该系统配备一台六轴工业机器人（KUKA KR90）和一台双轴变位机。激光头和同轴送粉喷嘴安装在机器人手臂的末端执行器上。LDED过程中的声音使用预极化麦克风传感器（Xiris WeldMIC）录制，其频率响应范围为 50 至 20,000 Hz。本研究所用的预极化麦克风传感器无需外接电源或前置放大器。麦克风可直接连接至笔记本电脑进行音频信号处理。麦克风放置在激光头旁边（距熔池约 10 cm）并倾斜约 30 度，采样率为 44,100 Hz，以满足香农-奈奎斯特定理[44]（即模拟信号可以转换为数字信号并将转换回模拟信号，而不会造成显著的信息损失）。

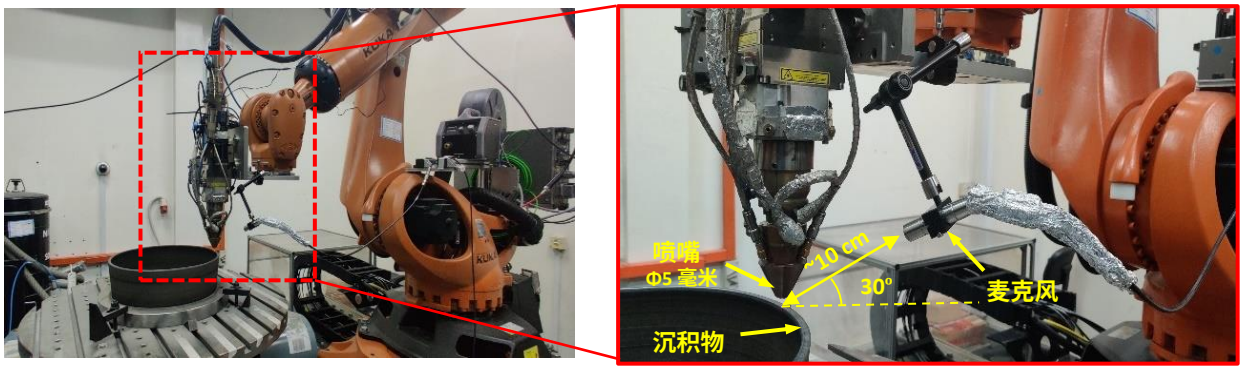

图2。机器人激光定向能量沉积系统的原位声学监测装置。

在送粉式激光定向能量沉积过程中，由于熔池冶金过程具有动态性和随机性，因此缺陷发生难以预测 [45]。从传导模式（例如无缺陷模式）转变为小孔模式熔化状态等异常状态尤其难以确定 [46]。在大多数情况下，采用试错法 [47] 或机理建模方法 [48] 来获得最优工艺参数，以制备致密且无缺陷的零件。然而，即使采用最优工艺参数，零件质量仍会出现波动。随着工艺持续进行，基板温度升高，导致沉积道不均匀、热影响区扩大、过度稀释、几何变形，以及因残余应力累积而产生开裂。此外，不稳定的熔池动力学和较高的能量密度可能导致材料蒸发，从而形成匙孔气孔。匙孔气孔和裂纹是LDED中最严重的缺陷，会直接降低力学性能，例如强度、显微硬度、

以及疲劳寿命 [46, 47]。

在本研究中，我们使用商用Maraging Steel C300粉末材料，在不同工艺参数下制备了若干单道壁结构，以构建增材制造声学数据集，如表1和表2所示。与现有大多数基于传感器的缺陷检测研究不同，我们并未刻意采用次优工艺设置来制造缺陷。相反，我们使用预先优化的工艺参数从头到尾沉积材料，从而观察从无缺陷状态到缺陷状态的转变。通过沉积块状样本开展试错实验，对工艺参数进行了优化。实验#1采用了原始优化打印参数，如表1所示。在打印用于采集声学数据的单道壁样本时，我们保持能量密度（P/v）不变，同时按比例调整激光功率和扫描速度。在不同实验中改变各层之间的停留时间，以推迟缺陷发生，因为停留[illegible]

[illegible]

图3(a)显示了为采集声学数据而制备的单道壁样本的OM图像（x-z外表面）。线切割工艺去除了单道壁的外表面，使我们能够观察特定位置的质量。如图3(a)所示，由于热量积累，沉积数层后，工艺从无缺陷状态转变为开裂状态。随着工艺推进，亚者的热积累导致材料蒸发，并在熔池中发生气体布留，从而在样本的上部层中形成匙孔气孔。将声学信号分割为500[illegible]

[illegible]

记为“裂纹/匙孔气孔”。这一过程使我们能够创建用于训练缺陷检测模型的标注数据集。

总声学数据集由从三个类别中分割得到的1300个长度为500ms的信号样本组成：无缺陷、裂纹和匙孔气孔（图3(b)）。还采集了每个去噪步骤前后的声学信号，用于验证所提出去噪方法的有效性。图3(c)-(d)展示了各类别去噪后的 LDED 声音。匙孔气孔的幅值最大，而裂纹具有明显的振幅包络，

而无缺陷状态的振幅更加稳定且更小。

表1. 用于声学数据采集的LDED实验。

实验	激光功率, P (kW)	速度，v （毫米/秒）	停留time (s)	粉末流动速率，f (g/min)	能量密度、P/v (kW·s /mm)	Line质量, f/v (g/mm)	缺陷类型生成
#1	2.3	25	0	12	0.092	0.480	裂纹，匙孔气孔
#2	2.53	27.5	0	12	0.092	0.436	裂纹，匙孔气孔
#3	2.3	25	5	12	0.092	0.480	裂纹，匙孔气孔
#4	2.3	25	10	12	0.092	0.480	裂纹，匙孔气孔
#5	2.53	27.5	5	12	0.092	0.436	裂纹，匙孔气孔
#6	2.53	27.5	5	12	0.092	0.436	裂纹, 匙孔气孔

表2。实验期间的其他LDED过程设置。

参数	数值
几何	单道壁结构
尺寸	90 mm * 42.5 mm
每个样品的层数	50
激光束直径	2 mm
层厚度	0.85 毫米
离焦距离	12 毫米
激光轮廓	高斯
激光波长	1064 纳米
材料	C300 马氏体时效钢

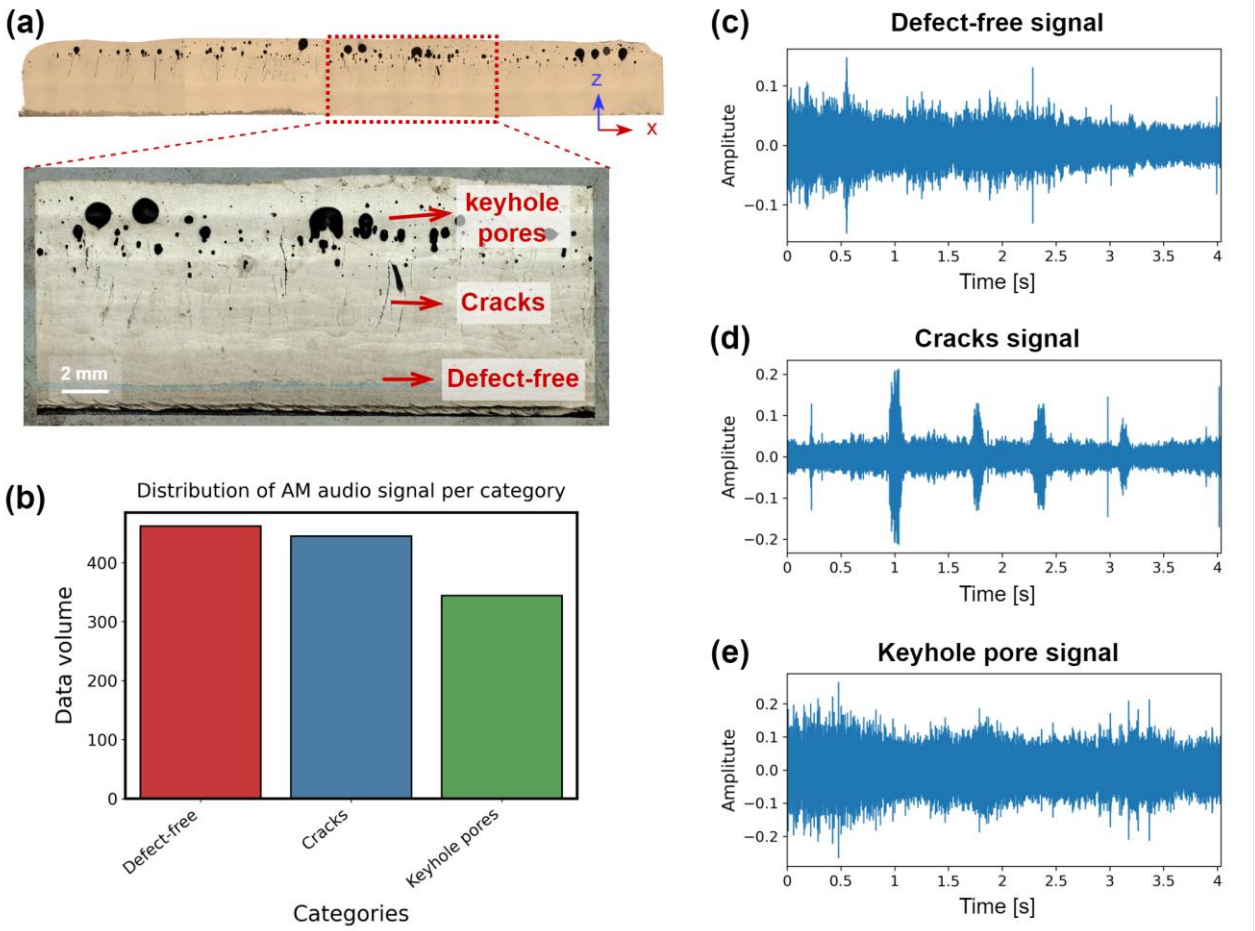

图 3。LDED 音频数据集的准备与说明。(a) 为采集声学数据而制作的单道墙样品的 OM 图像（图像取

3.2 基于声学的缺陷检测软件架构

自主设计的软件部署在运行 Linux（Ubuntu 20.04LS）的个人计算机（PC）上，作为基于声学信号的缺陷识别中央控制器。原位声学监测软件采用了与 [51] 和[24], 中报道的类似多节点理念，其中使用机器人操作系统（ROS）开源框架 [52] 建立传感器、机器人和 PC 之间的通信。图 4 展示了所提出的软件架构，由用于原始声学信号采集、去噪、特征提取、缺陷预测的 ML/DL 模型以及在线特征数据可视化的 ROS 节点组成。ROS 节点同时运行，并通过主题通道交换数据。“订阅”和“发布”描述了 ROS 节点之间的通信机制。“订阅”是指节点通过主题通道接收来自另一节点的数据。“发布”是指节点将数据发布到某个主题，从而向其他节点发送数据。节点既可以订阅多个主题，也可以发布到多个主题，从而实现灵活的通信。

机器人系统。许多事件驱动系统和物联网（IoT）平台都采用发布/订阅消息模型，包括消息

多既可以发布主题，也可以订阅主题来交换信息。因此，ROS之外的平台也可以采用图 4 所

示的相同软件架构。下面对软件架构的具体细节进行说明。

- “麦克风传感器采集节点”提取带时间戳的原始声学信号，并将其作为 ROS 主题发布。原始声学数据以 44100 Hz 的采样率采集并存储在缓冲区中。ROS 以 30 Hz 的频率发布带时间戳的信号。
- “声学信号去噪节点”订阅原始声学数据并执行去噪算法（即均衡化、带通滤波和谐波-打击乐源分离（HPSS）间戳的降噪信号作为 ROS 主题发布。原始信号和降噪信号均可供订阅，用于离线数据分析。
- “原位特征提取节点”订阅降噪数据，并提取幅度包络（AE）、频谱描述符和梅尔频率倒谱系数等关键特征。声学特征提取采用 nussl [57] 和 librosa [58] 库实现。
- 机器学习模型（例如 K近邻（KNN）、支持向量机、梯度提升等）和 MFCC-CNN模型被加载到一个 ROS 节点中，该节点订阅提取的特征并将其存储到缓冲区中。这些模型可以进行推理，并每 500 ms 将预测缺陷发布为 ROS主题。
- 所有特征均可通过PlotJuggler插件 [59]在线可视化。

所提出的原位缺陷检测策略能够在机器运行过程中预测缺陷的发生，而不是依赖离位质

该反馈信号优表光前质量，可用于闭环过程调整。软件在检测到缺陷时可以发出警告，并可

立即停止过程，以防止质量进一步下降，或者，在检测到缺陷时可以降低激光功率，从而最

大限度地减少局部热积累。

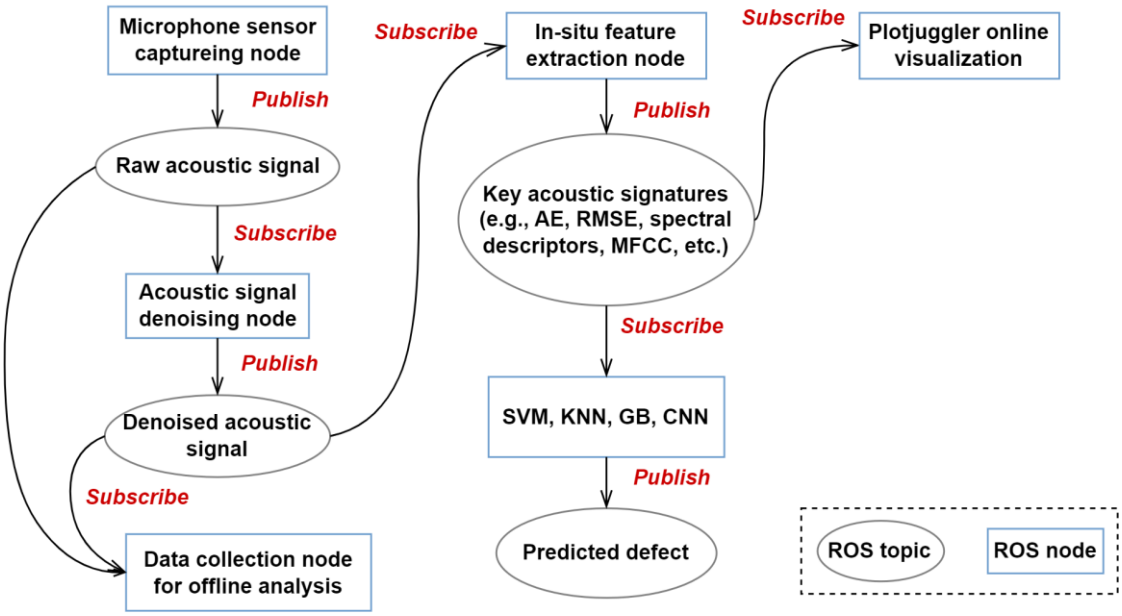

图 4. 基于麦克风传感器自主开发的 ROS 软件架构，用于通过麦克风传感器对 LDED 过程进行原位监测和缺陷预测。

3.3. 声学信号去噪

LDED过程的原始声学信号包含来自多个来源的噪声，包括机器运动、粉末流和保护气体流。图5展示了不同尺度下LDED过程中各种声音源的快速傅里叶变换（FFT）[60]。图5（a）以线性尺度展示幅值。图5（b）以对数尺度“分贝（dB）”展示幅值。在这种情况下，分贝值是归一化音频数据样本幅值的对数，使我们能够更轻松地检查和分析音频信号的结构和内容。图5（a）和（b）分别比较了对数尺度和线性尺度下的FFT频率。图5（a）中的FFT图揭示了低频带（<1000 Hz）中的信号内容，而图5（b）中的FFT图则揭示了1000Hz以上音频信号内容的更多信息。此外，每个声音成分都是单独采集的，且没有其他声源是个信号状态。频率频带中的信号。在这些频带中，LDED激光材料相互作用声音占主导地位。此外，机器声音显然对低频频带噪声的贡献最大，而其他声音源对总音频输出的影响相对较小。然而，由于所有声音源都会对整个频带中的能量产生贡献，因此声学信号分离具有挑战性。提出了一种LDED声音源分离技术，以便从

n 钱柜嘈杂环境下我们先前的研究 [61], 其简要说明如下 s.

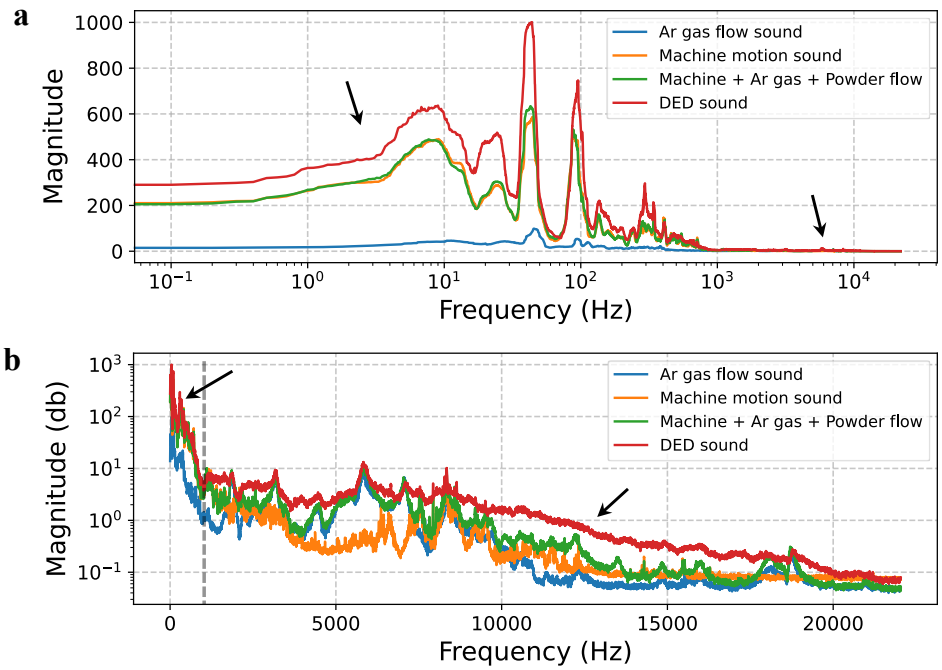

图 5. LDED过程中各种声学信号源的快速傅里叶变换（FFT）图：(a) 频率采用对数刻度，幅值采用线性刻度；(b) 幅值采用对数刻度，频率采用线性刻度。

首先使用声学校正技术 [62], 对原始信号进行调整，该技术会改变不同频带的幅值。并行声学校正的传递函数 $H_{eq}(z)$可写为：

$$H_{eq}(z) = \sum_{m}^{M} G_m H_m \quad (1)$$

其中H_m 表示不同频段的传递函数，而G_m 表示调节各带宽振幅的信号增益。为降低噪声成分并提高激光金属加工产生的声音音量，手动调节均衡器中的增益。增强频率范围为 1000 Hz 至 20,000 Hz 的声音，而将该区域之外、机器噪声占主导的频率声音静音。随后，为消除高频和低频噪声，采用带通滤波器。带通滤波器允许 1000 至 21,000 Hz 之间的频率通过，同时衰减通带之外的频率。使用 Python SciPy库进行带通滤波，滤波器阶数设为 3。最后，采用谐波-打击乐源分离（HPSS）[56] 技术提取打击乐。

LDED 声音中的组成部分。

图 6展示了三步声学信号去噪方法各阶段的FFT 图。声学均衡器降低了低频噪声，同时提高了1000至 20k Hz 范围内的振幅。通过提高感兴趣信号的音量，激光-材料相互作用声得到了放大，并且降低了噪声占主导区域的音量。随后，带通滤波器衰减了通带1000 Hz至21,000 Hz以外的频率。在最后一步中，HPSS算法提取了音频信号中的打击乐声音成分。因此，大部分环境噪声都被消除或大幅降低。

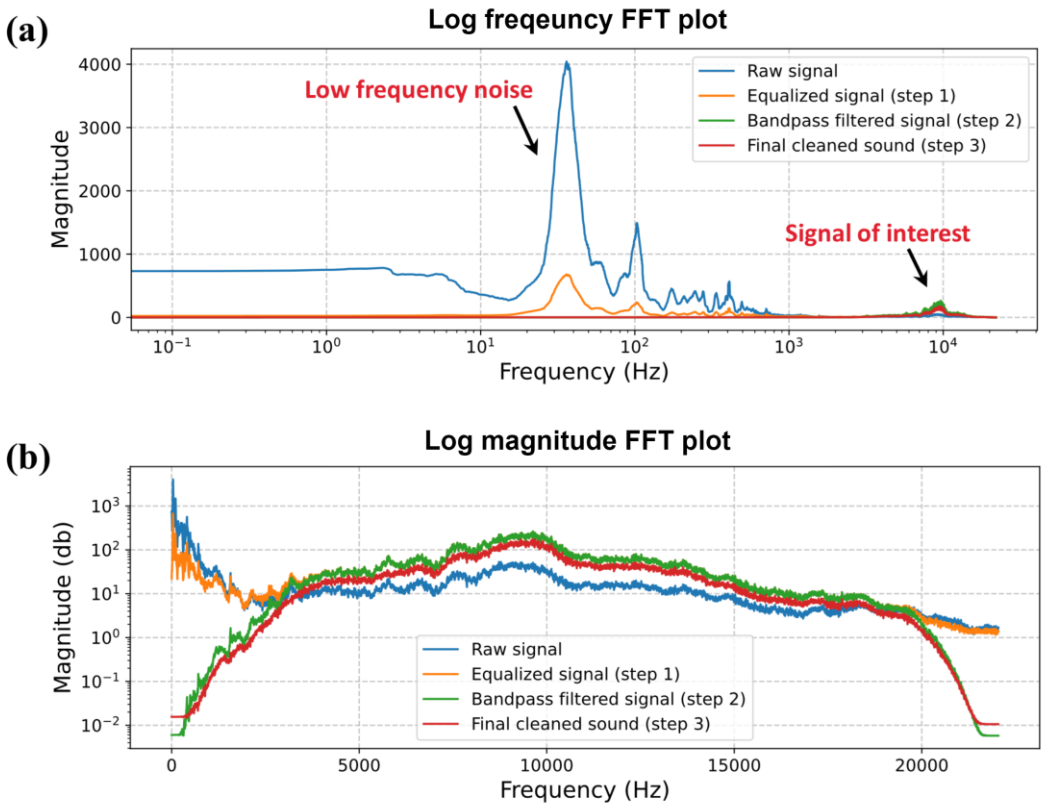

图 6。声学信号去噪的每个步骤均通过快速傅里叶变换（FFT）图表示：（a）频率采用对数刻度，幅值采用线性刻度；（b）频率采用线性刻度，幅值采用对数刻度。

图 7 展示了所提出的信号去噪技术的有效性。图 7(a) 对比了实验 #1 的原始信号和最终的去噪声学信号（对应图 3(a) 所示的显微镜图像）。该过程从无缺陷状态转变为裂纹状态，随后进入匙孔孔隙状态。降噪信号的振幅包络更加明显。图中可以观察到激光开启和关闭的时间段。为展示各去噪步骤的有效性，我们选取了裂纹状态下的一段声学信号，

如图 7(b)–(e) 所示。从原始信号中难以辨识裂纹声音的振幅包络。经过均衡化后，1000 Hz 至 20 kHz 之间的目标信号得到放大，同时噪声有所降低。带通滤波消除了残留噪声，而最后的 HPSS 阶段则清晰地提取出裂纹声音，如图 7(e) 所示。

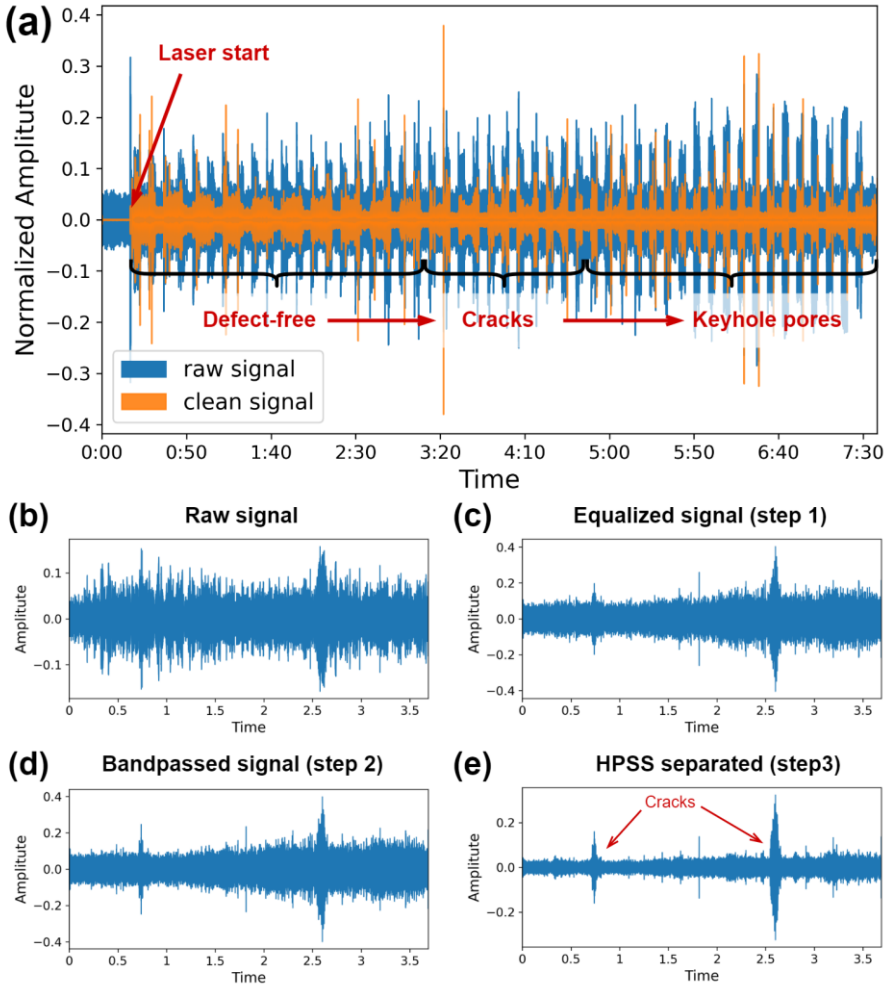

图 7。声学信号去噪步骤的可视化。(a) 一次实验中原始声学信号与最终降噪信号的比较，对应于图 3(a) 所示的显微镜图像。该过程从无缺陷状态过渡到裂纹状态，再到钥孔气孔状态。(b)-(e) 每个去噪步骤后声学信号的可视化。所选取的声音片段属于裂纹状态。

3.4. 声学特征提取

本节分析时域、频域和时频表示中的关键声学特征，并定量研究声学特征与输出类别（即无缺陷、裂纹、匙孔气孔）之间的相关性。采用斯皮尔曼公式 [63] 计算声学特征与类别标签之间的相关性（r_{ij}）：

$$r_{ij} = 1 - \frac{6\sum {d_{ij}}^2}{n(n^2-1)} \quad (2)$$

其中，d_{ij} 表示i^{th} 和j^{th} 特征变量的排名差异，n 表示数据点总数。r_{ij} 的取值范围为 -1（表示最强负相关）至 1（表示最强正相关），0 表示不相关。完整的特征相关矩阵见附录 A。图 A1。下面将逐一讨论各个特征。

3.4.1 时域特征

表3总结了时域声学特征、其数学定义及描述。在提取时域特征之前，必须指定librosa音频信号处理库[58] 中的窗口参数，将帧大小设置为512，并将跳跃长度设置为256。窗口化[64]是利用随时间滑动的窗口，将长音频信号分析为准稳态信号小片段的方法。共提取了三种时域特征，并计算了每个音频数据片段中这些特征的均值和方差。

- 振幅包络（AE）由帧的最大振幅值构成。AE 特征可以表明声能随时间的波动情况，并直接反映幅值变化。如图 A1 所示，AE 均值和方差与输出类别呈正相关，这表明与裂纹和无缺陷声音相比，匙孔气孔声音的 AE 值更大且更不稳定。

- 均方根能量（RMSE）是通过计算一帧中所有样本的均方根得到的。与 AE 类似，RMSE 可以表示声音随时间变化的幅值和波动，但对异常干扰的敏感度较低。图 A1 显示，RMSE 的均值和方差也与缺陷呈正相关。

- 信号符号变化的频率称为过零率（ZCR）。过零率在语音识别和音乐信息检索领域得到了广泛认可，是识别打击乐声音的重要因素。[65]。如第 3.3 节所述，研究发现 LDED 过程中的声音与声学信号中的打击乐成分有关；因此，过零率可能与过程中熔化的材料量相关。图 A1 显示，过零率的平均值与缺陷呈负相关：过零率越高，缺陷越少，熔化条件也越稳定。

表 3。时域声学特征及数学定义列表

特征名称	数学表达式	描述	Ref
振幅 包络（AE）	$AE_t = \max\left(s_{(k)}[t \cdot K, (t+1) \cdot K - 1]\right)$ - AE_t: k^{th} 帧处的声发射 t - $s_{(k)}$: 样本的振幅 - K: 帧中的样本数	描绘……的边界曲线 信号振幅随时间的变化， 捕捉其中能量如何 信号变化。	[66]
均方根 能量（RMS）	$RMS_t = \sqrt{\frac{1}{K} \cdot \sum_{k=t \cdot K}^{(t+1) \cdot K - 1} s_{(k)}{}^2}$	帧中所有样本的均方根： 响度指示	[67]
过零率 (ZCR)	$ZCR_t = \frac{1}{2} \cdot \sum_{k=t \cdot K}^{(t+1) \cdot K - 1} \left\lvert sgn(s_{(k)}) - sgn(s_{(k+1)}) \right\rvert$ - sgn: 函数的符号（+1、-1 或 0）	信号的频率穿过 时间轴：识别 打击乐声与有音高声音	[65]

3.4.2 频域特征

图 8 展示了三种不同类别（即无缺陷、裂纹和匙孔气孔）的去噪声学信号的 FFT 图。匙孔气孔声音在低频带（0-5000 Hz）的幅值显著较大，其次是裂纹声音和无缺陷声音。无缺陷声音在 5000 至 10000 Hz 频率范围内的幅值较高，而裂纹和匙孔气孔在此频率范围内的幅值相近。FFT 图中明显的模式表明，可以提取各种频谱描述符，用于后续的声音分类任务。表 4 总结了频域声学特征、其数学定义和描述。以下将逐一讨论各频域特征。

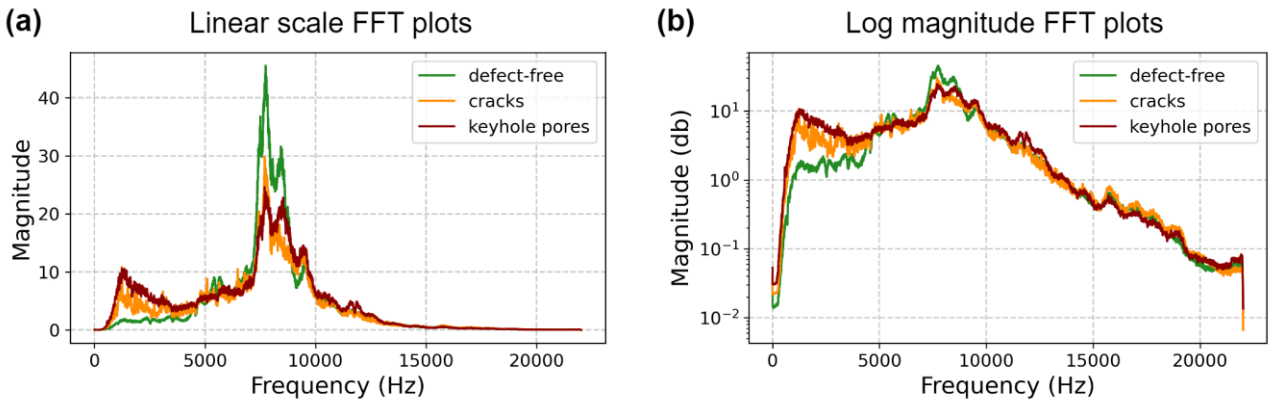

图 8。不同类别（即无缺陷、裂纹和匙孔气孔）的 LDED 声音的快速傅里叶变换（FFT）图。（a）线性尺度下的 FFT 图，（b）对数幅度尺度下的 FFT 图。

- 谱质心（SC）是幅度谱的重心（COG），通过计算所有频率的加权平均值确定。图 A1 显示，SC 的均值与缺陷呈负相关。

- 频谱带宽（SBW）（也称为频谱扩展或离散度）用于衡量幅度谱相对于谱质心（SC）的变化。图 A1 显示，SBW 的变化与缺陷明显呈正相关，其中匙孔气孔会导致 SBW 变化更大。由于 SBW 可以表明某个音调的主导程度（例如，音调分散时（呈噪声状），带宽会增大；音调汇聚时（呈节奏状），带宽会减小）[68], ，这一发现意味着无缺陷声音更加均匀且能量集中，而存在缺陷时，声音信号则更接近噪声状。

- 谱滚降（Rolloff）用于衡量包含给定百分比（85%）总能量的频率点，常用于音乐流派分类[69]。如图 A1 所示，Rolloff 值也与缺陷的存在呈负相关，而 Rolloff 的变化则与缺陷呈正相关。

- 谱平坦度（SF）计算功率谱的几何平均值与算术平均值之比，用于量化频率分布的均匀性。图 A1 表明，谱平坦度与缺陷呈负相关。

- 频带能量比（BER）定义为低频带中的功率除以高频带中的功率。正如图8 中前文的FFT图所示，缺陷在低频带中的幅值更大，而在高频带中的幅值更低。因此，图 A1 中的结果揭示了频带能量比与缺陷之间的正相关关系。

- 频谱方差、偏度和峰度分别是谱的二阶、三阶和四阶矩。这些统计特征反映了频域中幅度谱的各种属性，常用于音乐流派分类和语音识别 [64]。图 A1 显示，方差、偏度和峰度的均值均与缺陷的存在呈负相关。

- 谱峰因子表示谱的尖峰程度。对于谐波声音，其值更高；对于噪声声音，其值更低。如图 A1 所示，这与 SBW和SF中的结论相同，即较低的值对应缺陷声音，而缺陷声音更接近噪声状信号。

- 谱熵用于衡量能量分布的尖峰程度和均匀性。如图 A1 所示，它与缺陷呈负相关。谱通量是 L-2 的度量

谱随时间的范数，并且与缺陷呈正相关。

表4. List　　频域声学特征及其相应的数学定义

特征名称	**数学表达式**	**描述和备注**	**参考值**
谱质心 (SC)	$SC_t = \frac{\sum_{n=1}^{N} m_{t(n)} \cdot n}{\sum_{n=1}^{N} m_{t(n)}}$	频率的加权平均值。n 表示频带，$m_{t(n)}$ 为谱值（幅值），用于 n。N 是.....的范围频带。	[70]
频谱的带宽（SBW）	$SBW_t = \frac{\sum_{n=1}^{N} \lvert n - SC_t \rvert \ m_{t(n)} \cdot}{\sum_{n=1}^{N} m_{t(n)}}$	频带距离的加权平均值来自谱质心（能量扩散）。	[70]
频谱滚降 (SR)	$SR_t = i$ 满足 $\sum_{n=1}^{i} \lvert m_{t(n)} \rvert = \eta \sum_{n=1}^{N} \lvert m_{t(n)} \rvert$	某一特定比例对应的中心频率（85%）的总能量所在位置。η 是能量阈值（85%）。	[71]
谱平坦度 (SF)	$SF_t = \frac{(\prod_{n=1}^{N} m_{t(n)})^{\frac{1}{n}}}{\frac{1}{n}\sum_{n=1}^{N} m_{t(n)}}$	频谱的几何平均值除以算术平均值：用于确定声音中噪声状成分与音调状成分的比例。	[72]
频带能量比（BER）	$BER_t = \frac{\sum_{n=1}^{F-1} m_{t(n)}{}^2}{\sum_{n=F}^{N} m_{t(n)}{}^2}$	低频带中的功率除以高频带中的功率，其中 F 表示分界频率，其设定为7000 Hz.	[73]
谱对比度（对比度）	$Contrast_t = \frac{\sum_{peak} m_{t(n)}{}^2}{\sum_{valley} m_{t(n)}{}^2}$	取最高分位数中的平均能量，并将其与最低能量的平均值进行比较分位数。高对比度水平通常是与清晰的窄带信号相关，并且较低的对比度值与宽-带噪声。	[73]
频谱方差 (μ_2)	$\mu_2 = \sqrt{\frac{\sum (\sum_{n=1}^{N} n - SC_t{}^2 m_{t(n)})}{\sum_{n=1}^{N} m_{t(n)}}}$	频谱质心附近的标准差谱质心。	[74]
频谱偏度 (μ_3)	$\mu_3 = \frac{\sum (\sum_{n=1}^{N} n - SC_t{}^3 m_{t(n)})}{(\mu_2)^3 \sum_{n=1}^{N} m_{t(n)}}$	谱的三阶矩，用于衡量质心周围的对称性。	[74]
谱峰度 (μ_4)	$\mu_4 = \frac{\sum (\sum_{n=1}^{N} n - SC_t{}^4 m_{t(n)})}{(\mu_2)^4 \sum_{n=1}^{N} m_{t(n)}}$	谱的四阶矩。	[74]
谱峰 (峰值)	$Crest = \frac{\text{最大值}\ (m_{t(n)}[1,N])}{\frac{1}{N}\sum_{n=1}^{N} m_{t(n)}}$	谱的最大值与其算术平均值。	[74]

谱熵 (H)	$H_t = \frac{-\sum_{n=1}^{N} m_t(n) \cdot \log(m_t(n))}{\log(N)}$	衡量频谱的尖峰程度。	[75]
谱通量 （通量）	$Flux_t = \left(\sum_{n=1}^{N} \left\|m_{t(n)} - m_{t-1(n)}\right\|^p\right)^{\frac{1}{p}}$	衡量谱随时间的变化程度，在音频分割中很常用。p 是范数类型。本研究中，$p = 2$ 选用 L2范数。	[76]

3.4.3 时频表示倒谱特征

前述研究仅提取了时域和频域中的声学特征。时频表示[77] 通常是音频信号处理更有效的方法，因为可以计算不同频带中的相对能量密度。这使得能够同时在频域和时域中表达声学特征。常见的时频表示包括通过短时傅里叶变换（STFT）计算的声谱图[78], 通过小波变换（WT）计算的尺度图[79], 以及倒谱域特征 [80]。在本研究中，选择了梅尔频率倒谱系数（MFCCs）[81] 作为倒谱域特征。MFCCs 是实时语音识别应用中的常见选择。MFCCs 的主要优势在于计算效率高，并且能够捕捉感知特征。与STFT 和WT相比，MFCC 所需的计算量更少，因此在音频特征提取任务中速度显著更快。此外，MFCC通过对频率尺度应用非线性变换，可以模拟人耳的感知敏感性；与正常谱（例如WT 和STFT）中使用的线性

梅尔频率倒谱系数通过对信号频谱的对数进行逆傅里叶变换得到，其表示如下：

$$\boldsymbol{C}_{(x(t))} = F^{-1}[\log(F[x(t)])] \quad \textbf{(3)}$$

其中，函数 $\boldsymbol{C}_{(x(t))}$ 计算信号 $x(t)$ 的倒谱。F 表示傅里叶变换函数，F^{-1} 表示逆傅里叶变换。图9展示了在 Python 中实际实现梅尔频率倒谱系数的流程图，其中使用离散余弦变换来降低表示谱的

维度。图10展示了从每个类别（即无缺陷、裂纹和匙孔气孔）的去噪声学信号中截取的4秒片段的梅尔频率倒谱系数值结果。所有梅尔频率倒谱系数值均归一化至 -1 到 1 的范围。如图所示，梅尔频率倒谱系数是一种强大的特征，能够区分不同加工工况下的 LDED 声音。在无缺陷沉积过程中，低频频带中的梅尔频率倒谱系数值较低。裂纹和匙孔气孔中的较亮颜色（接近1的值）表示低频频带中的能量浓度较大。由于开裂是一个释放能量的过程，声波能够通过呈现反映裂纹扩展所诱发的声能突然增加的独特模式，轻易地区分出这类异常现象。

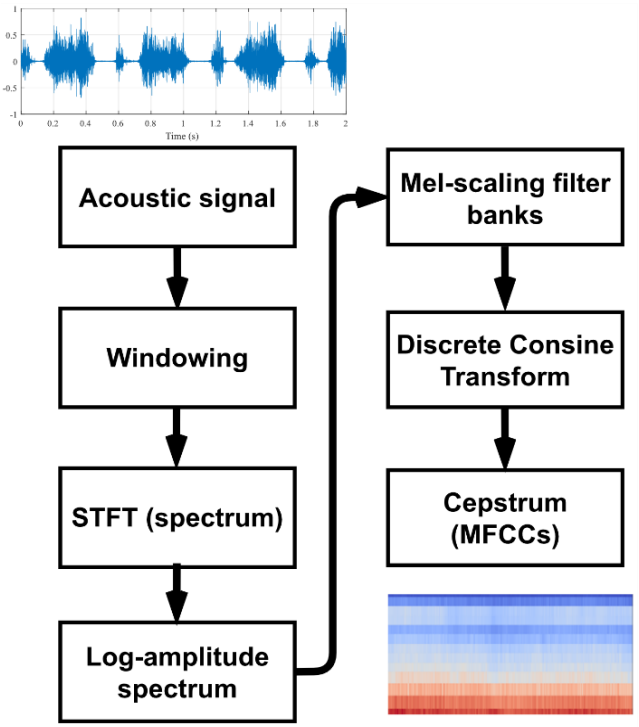

图9。梅尔频率倒谱系数（MFCC）的提取过程。

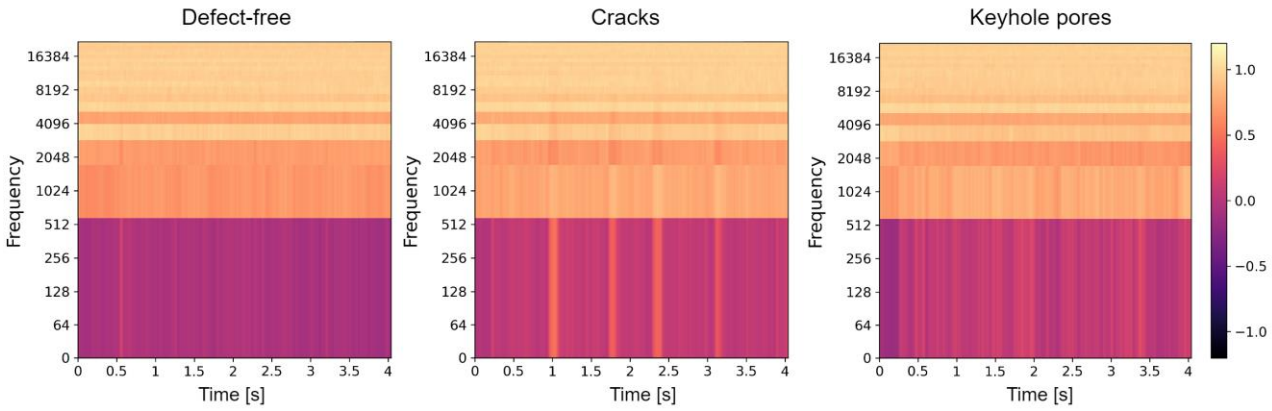

图10。各类别梅尔频率倒谱系数特征的可视化。

3.4.4 声学特征分析

在将声学特征输入机器学习模型以执行缺陷分类任务之前，探究这些特征之间的关系有助于选择合适复杂度的机器学习模型。我们进行了特征重要性分析，以确定哪些特征最能区分不同的工艺状态（即无缺陷、裂纹和匙孔气孔）。图11(a)展示了随机森林特征重要性分析的结果。LDED 声音中最重要的特征为 BER、谱质心、熵、带宽、平坦度、滚降和方差。然而，显然所有特征的重要性都较低（其中最高值仅略高于0.12）。这是因为缺陷形成过程极其复杂，任何单一特征都无法充分表征声学信号。图11(b)展示了从降噪信号中提取的最重要声学特征的斯皮尔曼相关矩阵。此外，为了可视化高维声学数据，我们使用主成分分析（PCA）进行降维。图11 (c)和(d)分别展示了原始声学信号特征和去噪声学信号特征的PCA投影。结果表明，去噪后的声学特征在低维空间中可以形成不同的簇，而原始信号则难以区分。

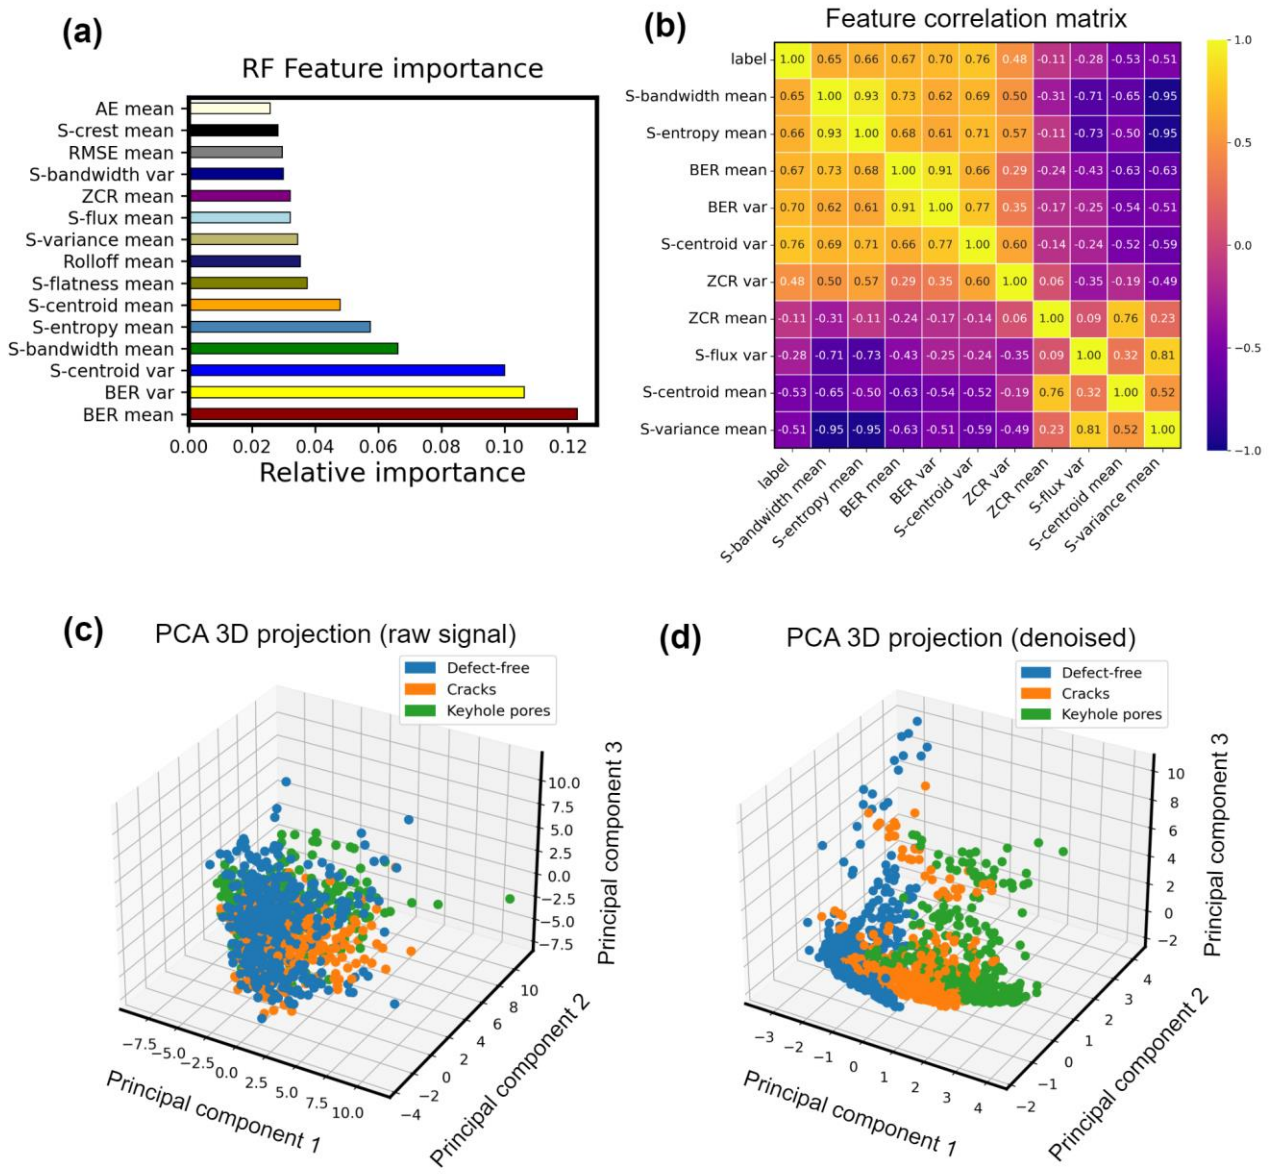

图 11。声学特征分析。（a）去噪声学信号的随机森林特征重要性。（b）关键声学特征与输出类别（即无缺陷、裂纹和匙孔气孔）的相关性矩阵热图。（c）通过原始声学信号特征的 PCA 投影进行低维特征可视化。（d）通过去噪声学信号特征的 PCA 投影进行低维特征可视化。

3.5. 缺陷预测模型

3.5.1 MFCC-CNN

我们使用 TensorFlow [82]Python 深度学习框架开发并实现了卷积神经网络（CNN）。如图12所示，该CNN模型以梅尔频率倒谱系数作为输入特征，因此称为MFCC-CNN。所提出的MFCC-CNN由三个卷积层、一个展平层、一个全连接层和一个SoftMax层组成。
MFCC-CNN接收

将从声学信号各片段中提取的梅尔频率倒谱系数值作为输入，其中倒谱域特征表示为20个频带。在输入模型之前，对输入特征进行归一化，使其具有零均值和单位方差。对于卷积层，二维卷积后接ReLU [83] 激活函数，随后连接最大池化层。每次最大池化操作都会减小二维卷积层的空间维度，相应的维度如图12所示。输出层是一个SoftMax [84] 函数，用于预测三个输出类别的概率分布（即无缺陷、裂纹和匙孔气孔）。表5列出了MFCC-CNN模型的超参数。使用K折交叉验证网格搜索法对超参数进行优化。选择Adam优化器 [85] 作为优化求解器，通过最小化真实标签与模型预测之间的交叉熵损失来训练模型 [86]。训练使用配备NVIDIA GeForce RTX 3070GPU的Keras和TensorFlow Python深度学习

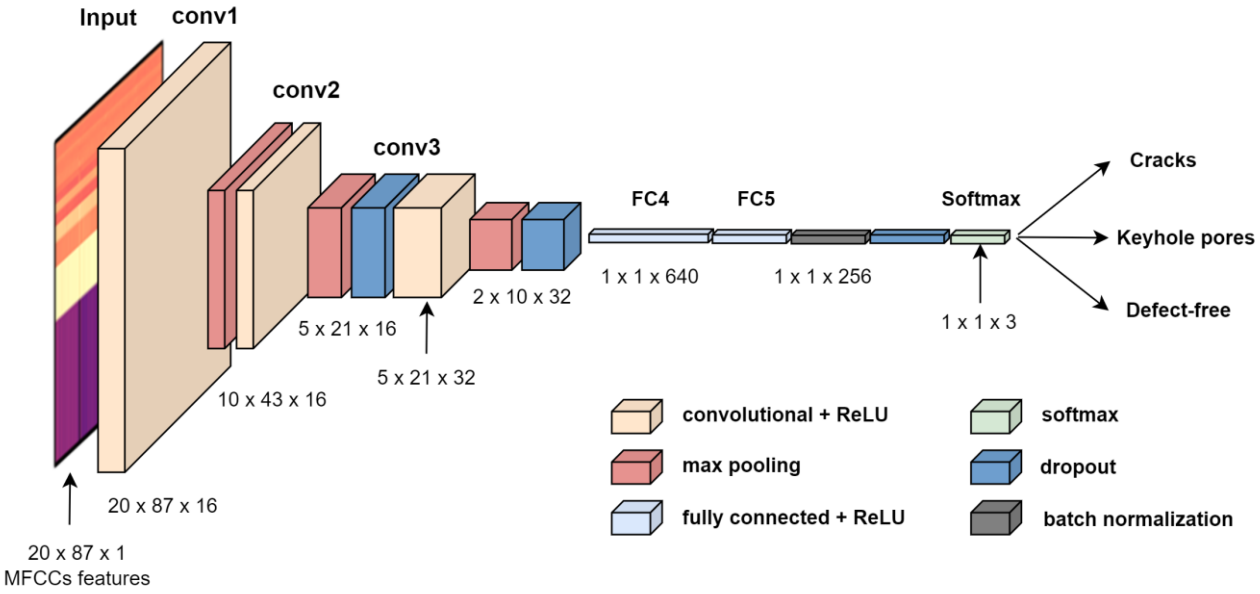

图12。基于梅尔频率倒谱系数的卷积神经网络（MFCC-CNN）的架构。

表5。MFCC-CNN超参数调优信息

训练超参数	最优值	研究范围
求解器名称	Adam优化器	['Adam', '随机梯度下降']
学习率	0.0001	[1e-2, 1e-3, 1e-4]
L2正则化因子	0.1	[0.01, 0.05, 0.1, 0.15]
激活函数	ReLU	['ReLU', 'Sigmoid']
批量归一化	True	['真', '假']
卷积层1-3中的卷积核大小	[2, 2, 3]	[[2, 3, 5], [2, 3, 5], [2, 3, 5]]

滤波器（通道）数量 in 卷积层 1-3	[16, 16, 32]	[[16, 32], [16, 32, 64], [32, 64, 128]]
卷积层 1-3 中的步幅	[1,1,1]	[[1, 2], [1, 2], [1, 2]]
填充	‘相同’	[‘相同’、‘零’]
FC5中的神经元数量	256	[64, 128, 256]
Dropout – 卷积层3	0.2	[0.1 - 0.5]
Dropout – FC4	0.5	[0.1 - 0.5]
Dropout – 全连接层5	0.2	[0.1 - 0.5]
跳跃长度	256	[128, 256, 512]
帧大小	512	[128, 256, 512, 1024]

3.5.2 传统机器学习模型

在本研究中，我们将所提出的 MFCC-CNN 模型与八种传统监督学习算法进行比较：朴素贝叶斯（NB）、随机森林（RF）、AdaBoost（AB）、决策树（DT）、支持向量机（SVM）、逻辑回归（LR）、梯度提升（GB）和 K近邻（KNN）。Scikit-Learn Python 包 [87] 用于实现机器学习算法，以进行训练和测试。传统机器学习算法使用第 3.4 节所述的时域和频域特征对 LDED 声音进行分类。输入特征根据第 3.4.4 节的分析选取，包括“频谱带宽均值”、“谱熵均值”、“BER 均值”、“BER 方差”、“谱质心方差”、“过零率方差”、“过零率均值”、“谱通量方差”、“谱质心均值”和“谱方差均值”。

为了优化机器学习模型的超参数，采用网格搜索方法。这是一种穷举搜索策略，会评估[illegible]评估。复合k-折都会重复进行k-折交叉验证。网格搜索结束时，选取交叉验证结果最佳的超参数组合。传统机器学习模型的最优超参数结果列于表6。

表6。传统机器学习算法的超参数优化结果

分类器	超参数	最优值	研究范围
NB	方差平滑	1e-9	[1e-10, 1e-9, 1e-8]
RF	最小分割值	3	[2 - 6]
	估计器数量	10	[2 - 10]
	划分算法	基尼不纯度	[“基尼系数”、“熵”]
	最大深度	4	[2 - 6]

AdaBoost	估计器数量	10	[1 - 10]
	算法	SAMME	['SAMME'、'SAMME.R']
KNN	邻居	4	[3 - 9]
	预测中的权重函数	距离	['均匀的', '距离']
	最近邻的计算	球树	['自动'、'球树'、'kd_tree']
LR	求解器	‘lbfgs’	[‘lbfgs’、‘liblinear’、‘newton-cg’]
	惩罚	L2 正则化	[‘l1’, ‘l2’, ‘elasticnet’]
SVM	核类型	径向基函数	[‘linear’, ‘poly’, ‘rbf’, ‘sigmoid’]
	正则化参数 (C)	1000	[1, 10, 100, 1000, 1500, 2000]
	核系数 (γ)	0.001	[1e-2, 1e-3, 1e-4]
DT	拆分所需的最少样本数	3	[1 - 10]
	分裂质量的测量	Gini	['基尼指数'、'熵']
	最大深度	6	[1 - 30]
GB	估计器数量	10	[1, 5, 10, 20, 50, 100]

4. 结果与讨论

为验证所提出降噪技术的有效性，使用不同降噪阶段的声学信号训练MFCC-CNN和传统机器学习模型。将每个降噪步骤对应的声学信号（原始信号、均衡信号、带通滤波信号和最终降噪信号）划分为训练集和测试集，以评估模型性能。训练集与测试集的比例为8:2。训练数据集包含1080个样本。由于各类别的数据点数量不同（如图3(b)所示），因此使用Scikit-Learn中的“分层随机拆分”方法创建训练集和测试集，同时保持各类别中的样本占比不变。

分别如图13(a)和(b)所示，MFCC-CNN在原始声学数据集和去噪声学数据集上训练得到的测试准确率曲线。采用去噪数据集训练的MFCC-CNN收敛更快，测试准确率更高，证实了所提出的声学降噪方法的有效性。下文将详细呈现并讨论相关比较结果。

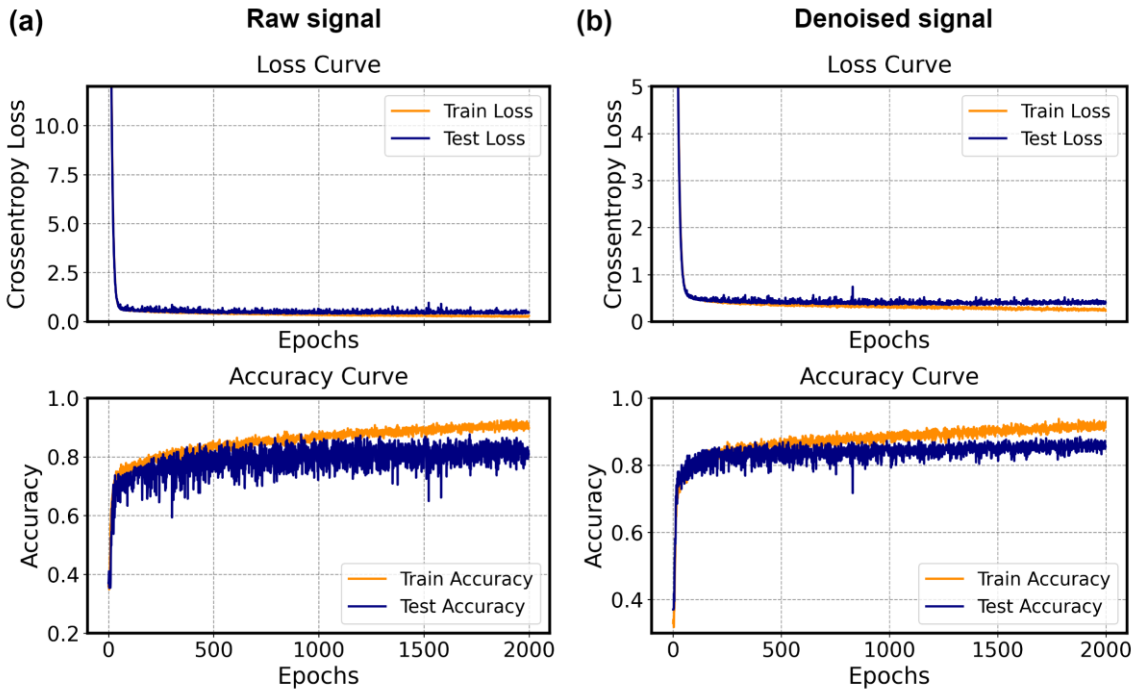

图 13。CNN 模型分别在 (a) 原始声学信号和 (b) 降噪信号上训练所得的损失和准确率曲线。在去噪数据集上训练的 MFCC-CNN 收敛更快，测试准确率更高。

从整体分类准确率、受试者工作特征曲线下面积（AUC-ROC）得分、假阳性率（即被错误分类为‘无缺陷’类别的实际缺陷百分比）以及匙孔孔隙预测准确率等方面，对所提出的MFCC-CNN模型和八种传统机器学习算法进行了评估。为证明其可行性和可重复性，本文报告的所有机器学习模型评估结果均取五次运行的平均值，并以误差条标示标准差。

总体准确率是正确预测的数量除以预测总数，如下式所示：

$$Accuracy = \frac{\#Correctly\ predicted\ samples}{\#Total\ predictions} \tag{4}$$

图14(a)展示了基于不同去噪阶段的声学信号训练的八种传统机器学习模型和MFCC-CNN模型的分类准确率。总体而言，每经过一次去噪处理，准确率都会提高。图14(b)中的ROC曲线下面积得分也表明，除LR、支持向量机和GB等少数例外外，模型性能均随去噪步骤的推进而提升。在所有分类器中，基于去噪声学数据集训练的MFCC-CNN模型总体预测准确率最高（89%），ROC曲线下面积得分也最高（98%），证实了

所提出的声学去噪技术的有效性。

图15和图16分别展示了不同分类器的ROC曲线和混淆矩阵。在去噪数据集上训练的MFCC-CNN的ROC曲线优于其他模型，对所有预测类别均表现出更高的AUC值。此外，在去噪数据上训练的MFCC-CNN的混淆矩阵显示，其对“无缺陷”类别（91.4%）和“锁孔孔隙”类别（92.8%）具有非常高的分类准确率。尽管该模型对裂纹的预测效果不佳，但被错误分类的裂纹声音通常会被错误标记为“锁孔孔隙”，这对实际应用影响不大，因为这两类都属于缺陷声音。

在本研究中，假阳性率（即被误分类为“无缺陷”类别的实际缺陷所占比例）是一项至关重要的性能指标。将实际缺陷（如裂纹和匙孔气孔）误判为“无缺陷”会造成不利影响，因为系统会认为无需中断或修正即可继续进行工艺。因此，应将假阳性率降至最低。另一方面，将匙孔气孔误识别为裂纹的负面影响较小，因为二者都是需要修正的缺陷。此外，假阴性判定（即将“无缺陷”状态误分类为有缺陷）造成的危害也较小，因为它们不会影响零件质量，只会影响生产效率（即工艺中断时间增加）。根据图14(c)和(d)，在所有模型中，基于去噪数据集训练的MFCC-CNN模型假阳性率最低（9%），匙孔孔隙预测准确率最高（92.8%）。

此外，在LDED过程中，对于我们的特定应用而言，采用500 ms的预测窗口并达到89%

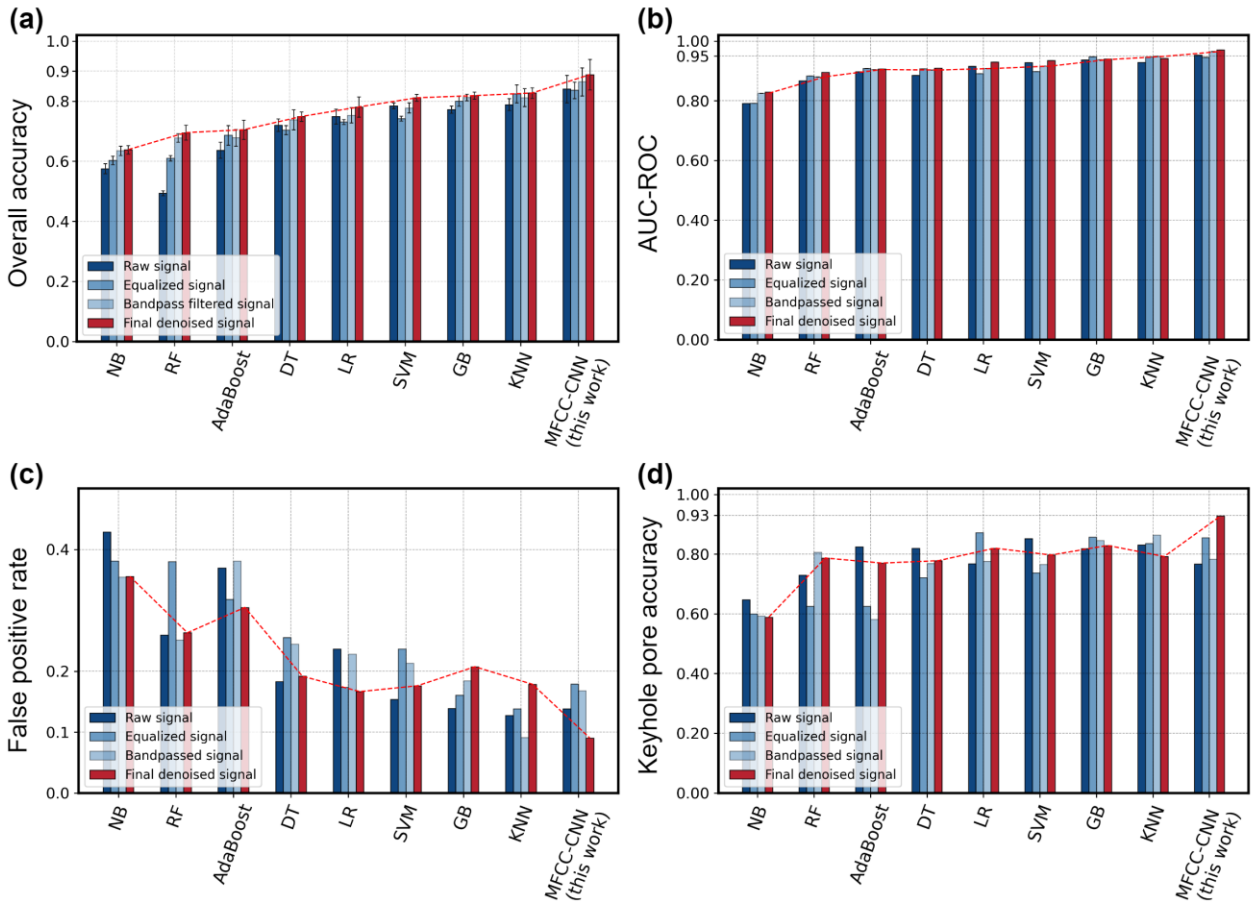

图14。LDED中基于声学的缺陷预测的性能评估和基准测试。(a) 在来自不同去噪步骤的声学信号上训练的八种传统机器学习模型和MFCC-CNN模型的总体准确率。(b) 在来自不同去噪步骤的声学信号上训练的八种机器学习模型和MFCC-CNN模型的AUC-ROC结果。(c) 假阳性率（即被错误分类为“无缺陷”类别的实际缺陷所占的百分比）。(d)匙孔孔隙预测准确率。（注：总体准确率、ROC曲线下面积得分和匙孔孔隙预测准确率的值越高，表示性能越好；假阳性率越低，表示性能越好。）

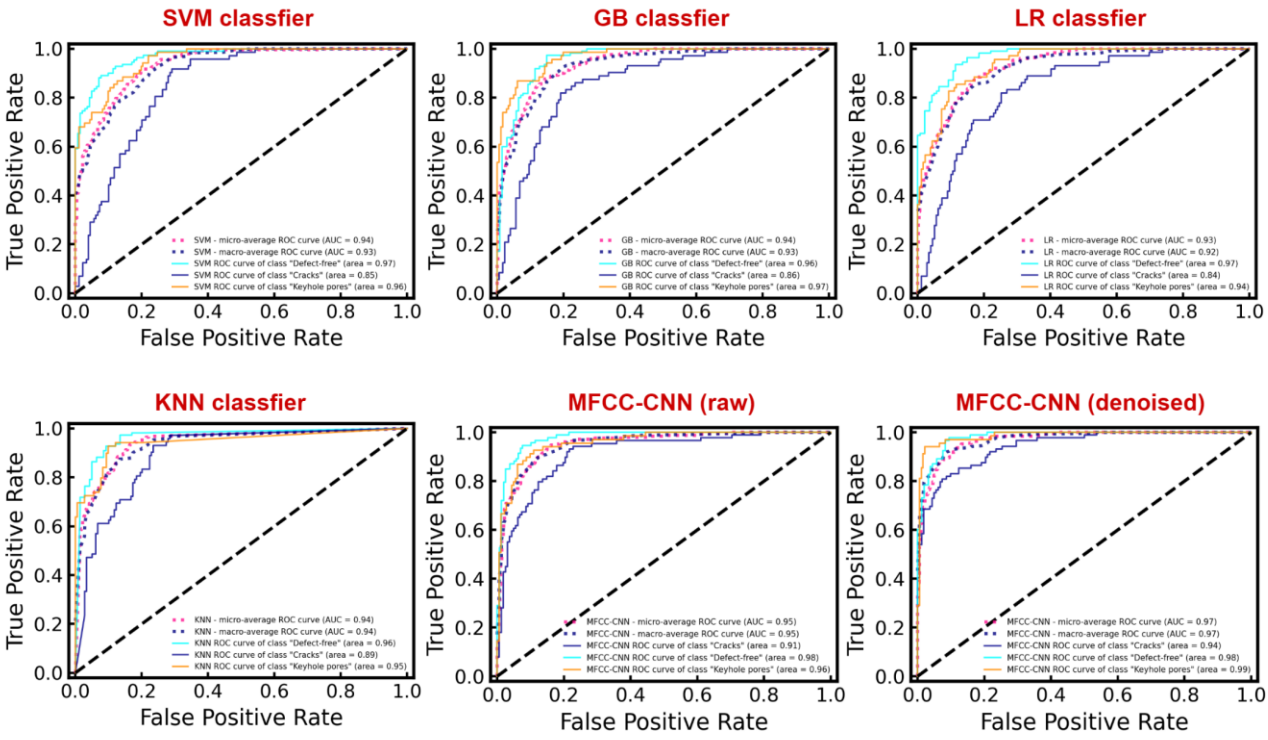

图 15。在原始声学数据集和去噪数据集上训练的“支持向量机”、“梯度提升”、“逻辑回归”、“K近邻（KNN）”和 MFCC-CNN 对 LDED 声音进行预测的受试者工作特征（ROC）曲线。SVM、GB、LR 和 KNN 的结果均使用去噪声学数据集进行训练。

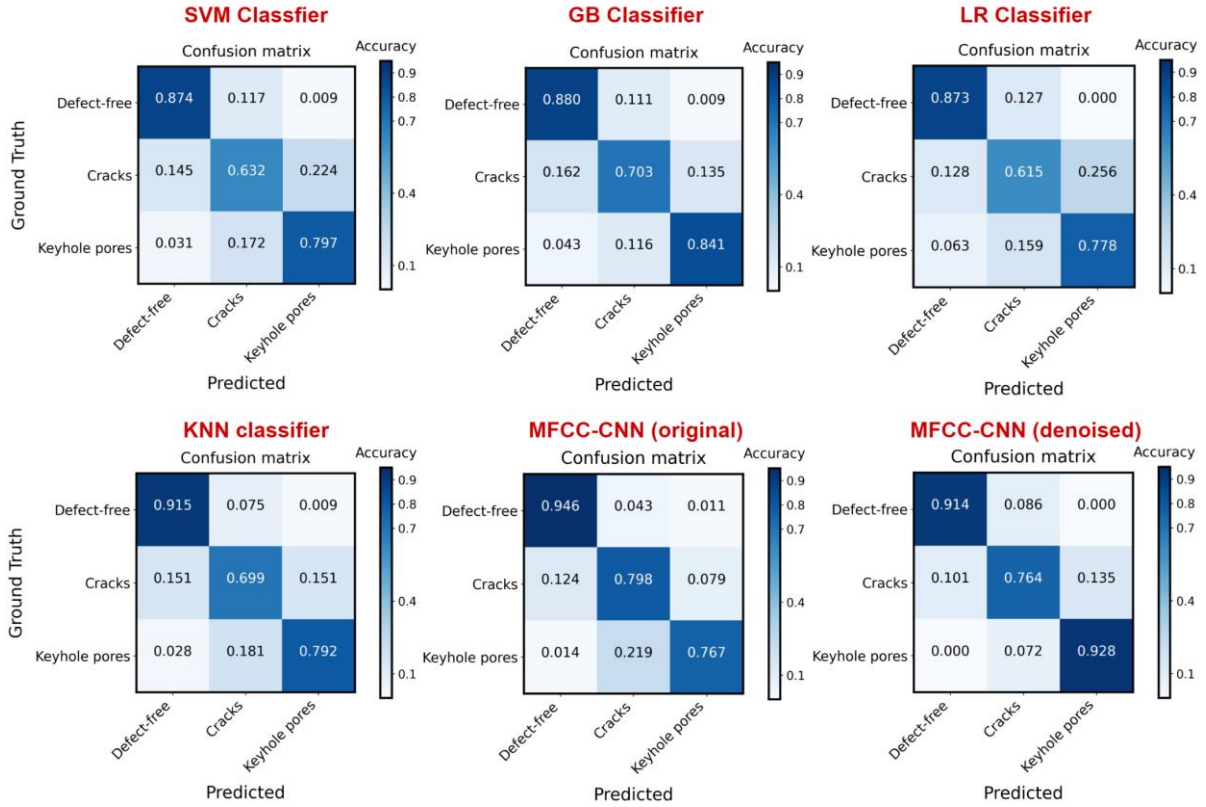

图 16。“支持向量机”、“梯度提升”、“逻辑回归”、“K近邻”和 MFCC-CNN 在原始声学数据集上训练的分类任务混淆矩阵，以及

去噪数据集。 SVM、GB、LR 和 K近邻（KNN）的结果是使用去噪后的声学数据集训练得到的 t.

5. 结论与未来工作

本文针对 LDED 过程中的原位声学缺陷检测，探讨了两个主要挑战：LDED 激光-材料相互作用声中存在噪声，以及缺乏具备原位特征提取与预测功能的自动化在线缺陷检测流程。这是首项将声学信号处理和深度学习用于 LDED 过程原位缺陷检测的研究。本研究的主要贡献和创新点总结如下：

- 一种自动化的原位声学去噪、特征提取和激光-材料相互作用声分类流程，用于预测 LDED 过程中的裂纹和匙孔气孔。
- 一种基于梅尔频率倒谱系数（梅尔频率倒谱系数）声学特征的卷积神经网络（卷积神经网络），用于对 LDED 声音进行分类，并以较高准确率（89%）预测缺陷。
- 开发了一种结合声学校正、带通滤波和HPSS算法的声学信号去噪技术，显著提高了声音分类准确率。
- 对时域（例如振幅包络、RMS能量等）、频域（谱质心、谱带宽度、频带能量比等）及时频表示（梅尔频率倒谱系数）中与无缺陷、裂纹和匙孔气孔相对应的关键声学特征进行研究。

所提出的MFCC-CNN模型在分类准确率、ROC曲线下面积得分和假阳性率方面均优于本研究中测试的所有经典机器学习算法。此外，模型评估结果表明，与原始声学信号相比，去噪声学信号能够提高声音分类模型的准确率并降低假阳性率。所提出的基于声学信号和深度学习的原位缺陷检测策略，通过利用灵活的麦克风 设置以及相较于现有传感方法更低的硬件成本，为LDED质量保证提供了一种经济高效的解决方案。然而，本研究中基于声学信号的原位缺陷检测时间尺度受到限制（500ms），显著长于LPBF工艺中所采用的方法[34]（2.5 ms）。一方面，LDED中的激光扫描速度明显低于LPBF。另一方面，由于环境噪声较大，LDED中缺陷的形成更加难以预测，因此需要足够长度的音频数据，

例如未熔合（LoF）和分层，每种缺陷都具有独特的声学特征和缺陷形成机制。此外，所提出的缺陷检测方法还[illegible] POS 实时获取机器人位置数据，并将其与预测的质量标签进行配准，即可实现这一点。从而便于识别特定位置的缺陷。确定缺陷区域后，可采用机器人加工将其去除。因此，原位缺陷检测策略为开发自适应混合加工策略奠定了基础，有助于提升零件质量并简化打印流程。

致谢

本研究由新加坡科学、技术与研究局（A*STAR）通过职业发展基金（资助编号：C210812030）资助。此外，本研究还获得新加坡3D打印中心（SC3DP）和新加坡总理公署国家研究基金会中型中心资助计划的支持。

参考文献

[1] C. Tan、F. Weng、S. Sui、Y. Chew 和 G. Bi，《航空发动机关键材料激光增材制造的进展与展望》，《国际机床与制造》，第 170 卷，文章编号 103804，2021 年 11 月，doi：10.1016/j.ijmachtools.2021.103804。[2] J. M. Wilson、C. Piya、Y. C. Shin、F. Zhao 和 K. Ramani，《采用激光直接沉积修复涡轮叶片及其能耗与环境影响分析》，《清洁生产期刊》，第 80 卷，第 170–178 页，2014 年，doi：10.1016/j.jclepro.2014.05.084。[3] A. Saboori、A. Aversa、G. Marchese、S. Biamino、M. Lombardi 和 P. Fino，《基于定向能量沉积的增材制造在修复中的应用》，《应用科学》，第 9 卷，第 16 期，文章编号 16，2019 年 1 月，doi：10.3390/app9163316。[4] B. T. Gibson 等，《使用 8 轴工业机器人和旋转运动进行 Ti-6Al-4V 五轴激光定向能量沉积的控制与工艺规划策略》，《增材制造》，文章编号 103048，2022 年 7 月，doi：10.1016/j.addma.2022.103048。[5] M. Schmidt 等，《工业界与学术界中的激光增材制造》，《*CIRP* 年鉴》，第 66 卷，第 2 期，第 561–583 页，2017 年 1 月，doi：10.1016/j.cirp.2017.05.011。[6] Z. Y. Chua、I. H. Ahn 和 S. K. Moon，《金属增材制造中的工艺监控与检测系统：现状与应用》，《精密工程与制造—绿色技术国际期刊》，第 4 卷，第 2 期，第 235–245 页，2017 年 4 月，doi：10.1007/s40684-017-0029-7。[7] Z. Tang 等，《激光定向能量沉积 AISI 316L 钢过程中熔池同轴视觉特征研究》，《材料加工技术期刊》，第 290 卷，文章编号 116996，2021 年 4 月，doi：10.1016/j.jmatprotec.2020.116996。[8] L. Chen、X. Yao、P. Xu、S. K. Moon 和 G. Bi，《通过原位点云处理进行增材制造表面监测》，载于《*2020*年第六届国际控制、自动化与机器人会议（*ICCAR*）》，2020 年 4 月，第 196–201 页。doi：10.1109/ICCAR49639.2020.9108092。[9] L. Chen、X. Yao、N. P. H. Ng 和 S. K. Moon，《利用红外热成像对激光辅助增材制造进行原位熔池监测》，载于《*2022 IEEE* 工业工程与工程管理国际会议（*IEEM*）》，2022 年 12 月，第 1478–1482 页。doi：10.1109/IEEM55944.2022.9989715。

[10] C. Gonzalez-Val、A. Pallas、V. Panadeiro 和 A. Rodriguez，《一种用于激光制造质量监控的卷积方法》，J Intell Manuf，第 31 卷，第 3 期，第 789–795 页，2020 年 3 月，doi：10.1007/s10845-019- 01495-8。[11] M. Grasso、A. G. Demir、B. Previtali 和 B. M. Colosimo，《通过对工艺羽流进行红外成像，原位监控锌粉的选择性激光熔化》，Robotics and Computer-Integrated Manufacturing，第 49 卷，第 229–239 页，2018 年 2 月，doi：10.1016/j.rcim.2017.07.001。[12] Z. Smoqi 等，《定向能量沉积中熔池温度的闭环控制》，Materials & Design，第 215 卷，文章编号 110508，2022 年 3 月，doi：10.1016/j.matdes.2022.110508。[13] H. Yeung、F. H. Kim、M. A. Donmez 和 J. Neira，《镍合金 625 激光粉末床熔融增材制造中匙孔气孔的减少》，International Journal of Machine Tools and Manufacture，第 183 卷，文章编号 103957，2022 年 12 月，doi：10.1016/j.ijmachtools.2022.103957。[14] B. T. Gibson 等，《通过多种闭环模式控制 Ti-6Al-4V 激光送丝定向能量沉积中的熔池尺寸》，Additive Manufacturing，第 32 卷，文章编号 100993，2020 年 3 月，doi：10.1016/j.addma.2019.100993。[15] L. Chen、X. Yao、Y. Chew、F. Weng、S. K. Moon 和 G. Bi，《基于数据驱动的激光增材制造自适应控制及自动控制器调谐》，Applied Sciences，第 10 卷，第 22 期，文章编号 22，2020 年 1 月，doi：10.3390/app10227967。[16] W. Li 等，《基于深度学习的电弧增材制造在线金属表面缺陷检测方法》，Robotics and Computer-Integrated Manufacturing，第 80 卷，文章编号 102470，2023 年 4 月，doi：10.1016/j.rcim.2022.102470。[17] L. Lu、J. Hou、S. Yuan、X. Yao、Y. Li 和 J. Zhu，《深度学习辅助的连续纤维增强聚合物复合材料增材制造实时缺陷检测与闭环调整》，Robotics and Computer-Integrated Manufacturing，第 79 卷，文章编号 102431，2023 年 2 月，doi：10.1016/j.rcim.2022.102431。[18] H. Z. Imam、H. Al-Musaibeli、Y. Zheng、P. Martinez 和 R. Ahmad，《用于自主机器人激光熔覆修复过程的基于视觉的空间损伤定位方法》，Robotics and Co mputer-Integrated Manufacturing，第 80 卷，文章编号 102452，2023 年 4 月，doi：10.1016/j.rcim.2022.102452。[19] Z. Li、Z. Zhang、J. Shi 和 D. Wu，《利用机器学习预测挤出式增材制造的表面粗糙度》，Robotics and Computer-Integrated Manufacturing，第 57 卷，第 488–495 页，2019 年 6 月，doi：10.1016/j.rcim.2019.01.004。[20] J. Xiong、Y. Pi 和 H. Chen，《利用被动视觉传感检测机器人 GTA 增材制造中的沉积高度并提取特征点》，Robotics and Computer-Integrated Manufacturing，第 59 卷，第 326–334 页，2019 年 10 月，doi：10.1016/j.rcim.2019.05.006。[21] C. Xia、Z. Pan、J. Polden、H. Li、Y. Xu 和 S. Chen，《利用机器学习对电弧增材制造中的表面粗糙度进行建模与预测》，J Intell Manuf，第 1–16 页，2021 年 1 月，doi：10.1007/s10845- 020-01725-4。[22] C. Liu 等，《基于深度学习的方法实现增材制造逐层表面形貌在线测量》，J Intell Manuf，第 1–17 页，2022 年 4 月，doi：10.1007/s10845-022-01933-0。[23] M. Perani、S. Baraldo、M. Decker、A. Vandone、A. Valente 和 B. Paoli，《基于在线机器视觉和深度神经网络的激光金属沉积沉积道几何预测》，Robotics and Computer- Integrated Manufacturing，第 79 卷，文章编号 102445，2023 年 2 月，doi：10.1016/j.rcim.2022.102445。[24] L. Chen、X. Yao、P. Xu、S. K. Moon 和 G. Bi，《通过原位点云处理与机器学习快速识别增材制造表面缺陷》，Virtual and Physical Prototyping，第 16 卷，第 1 期，第 50–67 页，2020 年 10 月，doi：10.1080/17452759.2020.1832695。[25] P. Xu 等，《利用激光线扫描实现激光辅助增材制造的加工中自适应尺寸校正策略》，Journal of Materials Processing Technology，第 303 卷，文章编号 117544，2022 年，doi：10.1016/j.j matprotec.2022.117544。[26] M. Li、Z. Du、X. Ma、W. Dong 和 Y. Gao，《一种基于三维重建的线激光传感器机器人手眼标定方法》，Robotics and Computer-Integrated Manufacturing，第 71 卷，文章编号 102136，2021 年 10 月，doi：10.1016/j.rcim.2021.102136。[27] Y. S. Touloukian 和 D. P. DeWitt，《物质的热物理性质——TPRC 数据系列，第 7 卷：热辐射性质——金属元素与合金》，THERMOPHYSICAL AND ELECTRONIC PROPERTIES INFORMATION ANALYSIS CENTER LAFAYETTE IN，1970 年 1 月。访问日期：2022 年 5 月 26 日。 [ ] 951941 在线。可访问：
[28]
https://apps.dtic.mil/sti/citations/ADA J. C. Heigel 和 B. M. Lane，《商用激光粉末床熔融工艺中单次扫描沉积道的熔池长度测量》，Journal of Manufacturing Science and Engineering，第 140 卷，第 5 期，2018 年 3 月，doi：10.1115/1.4037571。[29] V. Pandiyan、R. Drissi-Daoudi、S. Shevchik、G. Masinelli、R. Logé 和 K. Wasmer，《时间、

激光粉末床熔融过程中声发射的频域和时频域特征，”Procedia CIRP，第94卷，第392–397页，2020年，doi: 10.1016/j.procir.2020.09.152。[30] K. Asif、L. Zhang、S. Derrible、J. E. Indacochea、D. Ozevin和B. Ziebart，“利用空气耦合声发射和焊接输入预测焊接质量的机器学习模型”，J Intell Manuf，第1–15页，2020年10月，doi: 10.1007/s10845-020-01667-x。[31] S. Yaacoubi、F. Dahmene、M. El Mountassir和A. E. Bouzenad，“一种基于新型声发射算法的点焊裂纹检测方法，用于在线监测：案例研究”，Int J Adv Manuf Technol，第117卷，第5期，第1807–1824页，2021年11月，doi: 10.1007/s00170-021-07848-z。[32] K. Ito、M. Kusano、M. Demura和M. Watanabe，“通过无线声发射测量检测并定位选择性激光熔化过程中的微缺陷”，Additive Manufacturing，第40卷，文章编号101915，2021年4月，doi: 10.1016/j.addma.2021.101915。[33] K. Gutknecht、M. Cloots、R. Sommerhuber和K. Wegener，“激光粉末床熔融监测中声学、测温和热成像方法的相互比较”，Materials & Design，第210卷，文章编号110036，2021年11月，doi: 10.1016/j.matdes.2021.110036。[34] J. R. Tempelman等人，“利用声学过程监测测量检测激光粉末床熔融中的匙孔孔隙形成”，Additive Manufacturing，第55卷，文章编号102735，2022年3月，doi: 10.1016/j.addma.2022.102735。[35] V. Pandiyan等人，“基于深度学习的激光粉末床熔融过程监测：利用异构传感和原位X射线成像指导，适用于可变时间尺度”，Additive Manufacturing，第58卷，文章编号103007，2022年10月，doi: 10.1016/j.addma.2022.103007。[36] S. A. Shevchik、C. Kenel、C. Leinenbach和K. Wasmer，“利用谱卷积神经网络进行增材制造原位质量监测的声发射方法”，Additive Manufacturing，第21卷，第598–604页，2018年5月，doi: 10.1016/j.addma.2017.11.012。[37] R. Drissi-Daoudi等人，“结合机器学习，利用空气传播的声发射区分材料和激光粉末床熔融加工工况”，Virtual and Physical Prototyping，第0卷，第0期，第1–24页，2022年，doi: 10.1080/17452759.2022.2028380。[38] V. Pandiyan等人，“基于声发射的激光粉末床熔融过程半监督监测”，Virtual and Physical Prototyping，第0卷，第0期，第1–17页，2021年8月，doi: 10.1080/17452759.2021.1966166。[39] V. Pandiyan等人，“金属激光粉末床熔融过程中跨材料的增材制造机制深度迁移学习”，Journal of Materials Processing Technology，第117531页，2022年，doi: 10.1016/j.jmatprotec.2022.117531。[40] M. S. Hossain和H. Taheri，“通过结合小波和卷积神经网络（CNN）的声学技术对金属增材制造进行原位过程监测”，Int J Adv Manuf Technol，第1–16页，2021年7月，doi: 10.1007/s00170-021-07721-z。[41] C. Prieto等人，“利用光学麦克风对激光金属沉积应用中的裂纹进行原位过程监测与检测”，发表于第11届CIRP光子技术会议，2020年，第4页。[42] H. Gaja和F. Liou，“利用声发射传感器监测激光金属沉积中的缺陷”，Int J Adv Manuf Technol，第90卷，第1期，第561–574页，2017年4月，doi: 10.1007/s00170-016-9366-x。[43] T. Hauser、R. T. Reisch、T. Kamps、A. F. H. Kaplan和J. Volpp，“定向能量沉积过程中的声发射”，Int J Adv Manuf Technol，第119卷，第5期，第3517–3532页，2022年3月，doi: 10.1007/s00170-021-08598-8。[44] A. J. Jerri，“香农采样定理——其各种扩展与应用：教程综述”，Proceedings of the IEEE，第65卷，第11期，第1565–1596页，1977年，doi: 10.1109/PROC.1977.10771。[45] S. J. Wolff等人，“激光粉末吹送定向能量沉积增材制造中孔隙形成机制及动态过程的原位X射线成像”，International Journal of Machine Tools and Manufacture，第166卷，文章编号103743，2021年7月，doi: 10.1016/j.ijmachtools.2021.103743。[46] P. J. DePond等人，“通过检测热诱导电子发射解析增材制造过程中的激光-金属相互作用动力学”，Commun Mater，第1卷，第1期，第1–10页，2020年11月，doi: 10.1038/s43246- 020-00094-y。[47] N. T. Aboulkhair、N. M. Everitt、I. Ashcroft和C. Tuck，“降低选择性激光熔化加工的AlSi10Mg零件中的孔隙率”，Additive Manufacturing，第1–4卷，第77–86页，2014年10月，doi: 10.1016/j.addma.2014.08.001。[48] H. L. Wei等人，“金属构件增材制造的机理模型”，Progress in Materials Science，第116卷，文章编号100703，2021年2月，doi: 10.1016/j.pmatsci.2020.100703。[49] D. Svetlizky等人，“定向能量沉积（DED）增材制造：物理特性、缺陷、挑战与应用”，Materials Today，2021年6月，doi: 10.1016/j.mattod.2021.03.020。

[50] S. Wang等人，“孔隙缺陷在金属3D打印中的作用：形成机制、对性能的影响及缓解策略”，Materials Today，2022年9月，doi: 10.1016/j.mattod.2022.08.014。[51] A. García-Díaz等人，“OpenLMD：用于大型金属零件激光增材制造的开源中间件与工具包”，Robotics and Computer-Integrated Manufacturing，第53卷，第153–161页，2018年10月，doi: 10.1016/j.rcim.2018.04.006。[52] M. Quigley等人，“ROS：开源机器人操作系统”，载于ICRA开源软件研讨会，2009年，第3卷，第3.2期，第5页。[53] E. B. Sanjuan、I. A. Cardiel、J. A. Cerrada和C. Cerrada，“消息队列遥测传输（MQTT）安全性：一种密码智能卡方案”，IEEE Access，第8卷，第115051–115062页，2020年，doi: 10.1109/ACCESS.2020.3003998。[54] G. Pardo-Castellote，“OMG数据分发服务：架构概述”，载于第23届国际分布式计算系统会议研讨会论文集，2003年5月，第200–206页。doi: 10.1109/ICDCSW.2003.1203555。[55] “Apache Kafka”，Apache Kafka。https://kafka.apache.org/（访问于2023年2月10日）。[56] D. FitzGerald，“使用中值滤波进行谐波/打击乐分离”，发表于第13届国际数字音频效果会议（DAFX10），奥地利格拉茨，2010年。[57] E. Manilow、P. Seetharaman和B. Pardo，“西北大学音源分离库”，载于第19届国际音乐信息检索学会会议论文集（ISMIR 2018），法国巴黎，2018年，第297–305页。[58] B. McFee等人，“librosa：Python中的音频与音乐信号分析”，载于第14届Python科学会议论文集，美国得克萨斯州奥斯汀，2015年，第18–25页。doi: 10.25080/Majora-7b98e3ed-003。[59] D. Faconti，“PlotJuggler 3.5。”2022年7月17日。访问日期：2022年7月17日。 [在线]。可访问：https://github.com/facontidavide/PlotJuggler [60] K. R. Rao、D. N. Kim和J. J. Hwang，“二维离散傅里叶变换”，载于《快速傅里叶变换——算法与应用》，荷兰多德雷赫特：Springer Netherlands，2010年，第127–184页。doi: 10.1007/978-1-4020-6629-0 5。
[61] L. Chen、X. Yao和S. K. Moon，“利用深度学习辅助信号降噪对直接能量沉积过程进行原位声学监测”，Materials Today: Proceedings，2022年9月，doi: 10.1016/j.matpr.2022.09.008。[62] V. Välimäki和J. D. Reiss，“音频均衡化面面观：解决方案与前沿”，Applied Sciences，第6卷，第5期，文章第5号，2016年5月，doi: 10.3390/app6050129。[63] J. Hauke和T. Kossowski，“同一数据集上皮尔逊与斯皮尔曼相关系数值的比较”，Quaestiones Geographicae，第30卷，第2期，第87–93页，2011年6月，doi: 10.2478/v10117- 011-0021-1。[64] G. Sharma、K. Umapathy和S. Krishnan，“音频信号特征提取方法的发展趋势”，Applied Acoustics，第158卷，文章编号107020，2020年1月，doi: 10.1016/j.apacoust.2019.107020。[65] F. Gouyon、F. Pachet和O. Delerue，“过零率在打击乐声音分类应用中的运用”，载于COST G-6数字音频效果会议论文集（DAFX-00），2000年，第6页。[66] Y. Yuan、R. Wayland和Y. Oh，“声学振幅包络的视觉类比有助于在噪声环境中感知语音”，The Journal of the Acoustical Society of America，第147卷，第3期，第EL246–EL251页，2020年3月，doi: 10.1121/10.0000737。[67] S. Yildirim等人，“语音情感表达的声学研究”，载于Interspeech 2004，2004年10月，第2193–2196页。doi: 10.21437/Interspeech.2004-242。[68] A. I. Al-Shoshan，“语音与音乐分类及分离：综述”，Journal of King Saud University - Engineering Sciences，第19卷，第1期，第95–132页，2006年1月，doi: 10.1016/S1018-3639(18)30850- X。[69] G. Tzanetakis和P. Cook，“音频信号的音乐流派分类”，IEEE Transactions on Speech and Audio Processing，第10卷，第5期，第293–302页，2002年7月，doi: 10.1109/TSA.2002.800560。[70] A. Klapuri和M. Davy编，《音乐转录的信号处理方法》。纽约：Springer，2006年。[71] E. Scheirer和M. Slaney，“稳健多特征语音/音乐判别器的构建与评估”，载于1997年IEEE国际声学、语音与信号处理会议，1997年4月，第2卷，第1331–1334页，第2卷。doi: 10.1109/ICASSP.1997.596192。[72] S. Dubnov，“非高斯线性过程谱平坦度度量的推广”，IEEE Signal Processing Letters，第11卷，第8期，第698–701页，2004年，doi: 10.1109/LSP.2004.831663。[73] D.-N. Jiang、L. Lu、H.-J. Zhang、J.-H. Tao和L.-H. Cai，“基于谱对比特征的音乐类型分类”，载于IEEE国际多媒体与博览会会议论文集，2002年，第1卷，第113–116页，第1卷。doi:

10.1109/ICME.2002.1035731.[74] P.Geoffroy，“CUIDADO 项目中用于声音描述（相似性和分类）的大型音频特征集。”[在线]。可用：http://recherche.ircam.fr/anasyn/peeters/ARTICLES/Peeters_2003_cuidadoaudiofeatures.pdf[75] H. Misra、S. Ikbal、H.Bourlard 和H. Hermansky，“基于谱熵的稳健 ASR 特征”，载于*2004* 年*IEEE*国际声学、语音与信号处理会议，2004 年，第 1 卷，第I–193 页。doi：10.1109/ICASSP.2004.1325955。[76] S.Dixon，“重新审视起始点检测”，载于第九届国际数字音频效果会议论文集，加拿大蒙特利尔，2006 年，第 133–137 页。[77] E. Sejdić、I.Djurović和 J. Jiang，“使用能量集中度的时频特征表示：近期进展综述”，数字信号处理，第 19 卷，第 1期，第153–183 页，2009年 1月，doi：10.1016/j.dsp.2007.12.004。[78] J.Allen，“通过离散傅里叶变换进行短时谱分析、合成与修改”，*IEEE*声学、语音与信号处理汇刊，第 25 卷，第 3期，第235–238 页，1977 年 6月，doi：10.1109/TASSP.1977.1162950。[79] D.Zhang，“小波变换”，载于图像数据挖掘基础：分析、特征、分类与检索，D. Zhang 编。Cham：Springer InternationalPublishing，2019 年，第 35–44页。doi：10.1007/978-3- 030-17989-23。[80] A. M. Noll，“用于人声音高检测的短时谱与‘倒谱’技术”，美国声学学会杂志，第 36 卷，第 2期，第296–302 页，1964 年2 月，doi：10.1121/1.1918949。[81] L. Muda、M.Begam 和I. Elamvazuthi，“使用梅尔频率倒谱系数（MFCC）和动态时间规整（DTW）技术的语音识别算法。”arXiv，2010 年3 月 22日。doi：10.48550/arXiv.1003.4083。[82] M. Abadi 等，“{TensorFlow}：用于{Large-Scale}机器学习的系统”，发表于第 12 届 USENIX 操作系统设计与实现研讨会（OSDI16），2016 年，第265–283页。访问日期：2022 年 7 月 29 日。 [在线]。可用：https://www.usenix.org/conference/osdi16/technical- sessions/presentation/abadi[83] V.Nair 和G. E.Hinton，“修正线性单元改进受限玻尔兹曼机”，第 8 页。[84] E. Jang、S. Gu 和B.Poole，“使用 Gumbel-Softmax 的类别重参数化。”arXiv，2017 年8 月 5日。doi：10.48550/arXiv.1611.01144。[85] D. P.Kingma 和 J. Ba，“Adam：一种随机优化方法”，*arXiv:1412*。*6980 [cs]*，2017 年 1 月，访问日期：12 月 22, 2020 [ ] 1412 6980 。在线。可用：[86] http://arxiv.org/abs/。Z. Zhang和M. Sabuncu，“带噪声标签训练深度神经网络的广义交叉熵损失”，载于神经信息处理系统进展，2018年，第 31卷。访问日期：2022 年 7 月 29 日。[在线]。可用：https://proceedings.neurips.cc/paper/2018/hash/f2925f97bc13ad2852a7a551802feea0-Abstract.html[87] F. Pedregosa 等，“Scikit-learn：Python中的机器学习”，*PYTHON* 中的机器学习，第 6 页。

附录 A. 声学特征相关矩阵

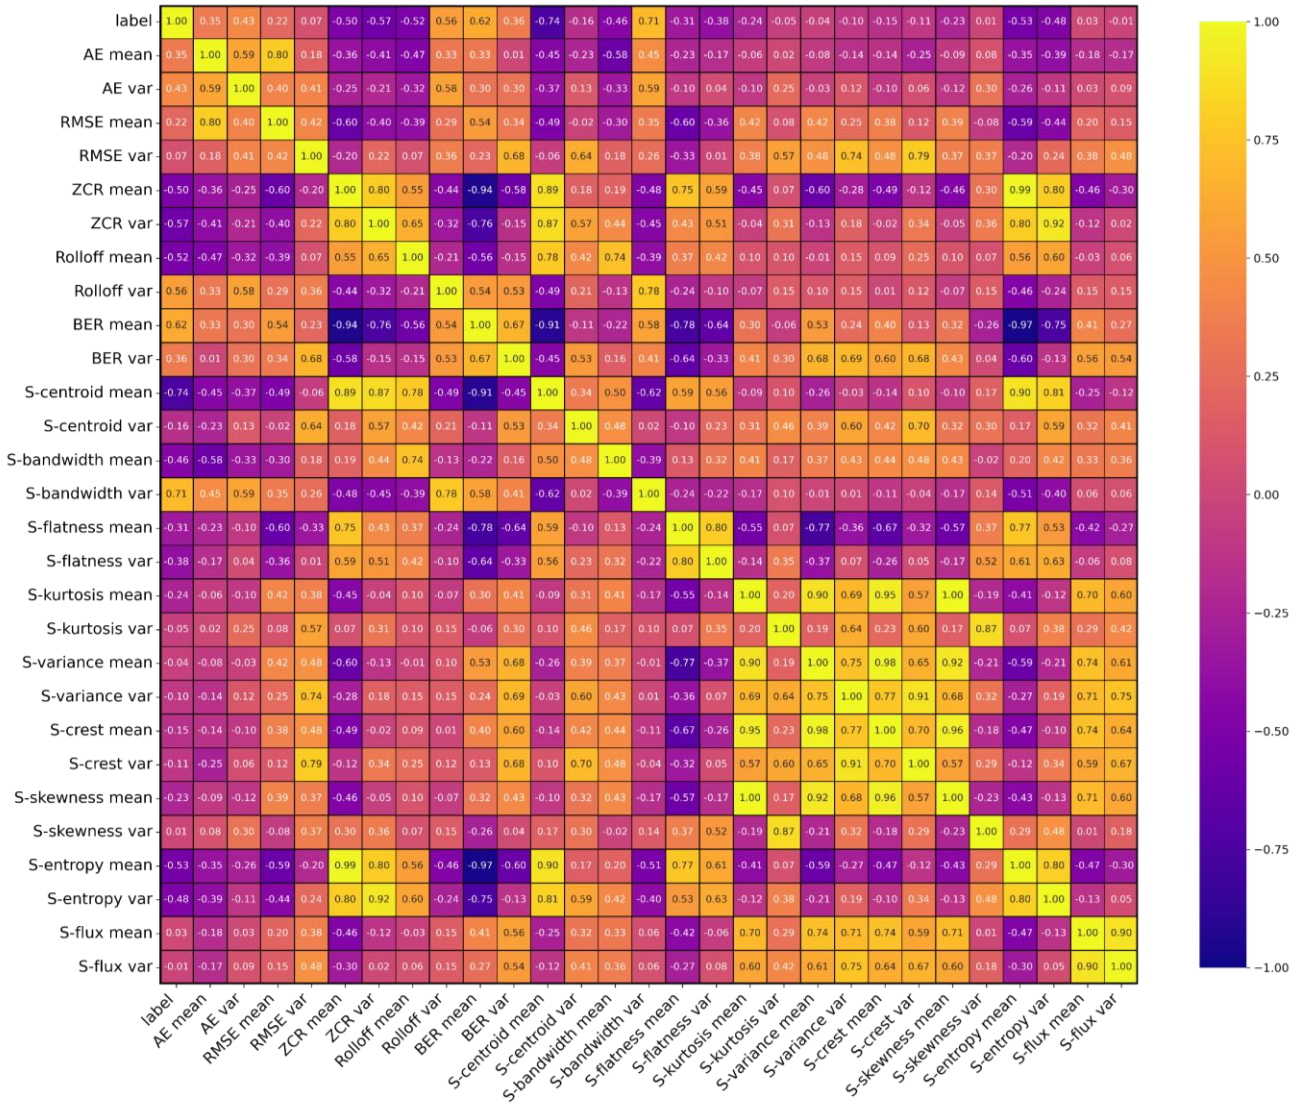

图 A1。显示数值声学特征（时域和频谱描述符）与输出类别（即 0 – 无缺陷，1 - 裂纹，2 - 匙孔气孔）之间相关性的热图。