

# 实时分布式光纤振动识别通过极端轻量级模型和跨域蒸馏

Zhongyao Luo,<sup>1</sup> Hao Wu,<sup>1,\*</sup> Zhao Ge,<sup>1</sup> and Ming Tang<sup>1</sup>

<sup>1</sup>Wuhan National Laboratory for Opto-electronics, Next Generation Internet Access National Engineering Laboratory, and Hubei Optics Valley Laboratory, School of Optical and Electronic Information, Huazhong University of Science and Technology, Wuhan, China

\*wuhaoboom@hust.edu.cn

**Abstract:** 分布式光纤振动传感 (DVS) 系统为大规模监控和入侵事件识别提供了有前景的解决方案。然而,其实用部署仍受两大挑战阻碍:(1) 动态条件下识别精度下降;(2) 处理大量感应数据时实时处理的计算瓶颈。本文提出了一种新的解决方案,通过 FPGA 加速的极端轻量级模型及新提出的知识蒸馏框架来应对这些挑战。所提三层深度可分离卷积网络仅包含 4141 个参数,是目前该领域最为紧凑的架构,并实现了每覆盖 12.5 米光纤长度在 0.256 秒内的最大处理速度为 0.019 毫秒。此性能对应于处理可达 168.68 公里传感光纤的实时处理能力。为了提高变化环境下的一般化能力,本文使用由物理先验引导的新跨域蒸馏框架将频域见解嵌入到时域模型中。这允许在不增加复杂性的情况下进行时间-频率表示学习,并在未见环境条件下将识别精度从 51.93% 提升至 95.72%。所提方法提供了包括结合可解释信号处理技术和深度学习的框架以及 DVS 系统实时处理和边缘计算参考架构,以及更广泛的分布式光纤传感 (DOFS) 领域的重要进展。它缓解了感知范围与实时能力之间的权衡,弥合了理论能力和实际部署需求之间的差距。此外,本工作揭示了一种构建 DOFS 技术中更高效、稳健且可解释的人工智能系统的新的方向。

© 2025 Optica Publishing Group

## 1. 介绍

光纤传感 (OFS) 在各个领域中发挥着越来越重要的作用,提供了独特的优点,包括抗电磁干扰、高灵敏度、坚固性和灵活性 [1]。分布式光纤传感器 (DOFS) 通过分析背散射图案将标准光纤转变为连续的传感介质,从而扩展了这些优势,有效地创建了千米级的传感器阵列 [2]。在 DOFS 变体中,基于相位敏感光时域反射计 (Phi-OTDR) 的分布式振动传感 (DVS) 因其在大面积监测应用中的出色空间分辨率和成本效益而特别受到关注。这使其可以应用于包括土木工程 [3]、管道监测 [4–6]、铁路监测 [7,8]、结构健康监测 [9] 和交通监测 [10] 等多个领域。

现代 DVS 系统利用窄线宽激光脉冲在光纤中传播时诱导的瑞利背向散射光。外部振动改变光纤的光学参数,产生可检测到的背向散射信号相位和强度变化。分析这些变化模式能够在多公里范围内同时实现振动定位和特征识别。然而,实际应用

面临基本挑战,包括由于光纤可能遇到的各种环境而导致的复杂环境噪声、介质异质性和耦合效应导致的信号模式变异,以及从捕获的传感数据中产生的大量数据量。

这些技术限制由于时间敏感应用(如管道监测和地震检测 [11])中的严格操作要求而变得更加复杂。现场部署无法确保提供丰富的计算资源和电源供应。这需要 DVS 算法同时满足关键标准,包括高维数据流的实时处理、对非平稳信号特性的鲁棒性以及资源受限环境中的可部署性。

传统的信号处理方法使用手工设计的特征提取器,需要大量的领域专业知识来进行特定应用的校准。虽然深度学习方法实现了自动特征提取并提高了适应性,但其高计算复杂度和 DVS 应用程序中的大量数据阻碍了 DVS 系统的实时运行。现有的缓解策略存在根本性的权衡:数据降采样技术 [12, 13] 通过手工设计的预处理牺牲信号保真度,而压缩感知方法 [14] 仅实现有限的压缩比率,并且吞吐量改进较小。为了解决这些问题,知识蒸馏作为一种有前景的策略出现,用于部署计算需求减少的轻量级神经网络 [15]。然而,现有的实现仍然难以满足大规模、实时系统的需要,尤其是在超过 100 公里的距离下。此外,传统的蒸馏框架通常作为黑盒过程操作并且缺乏可解释性。另外,这些方法往往依赖于高容量的教师模型,导致训练成本和复杂度增加。

为解决这些限制,我们的解决方案结合了三个关键要素:一种采用深度可分离卷积的轻量级卷积神经网络(CNN)架构、基于 FPGA 硬件加速实现实时推理以及一种新的跨域知识蒸馏框架,该框架融合了物理先验。我们开发了一种三层深度可分离 CNN,仅有 4141 个可训练参数,这也是目前报道的用于 DVS 应用中最紧凑的架构。部署在 FPGA 硬件上,系统在一个高端(Xilinx ZCU15EG)平台上实现了 0.256 秒内覆盖 12.5 米光纤长度的空间-时间样本的创纪录低推理延迟,为 0.019 毫秒,在一个低端(Xilinx XC7A35T)平台上则为 0.031 毫秒,使实时监测传感光纤分别可达 168.68 公里和 103.08 公里。为了在变化的环境条件下增强泛化能力,我们引入了一个跨域蒸馏框架,系统性地将频率域见解转移到时间域操作模型中。这种方法可以在不增加模型复杂度的情况下实现联合时频特征学习。通过结合领域知识与数据驱动训练,它提高了未见测试数据上的识别准确率从 51.93%到 95.72%,在鲁棒性和可解释性方面都取得了显著提升。所提出的架构不仅实现了实时、系统原生的吞吐量,还引入了一种嵌入物理理解到深度学习模型中的原则方法。通过建立卷积操作与谱分解之间的直接对应关系,我们的方法为特征学习提供了可解释的基础,同时保持了卓越的计算效率。

我们的贡献总结如下:

- 我们提出了一种包含 4141 个参数的深度可分离卷积神经网络,代表了迄今为止报道的最紧凑的 DVS 模型。
- 我们引入了一种基于先验物理知识的跨域蒸馏新技术,以解决轻量级模型的泛化局限性,并且也使得可以直接使用领域特定的知识。

- 我们使用实际数据集和硬件对所提出的方法和模型进行了全面评估，展示了该系统在理论最大负载下实现实时处理的能力。

## 2. 方法

### 2.1. 架构设计

为了设计一个适合实时部署的 DVS 系统，我们专注于优化模型架构以提高效率和适应性。现有工作 [15] 已经证明，在统计上与训练数据相似的环境中，浅层 CNN 可以实现强大的性能，尽管在不同环境下的泛化能力有限。在此基础上，本文介绍了一种改进的模型架构，进一步减少了复杂度并提高了整体效率。具体来说，我们设计了一个极其紧凑的网络，仅有三个卷积层，每个层都经过精心配置以平衡表示能力和计算成本。为了进一步减少模型大小和算术复杂性，我们采用了深度可分离卷积技术，这是一种比传统卷积 [16] 更参数高效的替代方案。它将标准卷积过程分解为两个步骤：通道级过滤（深度卷积）和特征组合（逐点卷积）。深度卷积对每个输入通道应用单独的滤波器，这意味着每个滤波器仅操作一个通道，与结合多个通道的标准卷积不同。逐点卷积使用  $1 \times 1$  滤波器来组合跨不同通道的特征。

$$O(K^2 \cdot C_{in} \cdot C_{out}) \rightarrow O(K^2 \cdot C_{in} + C_{in} \cdot C_{out}) \quad (1)$$




图 1. 卷积操作的示意图：(a) 标准卷积，(b) 深度可分离卷积。

这一过程极大地减少了所需的计算量，如公式 1 所示，同时保持了模型提取重要特征的能力。标准卷积的过程在图 1(a) 中进行了说明，而深度可分离卷积的过程则显示在图 1(b) 中。很明显，深度可分离卷积所涉及的卷积核数量明显少于标准卷积。因此，深度可分离卷积显著减少了所需的权重和算术运算的数量，从而大幅降低了对计算资源和存储空间的需求。

## 2.2. 跨域蒸馏

为了解决轻量级架构在噪声振动环境中的泛化问题，我们提出了一种基于物理引导的模内蒸馏框架，该框架集成了多域特征学习。

该框架通过战略性地将特征学习约束到物理上有意义的信号域，以寻求更高效和可泛化的特征。

与通过纯数据驱动参数隐式加权特征的传统基于注意力的方法 [9, 17, 18] 相比，该框架通过直接将学习到的特征与训练期间研究的选定域联系起来，提供了固有的可解释性。

该框架也从跨模态蒸馏技术 [19, 20] 根本上不同，因为它完全在互补信号表示的振动模态内运行。

这种模内策略消除了对多种类型传感器的依赖。

另一个关键优势在于其无教师设计，它用分析域参考取代了传统的具有高容量的教师模型。

与标准蒸馏方法相比，这种创新大大降低了计算开销，因为不需要训练或推理教师网络。




图 2. 跨域蒸馏的示意图

本文中，我们采用了一种简单的基于特征的蒸馏方法 [21]，利用频域进行知识迁移。传统的信号处理倾向于借助傅里叶分析从非平稳的时间振动信号中提取平稳的频谱特征。受这一物理洞察启发，我们的方法将频率域的知识迁移到时域模型中，建立了时间卷积操作与频谱分解过程之间的直接对应关系，从而结合了经典信号处理和数据驱动学习的优势。如图 2 所示，我们通过频谱信息改进了时序学习过程，建立了一个双域学习范式。蒸馏过程中采用约束优化来确保在时间特征学习中具备频谱意识。令  $I_t \in \mathbb{R}^{TS}$  表示具有  $T$  个时间步和  $S$  个空间点的时间输入。我们使用傅里叶变换算子  $\mathcal{F}$  制定蒸馏目标。

$$\mathcal{L} = \underbrace{\alpha \|\Phi(I_t) - \mathcal{F}(I_t)\|_2^2}_{\text{Spectral matching}} + \underbrace{(1 - \alpha) \mathcal{L}_{\text{CE}}(y, f(I_t))}_{\text{Classification}} \quad (2)$$

其中,  $\Phi(I_t)$  表示中间卷积特征,  $\mathcal{F}(I_t)$  表示离散傅里叶变换 (DFT) 系数,  $f(I_t)$  是分类输出, 而  $\alpha \in [0, 1]$  作为通过网格搜索优化的域加权系数。这种双重目标公式鼓励网络学习不仅保留关键频谱特性, 还能增强区分能力以实现准确分类的特征表示。通过平衡这些目标, 模型实现了更加稳健且具有信息量的嵌入空间, 支持解释性和性能。我们的方法的理论基础在于建立深度可分离卷积和傅里叶分析之间的联系。对于  $N$  点信号  $x[n]$ , 我们展示了深度卷积阶段可以通过自适应滤波器学习近似 DFT 矩阵  $F \in \mathbb{C}^{N \times N}$ 。

$$\underbrace{\sum_{c=1}^C (x_c * h_c)[m]}_{\text{Depthwise}} \rightarrow \underbrace{\sum_{k=0}^{N-1} x[n] e^{-j2\pi kn/N}}_{\text{DFT}} \quad (3)$$

其中  $x_c$  表示第  $c$  个通道的输入,  $h_c$  表示通道  $c$  的可学习核。与 DFT 中固定的基函数不同, 我们的卷积核通过梯度下降自适应地学习频率选择性滤波器。后续的逐点卷积将这些特定于通道的频谱成分综合成一个全面的频率表示, 类似于 DFT 的正交基组合。这种受限的知识蒸馏方法确保早期卷积层捕捉到时间局部特征及其频谱签名, 为后续网络层提供了一个基于物理的基础, 以提取鲁棒性噪声、任务特定的表示。




图 3. 所提议的 DVS 系统的示意图。一个窄线宽激光器 (NLL) 发射连续光学波, 这些波形由任意波形发生器 (AWG) 和半导体光放大器 (SOA) 进行整形和放大, 然后通过掺铒光纤放大器 (EDFA) 进一步增强。生成的光脉冲穿过传感光纤, 在此过程中振动引起的瑞利背向散射被光电二极管 (PD) 检测到, 并由模数转换器 (ADC) 数字化, 最后在 FPGA 平台上使用所提议的模型进行实时分析。

### 3. 实验

为了验证我们的框架，我们使用图 3 所示的系统收集了真实世界的 DVS 数据。该设置包括一段 30 公里长的光纤，其中 50 米长的部分被埋在 0.5 米厚的复合材料下，这种材料由土壤、沙子和石头以随机比例组成。这种配置引入了现实环境噪声和振动模式的变化，使模型能够在变化条件下进行稳健的泛化评估。

表 1. 数据集的类标签和样本分布

| Class     | Dataset-1 | Dataset-2 |
|-----------|-----------|-----------|
| Hammer    | 3332      | 268       |
| Air Pick  | 3558      | 330       |
| Excavator | 3359      | 277       |




图 4. 空间-时间格式下的样本可视化：(a), (b), (c) 来自数据集-1, (d), (e), (f) 来自数据集-2。颜色强度表示归一化信号幅度。

系统以 1 毫秒的间隔捕捉瑞利后向散射光迹，空间间隔为 1.5 米。这些轨迹被汇总并分割成  $256 \times 11$  的样本，每个样本代表 256 毫秒时间窗口内的 12.5 米光纤



段。数据在不同的日子从两个不同的地点收集，产生了两个独立的数据集。这些数据集的类别分布详见表 1。图 4 描述了数据集类别的固有变异性，展示了仅通过轻量级架构提取可靠信号特征的挑战性。为了支持跨域评估，我们通过对样本的时间轴（即列方向）进行 DFT 生成了互补的空间光谱表示。

### 3.1. 模型优化




图 5. DSCNN-3 模型的推理过程。每个框表示网络中特定层的输出特征图。

我们使用数据集-1 进行训练和验证，采用五折交叉验证，并使用数据集-2 进行泛化测试。所有指标报告了五个独立试验的平均值。Adam 优化器以 0.01 的学习率初始化，在检测到验证损失停滞时每五个周期将学习率减半（耐心=5），使用批量大小为 8，以在 200 个训练周期内稳定梯度估计。

基于先前的工作，我们开发了一个更为紧凑的 3 层 CNN 架构（DSCNN-3），该架构结合了深度可分离卷积以降低复杂性同时保持性能。我们进一步实现了一个流行的大型网络 ResNet-34 进行比较 [22, 23]。DSCNN-3 由三个深度可分离卷积层组成，每个卷积层后面都跟着池化层：前两个使用最大池化对特征图进行下采样，而第三个使用平均池化以保留更多的上下文信息。这些层逐渐将输出通道的数量从 8 增加到 16，最后到 32。在卷积块之后，输出被展平并传递给一个全连接层，该全连接层将特征映射到最终的类别预测。图 5 展示了端到端推理管道，包括空间-时间输入、引导首次卷积的 DFT，引入频谱敏感性，随后的卷积层和池化层提取混合的空间-频谱特征，以及最终的分类层。

为了量化跨域蒸馏框架的影响，我们比较了使用三种不同训练范式的模型：S-T 模型，在原始时空数据上进行训练；S-S 模型，在通过 DFT 衍生的空谱数据上进行训




图 6. DSCNN-3 和 ResNet-34 模型在不同训练模式下的性能。S-T：基于原始时空数据训练的时空模型；S-S：基于通过 DFT 获得的空间光谱数据训练的空间光谱模型；C-D：使用跨域蒸馏训练的跨域模型。

练；以及 C-D 模型，使用跨域蒸馏进行训练。如图 6 所示，尽管参数较少，DSCNN-3 仍能匹配 CNN-4 和 ResNet-34 的验证准确率。这证实了深度可分离卷积在减少模型复杂性的同时保持模型性能的有效性。但 S-S 和 S-T DSCNN-3 在测试集上的准确性出现了显著下降，表明该模型的泛化能力有限。图 6 还可可视化了三种训练范式的比较表现。蒸馏后的 DSCNN-3 不仅在总体准确率上匹配深度 ResNet-34，还缩小了验证和测试性能之间的差距，这表明泛化能力和鲁棒性得到了提升。相比之下，S-T 模型虽然实现了高验证准确性，但在测试准确性方面出现了显著下降，而 S-S 模型表现出中等程度的泛化能力。跨域蒸馏框架引导模型在两个领域内寻找特征，从而获得既高效又稳健的特征，这带来了更好的性能和泛化性。

图 7 对这些趋势提供了更深入的洞察。在 S-T 模型测试集的结果中，低精度和召回率揭示了其对局部时间模式的过度依赖。S-S 模型缓解了一些错误，但仍表现出混淆，如“Hammer”类中的低精度和高召回率，“Air Pick”类中的高召回率但低精度所示。相比之下，C-D 模型显示出更加均衡的表现矩阵。这表明跨域蒸馏不仅提高了整体准确性，而且关键的是将这种准确性均匀地分布在所有类别中，验证了其在引导轻量级网络学习高效时间特征和可泛化的光谱签名方面的作用。

为了研究深度对蒸馏效果的影响，我们进一步在池化层前的 1-5 个卷积层中进行了控制实验，涉及三个  $\alpha$  值 (0.3, 0.5, 0.7)。这也是为了探讨这样一个问题：尽管深层确实有助于提供更好的容量，但这是否意味着改进后的网络容量能帮助知识蒸馏过程，或是更好地近似 DFT 过程以将频谱信息引入低级特征，同时提取时间信息。图 8 绘制了不同深度和  $\alpha$  值的验证和测试准确率。单层变体实现了 95.72% 的测试准确率，略高于深层模型，并且非常接近最佳 ResNet-34 基线。超过一个卷积层后，额外的层数带来递减回报：尽管更深的架构带来了微小增益，但这些都与单层模型相比没有显示出改进，因此没有使用更深层结构理由。这种饱和表明由跨域蒸馏强制执行的核心频谱-时间对齐已经由第一个卷积层捕捉到，这与我们的理论见






图 7. 模型结果的可视化: (a), (b), (c) 是验证结果, (d), (e), (f) 是测试结果。

解一致，即逐深度可分离卷积可以有效地近似线性 DFT 映射（方程 3）。这些结果有两个重要的含义。首先，它们证实了适当结构的最小网络足以吸收来自另一个域的知识转移，缓解了对更深和计算更昂贵架构的需求。其次，它们强调增加层的主要好处不是提高蒸馏效果，而是细化层次特征抽象，在我们的轻量级设置中，这对于特定的跨域任务是不必要的。总的来说，这些发现验证了我们设计单层蒸馏 CNN 的选择，达到了参数效率、频谱对齐和时间特征学习之间的最优平衡。

### 3.2. 硬件加速

为了优化所提模型的计算速度，我们在 FPGA 平台上实现它，利用其可重构性和灵活性。为了进一步加速处理，我们采用专门的“移位-加法”量化方案 [15]。在该方案中，传统的资源密集型乘法运算被移位运算取代，使计算能够由 FPGA 的逻辑单元处理，而不是其有限的数字信号处理 (DSP) 资源 [24]。这种转换显著增强了并行性，允许更多操作同时执行，从而降低延迟。

为了实际评估，选择了高性能的 Xilinx ZCU15EG 平台进行性能测试，因为它提供了丰富的资源来实现全并行化和时钟速率优化。该实现达到了令人印象深刻的 8,469 周期延迟，在 2.24 ns 的时钟周期下，实现了每秒处理 13,494 个样本的能力，并且仅消耗了可用 LUTs 的 2.55%（共使用了 8,690 个，总计 341,280 个）和 FFs 的




图 8. 模型性能跨网络深度和  $\alpha$  值的域间蒸馏: (a) 是验证准确率, (b) 是测试准确率。

1.32% (共使用了 9,020 个, 总计 682,560 个)。值得注意的是, 它不消耗任何 DSP 块、BRAM 或 URAM, 使其非常适合作为成本敏感且资源受限边缘设备上的部署方案。这种处理速度支持在 1.25 m 的空间间隔下监测 168.7 km 的光纤。

表 2. 计算效率和模型性能对比: 蒸馏模型与深度模型

| Model      | Inference time<br>on GPU/ms | Inference time<br>on FPGA/ms | Val/% | Test/% | FLOPs     | Params  |
|------------|-----------------------------|------------------------------|-------|--------|-----------|---------|
| ResNet-34  | 0.375                       | -                            | 99.50 | 97.67  | 226235392 | 8164803 |
| CNN-4 [15] | 0.178                       | 0.083                        | 99.61 | 95.39  | 4331520   | 30771   |
| DSCNN-3    | 0.162                       | 0.019                        | 99.49 | 95.73  | 601600    | 4141    |

如表 2 所示, 蒸馏后的 DSCNN-3 模型在计算效率方面显著优于传统的深度模型和之前发布的轻量级模型, 并且保持了竞争力的准确性。与 ResNet-34 相比, DSCNN-3 通过大幅降低计算复杂性实现了这一点。这突显了我们跨域蒸馏和轻量化架构设计的有效性。在推理延迟方面, DSCNN-3 展示了显著的速度优势。在 GPU 上, 它优于轻量级 CNN-4 模型, 并且比 ResNet-34 快得多。更重要的是, DSCNN-3 的 FPGA 实现实现了仅 0.019 毫秒的超低延迟, 这比使用相同实施方案和 FPGA 平台的 CNN-4 达到的 0.083 毫秒快了 4.37 倍。这种改进主要归功于深度可分离卷积和移位加量化策略的有效利用, 两者都使得在 FPGA 上的高程度并行性和优化资源利用成为可能。

值得注意的是，由于其较高的资源需求使得完全并行化在实际硬件上不可行，因此 ResNet-34 未在 FPGA 上实现。GPU 和 FPGA 推理时间之间的对比进一步揭示了我们的模型和实施方案对硬件资源的有效使用，尤其考虑到使用的 GPU 的最大时钟频率为 2520 兆赫兹，这大约是 FPGA 实现速度的五倍快。虽然深度模型通常受益于 GPU 加速，但由于其高参数和计算复杂性，它们无法充分利用 FPGA 的并行处理能力。相比之下，DSCNN-3 精简的设计和量化算术特别适合 FPGA 实现，实现了实时吞吐量和最小延迟，而不会牺牲准确性。

为了评估在资源受限环境中的部署能力，我们还在低端的 Xilinx XC7A35T 平台上实现了 DSCNN-3。此实现通过将时钟周期放宽到 4.9 纳秒，在 103.1 公里监控能力方面达到了实时合规性，这是由于硬件资源有限所致。所提出的设计展示了卓越的硬件效率，仅使用了低端 XC7A35T FPGA 上的 8,579 个查找表 (LUT) 和 10,068 个触发器 (FF)，分别相当于可用资源的 20.6% 和 48.4%，并且完全没有 DSP、BRAM 或 URAM 的消耗。

两种实现方式都超过了 100 公里的感知范围，这与本文使用的评估系统理论最大感知范围相一致。总体而言，上述结果清楚地表明，所提出的 DSCNN-3 模型以及提出的方法在精度、计算成本和硬件效率之间提供了一个良好的平衡。它为实时动态视觉传感器应用提供了一种实用且可扩展的解决方案，尤其是在资源受限环境中，传统的深度模型难以部署。

#### 4. 结论

本文解决了 DVS 系统中实时处理的关键挑战，这一挑战传统上受限于硬件限制和常规深度学习模型的沉重计算负担。所提出的框架结合了超轻量级神经网络 (DSCNN-3) 与基于 FPGA 的加速，在资源有限的平台上也能提供高速推理。所提出的深度可分离卷积神经网络 (DSCNN-3) 以仅 4,141 个参数实现了最先进的性能，相比 ResNet-34 减少了 99.95% 的模型复杂度，同时保持了相似的性能和泛化能力。结合为 FPGA 实现优化的移位加量化方案，我们的解决方案在商业级 FPGA 芯片上实现了实施，并提供了系统最大理论感应范围的过程能力，展示了其在实际应用中的高适用性。本文提出了跨域蒸馏技术以提高轻量模型的泛化能力，并将物理知识引入训练过程，从而提供更高的可解释性。通过结合信号处理技术和数据驱动学习，该方法直接将先验物理知识，如源自傅里叶分析的频谱-时间关系嵌入现代神经网络中。我们的实验表明，跨域蒸馏相比用传统方法训练的基础模型提高了 43.8% 的测试准确性，解决了轻量模型在各种环境下的泛化问题。通过统一轻量化架构、物理知识引导的蒸馏和硬件加速，本研究提供了一种可扩展且高效的解决方案，用于实时长距离振动监测。除了 DVS 之外，所提出的方法为将领域特定的物理知识整合到神经网络中提供了路径，提供了一种构建稳健、高效和可解释的基于深度学习系统的泛化策略。

**资助.** 国家自然科学基金委员会 (62225110, 61931010); 湖北省重大项目 (JD)(2023BAA013); 湖北

省自然科学基金委员会 (2025AFB008)。

**披露.** 作者声明没有利益冲突。

**数据可用性.** 本文中呈现结果所依据的数据和代码均可在 GitHub 存储库 [https://github.com/HUST-IOF/Cross-Domain\\_Distill](https://github.com/HUST-IOF/Cross-Domain_Distill) 中获得。

## 参考文献

1. C. Pendão and I. Silva, “Optical Fiber Sensors and Sensing Networks: Overview of the Main Principles and Applications,” *Sensors* **22**, 7554 (2022).
2. X. Zhou, F. Wang, C. Yang, *et al.*, “Hybrid Distributed Optical Fiber Sensor for the Multi-Parameter Measurements,” *Sensors* **23**, 7116 (2023).
3. S. M. Ouellet, J. Dettmer, M. J. Lato, *et al.*, “Previously hidden landslide processes revealed using distributed acoustic sensing with nanostrain-rate sensitivity,” *Nat. Commun.* **15**, 6239 (2024).
4. H. Gietz, J. Sharma, and M. Tyagi, “Machine Learning for Automated Sand Transport Monitoring in a Pipeline Using Distributed Acoustic Sensor Data,” *IEEE Sensors J.* **24**, 22444–22457 (2024).
5. M. Jia, Z. Sun, C. Duan, *et al.*, “Pipeline Leaks Early Warning Based on Distributed Optical Fiber Sensing Technology,” *IEEE Photonics Technol. Lett.* **36**, 397–400 (2024).
6. Z. Lyu, C. Zhu, Y. Pu, *et al.*, “Two-Stage Intrusion Events Recognition for Vibration Signals From Distributed Optical Fiber Sensors,” *IEEE Trans. on Instrum. Meas.* **73**, 1–10 (2024).
7. L. Xie, Z. Li, Y. Zhou, *et al.*, “Railway Track Online Detection Based on Optical Fiber Distributed Large-Range Acoustic Sensing,” *IEEE Internet Things J.* **11**, 6469–6480 (2024).
8. M. He, W. Qing, and J. Qu, “Defect Recognition in Ballastless Track Structures Based on Distributed Acoustic Sensors,” *Appl. Sci.* **13**, 9663 (2023).
9. Y. Feng, L. Jianwei, L. Wei, *et al.*, “Identification of Corrosion-Induced Optical Fiber Acoustic Emission Sensor Signals on the Bottom Plate of Oil Storage Tank Based on Multichannel Attention Mechanism (CBAM),” *IEEE Sensors J.* **24**, 22790–22800 (2024).
10. Z. Ding, S. Wang, J. Kang, *et al.*, “Distributed Acoustic Sensing-Based Weight Measurement Method,” *J. Light. Technol.* **42**, 3454–3460 (2024).
11. P. D. Hernández, J. A. Ramírez, and M. A. Soto, “Deep-learning-based earthquake detection for fiber-optic distributed acoustic sensing,” *J. Light. Technol.* **40**, 2639–2650 (2022).
12. N. Yang, Y. Zhao, and J. Chen, “Real-Time  $\Phi$ -OTDR Vibration Event Recognition Based on Image Target Detection,” *Sensors* **22**, 1127 (2022).
13. H. Wu, Y. Wang, X. Liu, *et al.*, “Smart Fiber-Optic Distributed Acoustic Sensing (sDAS) With Multi-Task Learning for Time-Efficient Ground Listening Applications,” *IEEE Internet Things J.* pp. 1–1 (2023).
14. X. Shen, H. Wu, K. Zhu, *et al.*, “Fast and Storage-Optimized Compressed Domain Vibration Detection and Classification for Distributed Acoustic Sensing,” *J. Light. Technol.* **42**, 493–499 (2024).
15. Z. Luo, H. Wu, Z. Ge, and M. Tang, “Real-time event recognition of long-distance distributed vibration sensing with knowledge distillation and hardware acceleration,” *IEEE Internet Things J.* pp. 1–1 (2025).
16. A. G. Howard, M. Zhu, B. Chen, *et al.*, “Mobilenets: Efficient convolutional neural networks for mobile vision applications,” *ArXiv abs/1704.04861* (2017).
17. J. Yang, C. Wang, J. Yi, *et al.*, “Railway Intrusion Events Classification and Location Based on Deep Learning in Distributed Vibration Sensing,” *Symmetry* **14**, 2552 (2022).
18. H. Zhao, C. Liu, J. Yang, *et al.*, “A fast and accurate recognition method for low-cost intensity-demodulated fiber-optic Distributed Vibration Sensor (DVS),” in *Thirteenth International Conference on Information Optics and Photonics (CIOP 2022)*, vol. 12478 Y. Yang, ed., International Society for Optics and Photonics (SPIE, 2022), p. 124781V.
19. Z. Ye, Z. Li, N. Wang, *et al.*, “HR and LiDAR Data Collaborative Semantic Segmentation Based on Adaptive Cross-Modal Fusion Network,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote. Sens.* **17**, 12153–12168 (2024).
20. G. Bang, K. Choi, J. Kim, *et al.*, “Radardistill: Boosting radar-based object detection performance via knowledge distillation from lidar features,” in *2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, (2024), pp. 15491–15500.

21. A. Romero, N. Ballas, S. E. Kahou, *et al.*, “FitNets: Hints for Thin Deep Nets,” (2015).
22. X. Jin, K. Liu, J. Jiang, *et al.*, “Pattern recognition of distributed optical fiber vibration sensors based on resnet 152,” *IEEE Sensors J.* **23**, 19717–19725 (2023).
23. R. Yao, J. Li, J. Zhang, and Y. Wei, “Vibration event recognition using sst-based  $\phi$ -otdr system,” *Sensors (Basel, Switzerland)* **23** (2023).
24. J. Meng, S. K. Venkataramanaiah, C. Zhou, *et al.*, “Fixyfpga: Efficient fpga accelerator for deep neural networks with high element-wise sparsity and without external memory access,” 2021 31st Int. Conf. on Field-Programmable Log. Appl. (FPL) pp. 9–16 (2021).