

基于非训练神经网络的傅里叶单像素 高光谱边缘成像*

仪登利¹⁾ 张恩睿²⁾ 王晞颜²⁾ 孟少英²⁾ 陈希浩^{2)†}

1) (营口理工学院机械与动力工程学院, 营口 115014)

2) (辽宁大学物理学院, 沈阳 110036)

(2026 年 1 月 18 日收到; 2026 年 2 月 24 日收到修改稿)

高精度边缘检测在工业制造中对表面缺陷识别与质量控制具有关键意义, 然而传统成像方法在微尺度缺陷的解析能力上仍受到空间分辨能力不足的限制. 本文提出一种基于物理驱动的生成对抗网络近红外傅里叶单像素高光谱边缘成像方法. 该方法通过空间光调制器加载具有微分算子结构的测量基, 将高斯-拉普拉斯算子的空间响应嵌入单像素调制与探测过程, 使测量对目标空间强度的高阶变化更加敏感, 从而在数据获取阶段直接增强边缘相关的高空间频率信息. 在重构端, 构建融合单像素积分测量模型的生成对抗网络, 并引入物理一致性约束与光谱相关性约束, 实现从 512 个近红外光谱通道的桶探测信号中反演高分辨率二维边缘图像. 实验结果表明, 在稀疏采样条件下, 该方法在边缘分辨力与光谱保真度方面均显著优于传统重构策略, 能够有效解析常规方法难以识别的微尺度表面划痕. 该工作为高光谱单像素成像在材料表征、表面缺陷检测及精密测量等应用中提供了一种新的物理-数据协同成像方案.

关键词: 单像素成像, 高光谱成像, 边缘检测, 生成对抗网络, 物理驱动网络, 近红外成像

DOI: 10.7498/aps.75.20260092

CSTR: 32037.14.aps.75.20260092

1 引言

边缘检测是图像处理与计算机视觉领域的一项基础且关键技术, 其目标是精确识别图像中物体的边界或不同区域间的灰度突变^[1-3]. 该技术在目标识别、图像分割、特征提取及工业缺陷检测等应用中具有重要作用^[4,5]. 在制造业中, 边缘检测是机器视觉系统的核心环节, 广泛应用于焊缝跟踪、零件尺寸测量以及表面检测等质量控制任务^[6], 例如金属表面裂纹与划痕识别、电子产品微型零件定位以及纺织品瑕疵分割等^[7]. 随着计算成像技术的发

展, 边缘检测^[8,9]逐渐从依赖经典图像域算子的方式, 演进为一种融合前向物理编码与反演端计算重建的统一框架. 在这一背景下, 不同技术路径分别从测量端与反演端对边缘信息获取过程进行了拓展与优化: 一方面, 单像素成像通过时空调制与相关测量, 在经典光源条件下实现对高维场景信息的间接获取, 其成像性能主要依赖于编码策略与反演算法的协同设计; 在此基础上, 引入纠缠光等量子光源的研究^[10]则进一步尝试利用非经典关联特性, 在低光子数或强噪声条件下提升测量灵敏度和高空间频率分量的响应, 这类方法通常通过改变光源统计特性来增强前向测量过程. 另一方面, 超表面

* 辽宁省自然科学基金营口联合计划 (批准号: 2024-YKLH-15)、冶金智能制造系统全国重点实验室氢冶金开放课题 (批准号: QZKF2024-12)、辽宁省储能与能源利用技术重点实验室内部课题 (批准号: CNNK202504) 和辽宁省菱镁矿高值利用工程研究中心内部课题 (批准号: LMNY2025020218) 资助的课题.

† 通信作者. E-mail: xi-haochen@163.com

等新型光学器件通过在器件层面直接实现空间微分等光学算子, 为边缘检测提供了高并行、低延迟的物理实现途径. 结合深度学习方法, 在保持实验系统结构相对简洁、光源与探测方式不变的前提下, 可通过反演端的结构化建模与数据驱动优化, 实现复杂场景中边缘特征的鲁棒重建与自适应增强, 体现了物理编码与计算智能深度融合的综合优势. 特别是以鬼成像和单像素成像 (single-pixel imaging, SPI) 为代表的新型计算成像方法, 为边缘检测提供了全新的解决思路^[11-18]. 与传统方法依赖完整图像进行数字处理不同, SPI 边缘检测能够以“无图像”的方式, 通过特定光学编码直接从测量端获取目标的边缘信息. 为实现这一目标, 研究者提出了多种光学编码方案. 早期的梯度鬼成像^[12]和散斑位移鬼成像^[13]验证了直接提取边缘的可行性, 但基于随机散斑照明的方法普遍存在采样效率低和成像质量受限的问题. 为突破这一瓶颈, 基于傅里叶单像素成像 (Fourier single-pixel imaging, FSI) 的频域编码方法被提出^[14]. 例如, Zhou 等^[16]通过将二阶高斯-拉普拉斯 (Laplacian of Gaussian, LoG) 算子与傅里叶基图案卷积, 生成可直接探测边缘信息的特殊正弦图案, 从而有效增强了成像的抗噪能力.

在经典 SPI 边缘成像框架下, 尽管现有的 SPI 边缘检测技术已在目标识别和结构提取等方面取得一定进展, 但在复杂场景下恢复物体表面的精细物理细节仍存在显著局限. 为突破传统 SPI 在成像速度与重建质量上的瓶颈, 尤其是在低采样率条件下实现高质量重构, 深度学习被视为一种极具潜力的途径^[19]. 然而, 数据驱动的深度学习方法通常依赖大规模标注数据集, 而这在实际物理成像中往往难以获取; 同时, 其“黑箱”特性导致缺乏物理可解释性, 并在新样本上泛化能力不足^[20]. 为此, 物理驱动深度学习方法近年来受到广泛关注^[20,21]. 该方法将成像系统的物理模型作为先验知识嵌入网络结构中, 从而摆脱对数据集的依赖并提升模型的可解释性. 基于深度图像先验 (deep image prior, DIP)^[22]的思想, 即未经训练的生成网络结构本身即可捕获图像的低层统计特征, 已在单像素高光谱成像^[23]、透明物体恢复^[24]及自适应鬼成像^[25]等任务中取得成功. 在此基础上, 生成对抗网络 (generative adversarial network, GAN) 通过引入对抗机制显著增强了生成结果的真实感与细节保真

度^[26]. 尽管物理驱动深度学习在 SPI 领域展现出巨大潜力, 但在专门面向边缘检测的研究方向上仍相对匮乏^[27], 现有方法主要基于卷积神经网络结构, 在含噪与欠采样场景下的边缘重建性能仍受限制, 难以充分恢复细节保真的高质量边缘信息.

为解决上述问题, 本研究提出一种基于物理驱动 GAN 的近红外单像素边缘成像方法, 并在近红外高光谱单像素成像条件下开展工作. 该方法在物理层面, 通过融合 LoG 算子与傅里叶基的调制策略, 对目标边缘信息的空间频率响应进行先验编码与增强; 在计算层面, 则利用 GAN 结构的端到端非线性映射能力, 实现对编码信息的自适应特征学习与高保真重建. 数值仿真验证了该方法对比传统重构算法能对边缘模糊和灰度阶梯伪影有效抑制, 并显著提升了边缘保真度与细节连续性. 实验研究进一步证实, 该方法能够精确恢复传统算法无法解析的物体表面微细划痕. 综上, 该物理驱动 GAN 框架为单像素边缘成像提供了实现更优细节保真度与结构辨识度的有效途径, 为工业缺陷检测和精密测量等应用领域提供了方法基础.

2 原理与方法

基于物理驱动 GAN 的近红外单像素边缘成像方案如图 1 所示. 其中, 图 1(a) 展示了经典的被动式单像素成像原理. 光源发出的近红外光照射目标后, 经反射并通过成像透镜系统在数字微镜器件 (digital micromirror device, DMD) 平面上形成目标的光学映射. DMD 按照预设的调制散斑序列对入射光场进行空间调制, 经调制后的反射光由单像素探测器采集, 得到与每个调制散斑对应的一维桶式信号序列. 随后, 这些信号经模数转换及数据采集模块输入计算机进行存储与处理. 最终, 预设的调制散斑与对应的桶信号共同用于 GAN 重建优化, 实现目标图像的重建, 如图 1(b) 所示.

2.1 基于高斯-拉普拉斯算子的物理编码

在 FSI 系统中, 通过投射一系列正交的二维傅里叶基图案进行照明. 每一个基图案 P_ϕ 可由其空间频率 (f_x, f_y) 和初始相位 ϕ 定义:

$$P_\phi(x, y; f_x, f_y) = a + b \cos(2\pi f_x x + 2\pi f_y y + \phi), \quad (1)$$

其中 a 和 b 分别为直流分量和对比度. 当携带物体




图 1 基于物理驱动 GAN 的单像素边缘成像方案示意图 (a) 实验光路图; (b) GAN 重构网络框架图

Fig. 1. Physics-driven GAN-based single-pixel edge imaging scheme: (a) Experimental optical setup; (b) GAN reconstruction network framework.

信息的光场 $O(x, y)$ 被该图案调制后, 单点探测器记录的总光强为二者的内积. 通过四步相移法, 即依次投射 $\phi = \{0, \pi/2, \pi, 3\pi/2\}$ 的四个图案, 可以精确求解出物体在该空间频率下的傅里叶频谱分量^[14].

为了实现对物体边缘特征的直接光学采样, 本文采用 Zhou 等^[16] 提出的方法, 将 LoG 二阶差分算子与傅里叶基进行卷积, 以生成一系列携带边缘信息的特殊照明图案 P_ϕ^* . LoG 算子因其在抑制噪声的同时能有效检测精细边缘而被广泛应用, 其卷积核可表示为

$$\text{LoG}(x, y) = \frac{x^2 + y^2 - 2\sigma^2}{\pi\sigma^4} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right), \quad (2)$$

其中 σ 为高斯分布的标准差. 根据卷积定理, 对物体图像 $O(x, y)$ 进行 LoG 边缘检测, 等效于在频域中将其频谱与 LoG 算子的传递函数相乘^[16]. 因此, 通过生成并投射如下的特殊图案:

$$P_\phi^*(x, y; f_x, f_y) = P_\phi(x, y; f_x, f_y) * \text{LoG}(x, y), \quad (3)$$

探测器所采集的桶信号 D_ϕ^* 将直接对应于物体边缘图像的傅里叶分量, 而非物体本身. 这一过程完成了边缘信息的物理编码.

2.2 基于物理驱动 GAN 的图像重构

获得一维边缘桶信号 D_ϕ^* 后, 核心问题在于如何在有限、含噪测量下高保真重建二维边缘图像. 传统四步相移傅里叶单像素成像在理论上依赖相位移动的精确控制与线性叠加假设, 因而对噪声扰动、光学畸变及系统非理想因素较为敏感, 常导致边缘模糊或细节丢失. 为克服这些限制, 本文采用一种物理驱动的无数据 (非训练) GAN 框架: 在生成网络中显式嵌入单像素成像的前向物理模型, 通过测量域的一致性约束将网络输出映射回真实测量; 与

此同时, 以图像域的边缘先验作为正则化, 以保证局部梯度与空间结构的物理可解释性与稳定性.

如图 1(b) 所示, 框架由生成器 G 与判别器 D 组成并在极大极小博弈中联合优化. 生成器采用 U-Net 等深度卷积结构, 以一个固定随机码 z (或任意先验图样) 为输入, 输出候选边缘图像 $\tilde{O}_{\text{edge}} = G(z)$; 真实测量 D_ϕ^* 不直接作为网络输入, 而是通过前向物理算子进入损失函数, 用于约束 $\tilde{O}_{\text{edge}}$ 与测量的一致性, 这与非训练物理驱动网络的范式一致.

正向物理模拟采用与 2.1 节一致的积分测量模型. 注意到 LoG 核 $\text{LoG}(x, y)$ 为偶对称核 ($\text{LoG}(x, y) = \text{LoG}(-x, -y)$), 根据卷积定理, 有 $P_\phi^* = P_\phi * \text{LoG}$. 因此, 用原始傅里叶基图案 P_ϕ 对图像域的边缘 $\tilde{O}_{\text{edge}}$ 做前向映射, 可与真实的 LoG 编码桶信号 D_ϕ^* 在测量域建立一一对应关系. 相应地, 生成器输出 $\tilde{O}_{\text{edge}}$ 的“模拟桶信号”定义为

$$\tilde{D}_\phi = \mathcal{M}(\tilde{O}_{\text{edge}}) = \iint_{\Omega} \tilde{O}_{\text{edge}}(x, y) P_\phi(x, y) dx dy, \quad (4)$$

其中积分区域 Ω 为照明口径范围. 与真实测量的一致性采用二范数平方形式

$$L_{\text{phys}} = \frac{1}{|\Phi|} \sum_{\phi \in \Phi} \|\tilde{D}_\phi - D_\phi^*\|_2^2, \quad (5)$$

其中 Φ 表示本次测量涉及的相位/图案集合.

为进一步提升在无数据条件下的稳健性与细节保真度, 判别器在测量域对“真实/模拟”桶信号进行判别, 形成无监督对抗约束. 其对抗损失可写为

$$L_{\text{adv}}(G, D) = \mathbb{E}_\phi [\log D(D_\phi^*)] + \mathbb{E}_\phi [\log (1 - D(\tilde{D}_\phi))], \quad (6)$$

这里 G 与 D 分别为生成器与判别器神经网络. G

的参数化形式为 G_{θ_G} , 旨在通过学习分布映射来欺骗判别器; D 的参数化形式为 D_{θ_D} , 旨在通过最大化该损失函数以精确区分真实样本分布与生成样本分布. $\mathbb{E}_{\phi}$ 表示对集合 Φ 的经验平均 (实现中等价于 $(1/|\Phi|) \sum_{\phi \in \Phi}$), 与 (5) 式中 L_{phys} 的归一化处理保持一致. 实际实现中亦可采用 hinge 或 WGAN-GP 提升稳定性. 边缘先验不通过判别器直接施加, 而是并入图像域正则项以鼓励边缘稀疏与结构连续, 例如

$$L_{\text{reg}} = \beta_{\text{TV}} \text{TV}(\tilde{O}_{\text{edge}}) + \beta_{\nabla} \|\nabla \tilde{O}_{\text{edge}}\|_1, \quad (7)$$

其中 TV 表示总变分正则; $\|\nabla \cdot\|_1$ 表示一阶梯度的 ℓ_1 范数; β_{TV} 和 β_{∇} 分别为总变分正则项和一阶梯度正则项的权重系数, 用于平衡边缘稀疏性与结构连续性. 于是, 生成器与判别器的联合优化目标为

$$\min_G \max_D L_{\text{phys}} + \lambda_{\text{adv}} L_{\text{adv}}(G, D) + \lambda_{\text{reg}} L_{\text{reg}}, \quad (8)$$

其中 λ_{adv} 与 λ_{reg} 为权重超参数. 通过反向传播迭代更新, $\tilde{O}_{\text{edge}}$ 在测量域逐步对齐 D_{ϕ}^* , 同时在图像域满足边缘先验, 从而在无数据条件下获得物理一致且细节清晰的边缘重建结果. 若采用多波段采集, 上述记号与损失可按波段集合 Λ 逐通道扩展并在 (ϕ, λ) 上取平均, 具体采集配置与展示策略见第 3 节.

3 结果与分析

为验证所提出的物理驱动 GAN 框架的有效性与优势, 本节设计并实施了一系列数值模拟与实验. 作为对照, 我们采用基于 LoG 算子的傅里叶单像素成像 (Laplacian of Gaussian-based Fourier single-pixel imaging, LFSI) 方法^[16]. 通过在不同实验条件下对两种方法进行定量与定性比较, 评估所提方法在边缘重构任务中的性能.

3.1 数值模拟

在实际应用场景中, 成像目标往往具有复杂的结构特征与多变的边缘形态. 例如, 由于光学系统分辨率限制、散射噪声或物体表面的纹理渐变等因素, 目标边缘常呈现不同程度的模糊和灰度过渡. 这些特性使得传统的边缘检测与重构算法在处理时易受噪声干扰, 导致边界定位不准、伪影增多, 以及灰度层次信息损失. 因此, 为全面评估所提基

于生成对抗网络 (GAN) 的成像重构方法在复杂边缘场景下的鲁棒性与泛化性能, 我们设计了一组具有代表性的数值模拟实验, 结果如图 2 所示. 在模拟实验中, 通过将待成像目标与计算机生成的周期性正弦条纹进行卷积, 并对卷积结果逐点求和, 仿真单像素探测器在光场调制条件下采集桶信号的过程. 随后, 分别利用传统的四步相移光场单像素成像 (LFSI) 算法与本文提出的基于 GAN 的重构算法进行图像恢复与边缘提取. 为保证分析的全面性, 选取了三种典型目标: (a) 边缘清晰、结构简单的二值字母“Z”; (b) 经高斯模糊处理并包含灰度过渡区域的字母“Z”; (c) 纹理与细节均较为复杂的灰度海豚图像.




图 2 模拟结果对比 (a) 二值物体“Z”; (b) 边缘模糊且存在灰度阶梯的物体“Z”; (c) 复杂灰度海豚图像

Fig. 2. Comparison of simulation results: (a) Binary object “Z”; (b) object “Z” with blurred edges and grayscale steps; (c) complex grayscale dolphin image.

从图 2 可知, 对于理想化的二值目标 (图 2(a)), 两种方法均能较好地恢复目标的基本轮廓与边缘结构, 说明在低复杂度场景下, 传统 LFSI 方法仍具有一定的有效性. 然而, 当目标出现边缘模糊和灰度渐变 (图 2(b)) 时, 传统 LFSI 算法由于对光场采样信号变化的线性假设较强, 容易受到边缘过渡区的相位非线性影响, 从而导致重构图像中出现伪影、虚边及多重边缘效应. 相比之下, 所提 GAN 方法在生成器的深层特征学习机制和判别器的对抗优化作用下, 能够充分利用图像的统计先验与空间结构信息, 从而在重构结果中准确还原目标真实轮廓, 边缘过渡自然且无明显伪影, 表现出显著的鲁棒性. 当目标进一步复杂化为灰度海豚图像 (图 2(c)) 时, 传统 LFSI 方法的局限性更加突出, 重构结果

存在严重的纹理断裂与灰度漂移现象. 相反, GAN 方法凭借其端到端的非线性映射能力, 不仅在整体轮廓上保持了较高的一致性, 而且在局部细节和边缘连续性上均表现出优异的重建质量. 综合来看, 实验结果充分验证了本方法在处理边缘模糊、灰度复杂以及纹理细节丰富目标时的鲁棒性与优越性能, 为其在真实成像任务中的应用奠定了可靠基础.

3.2 实验验证与分析

为进一步验证本方法在真实物理环境中的有效性与可推广性, 我们基于图 1(a) 所示的实验装置图, 进行了近红外高光谱单像素边缘成像实验. 在具体的实验中, 系统主要由照明模块、空间调制模块与数据采集模块组成. 宽带近红外光源 (HL-2000-HP, Ocean Optics, 波长范围 900—1700 nm) 为系统提供照明. 该光源的辐射通量随波长呈现非均匀分布特征. 目标物体由塑料字母“B”和铝制字母“L”组成复合目标. 目标反射光经由焦距为 $f = 60$ mm 的成像透镜聚焦于数字微镜器件 (DMD, DLP7000, 德州仪器) 的感光面上. 计算机采用第 2.1 节所述的物理编码方法, 预先生成由高斯-拉普拉斯 (LoG) 算子与傅里叶基卷积而成的正弦调制图案, 并利用 Floyd-Steinberg 抖动算法将其二值化. DMD 依次加载编码图案对光场进行空间调制. 调制后的光束由聚光透镜收集, 经多模光纤耦合进入近红外光谱仪 (NIRQuest512, Ocean Optics). 该光谱仪专为弱光探测设计, 内置热电制冷模块 (恒温 -10 °C) 以有效抑制热噪声, 具备 1.6 nm 的光谱分辨能力及 512 个独立的 InGaAs 探测通道. 最后, 数据由采集卡 (NI USB-6363) 数字化并传输至计算机, 通过 LabVIEW 与 Python 联合编写的程序实现调制与采集的严格同步控制 [28]. 整个实验与图像重建过程具体可分为四个步骤: 步骤 1: 光场构建与图案加载. 宽带近红外光照射目标后成像于 DMD 平面, 系统以 20 Hz 的频率依次加载经第 2.1 节方法编码并完成二值化处理的调制图案, 实现对目标反射光场的高频空间调制. 步骤 2: 同步信号采集. 调制后的光信号经光纤耦合至近红外光谱仪, 利用软硬件联合控制确保 DMD 图案刷新与采集卡 (1000 Hz 采样) 严格同步, 获取对应 512 个光谱通道的一维桶信号. 步骤 3: 数据预处理. 对采集到的原始多通道桶信号进行暗噪声校正与归一化处理, 以有效消除环境光漂移及系统非线性响

应的干扰. 步骤 4: 物理驱动网络重构. 将预处理后的多通道数据输入至随机初始化的 GAN 网络中. 在训练过程中, 采用 Adam 优化器, 通过损失函数施加物理一致性与边缘先验约束, 优化网络参数以保证输出结果符合物理模型, 最终输出二维边缘图像.

图 3 为在 5 个具有代表性的近红外波段下的边缘重构结果, 分别对应波长为 882.76, 1086.53, 1412.56, 1650.56 和 1704.35 nm 的典型光谱通道. 这些波段覆盖了从塑料到金属等常见材料的主要反射响应范围, 因此能够有效反映算法在不同光谱特征条件下的成像性能. 实验结果与数值模拟所得的结论高度一致, 进一步验证了所提方法在真实物理系统中的可行性与稳定性. 对比图像可以看出, 在所有波段条件下, 传统 LFSI 方法重构结果普遍存在边缘模糊与纹理断裂等问题. 值得注意的是, 在非目标 (背景) 区域, LFSI 的结果充斥着大量低频纹理与类似散斑的随机结构. 尤其在长波段 (>1400 nm) 区域中, 由于系统信噪比降低与材料反射率差异增强, 这些失真效应更为明显. 相比之下, 本文提出的基于 GAN 的重构方法在边缘对比度、结构连续性以及背景抑制方面均表现出显著优势. 首先, 从全局重构质量来看, 本方法不仅获取的边缘局部锐度更高, 且背景区域更接近“零响应”, 噪声分布极度稀疏, 能量高度集中于边缘处. 表明该方法更接近算子意义上的物理边缘检测, 而非仅对全局图像做模糊增强. 其次, 从抗噪能力与鲁棒性来看, 在图 3 最后两列所示的长波段 (1650.56 nm 和 1704.35 nm) 条件下, 随着探测器响应衰减导致信噪比急剧下降, LFSI 的有效边缘已完全被散斑噪声吞没; 而本文方法依然能够克服强噪声干扰, 重构出目标字母 (“L”和“B”) 可辨识的连续拓扑轮廓, 主体结构并未丢失. 造成这一差异的根本原因在于, 相较于 LFSI 的通用频域成像特性, 本文方法将光学端的物理编码 (差分算子) 与计算端的非线性反演 (生成网络) 进行了协同优化. 这种“编码-反演”机制不仅能靶向提取边缘, 还能自适应地滤除无关的背景成分. 因此, 即便在面临波长漂移、信噪比骤降及系统退化等复杂工况时, 该方法依然不敏感, 在多波段下展现出了优异的成像一致性与抗噪鲁棒性.

最为关键的是, 本文方法成功重构出了传统方法完全无法分辨的物体表面微小划痕与亚像素级




图 3 实验结果对比. 上图为传统 LFSI 方法的重构结果, 下图为本文 GAN 方法的重构结果

Fig. 3. Comparison of experimental results: top panel, reconstructions using the traditional LFSI method; bottom panel, reconstructions using the proposed GAN method.

结构细节. 如图 4 所示, 这些细微划痕宽度仅约为 50—80 μm , 已远低于系统成像孔径所对应的空间分辨极限. 由于传统 LFSI 方法在强噪声与有限采样条件下无法准确恢复高空间频率分量, 其重构结果中的划痕信息被完全淹没于背景噪声之中, 仅呈现模糊不清的亮斑或随机纹理. 而在本文提出的基于 GAN 的重构结果中, 这些微划痕的形态、走向及边缘过渡均得以清晰呈现, 与真实样品的表面形貌高度一致 (如图中箭头所示). 这一现象充分说明, 所构建的 GAN 框架能够有效学习并重建传统线性算法无法捕获的高频细节信息. 具体而言, GAN 的生成器通过端到端的非线性映射学习, 将光谱桶信号中隐含的微弱空间特征进行解码, 而判别器则通过对抗训练自适应抑制重建噪声, 从而在

保持整体结构一致性的同时, 显著提升了细节保真度. 值得注意的是, 即便在改变网络训练超参数 (如学习率、批量大小等) 或对输入数据进行不同程度的归一化处理后 (见图 4 下图), 这些微划痕特征仍能稳定被恢复出来, 表明本方法在参数扰动下依旧保持良好的重建鲁棒性与网络收敛稳定性. 上述结果强有力地证明了, 本方法在单像素边缘成像框架下显著增强了对物体表面微结构的感知与区分能力. 相较于传统方法, 它不仅能在噪声主导环境中恢复亚波长级细节, 而且能在多次实验与不同参数条件下保持稳定性能, 体现了其在真实复杂场景中的可应用潜力. 从更广的视角来看, 该特性为非接触式表面缺陷检测、材料微结构表征及微尺度制造质量评估等应用提供了新的技术路径, 也为单像素高光谱成像在精密测量和工业检测领域的拓展奠定了重要基础.

4 结 论

本文针对当前傅里叶单像素边缘成像在复杂场景下因依赖传统重构算法而导致重建质量下降、细节丢失的问题, 提出并实现了一种基于物理驱动 GAN 的高鲁棒性重构框架. 该方法以成像物理模型为核心约束, 通过生成器与判别器的对抗优化, 从单次测量获得的一维光学编码信号中直接恢复高质量的二维边缘图像.

系统的数值仿真与近红外高光谱成像实验结果表明, 该方法在边缘清晰度、结构连续性及细节保真度方面均显著优于传统 LFSI 方法. 尤其在处理具有模糊边缘或灰度渐变结构的复杂目标时, 所提出的 GAN 框架能够有效抑制伪影与噪声, 获得锐利稳定的边缘轮廓. 更为重要的是, 该方法展现




图 4 细节恢复能力对比. 上图为真实物体 (左, 红色箭头标示出表面划痕) 及其采用传统 LFSI 方法得到的重构结果 (右); 下图为本文提出的 GAN 方法在不同学习率 (LR) 下的重构结果

Fig. 4. Comparison of detail recovery: top panel, real object (left, with red arrows indicating surface scratches) and its reconstruction using the traditional LFSI method (right); bottom panel, reconstructions using the proposed GAN method with different learning rates (LR).

出卓越的极限细节恢复能力, 成功重构出传统算法完全无法分辨的物体表面微小划痕, 验证了其在复杂测量条件下的高灵敏度与鲁棒性.

综上所述, 本研究提出的物理驱动 GAN 框架无需依赖大规模预训练数据集, 即可实现高保真度、高效率的单像素边缘重构. 其在细节恢复与噪声抑制方面的突破性表现, 为单像素成像技术在工业无损检测、材料表面缺陷分析等高精度细节感知领域的应用提供了新的可能, 也为推动计算成像向高分辨率、智能化方向发展奠定了重要基础. 依托快速、鲁棒的边缘提取能力, 该方法有望在自动化生产线的机器视觉系统中实现实时质量监控与精密装配指导, 从而提升生产过程的可靠性与智能化水平.

参考文献

- [1] Canny J 1986 *IEEE Trans. Pattern Anal. Mach. Intell.* **PAMI-8** 679
- [2] Marr D, Hildreth E 1980 *Proc. R. Soc. Lond. B* **207** 187
- [3] Torre V, Poggio T 1986 *IEEE Trans. Pattern Anal. Mach. Intell.* **PAMI-8** 147
- [4] Liu Y, Cheng M M, Hu X, Bian J W, Zhang L, Bai X, Tang J 2019 *IEEE Trans. Pattern Anal. Mach. Intell.* **41** 1939
- [5] He J, Zhang S, Yang M, Shan Y, Huang T 2022 *IEEE Trans. Pattern Anal. Mach. Intell.* **44** 100
- [6] Tang X, Yao X F, Dong Y, Zhang J M 2022 *Comput. Integr. Manuf. Syst.* **28** 2865 (in Chinese) [唐溪, 姚锡凡, 董艺, 张峻铭 2022 计算机集成制造系统 **28** 2865]
- [7] Wang X, Chen K, Su S, Lin Y, Du W, He Z 2025 *Precis. Eng.* **96** 329
- [8] Xie Z Q, He Y L, Wang P P, Su M Y, Chen X Y, Yang B, Liu J M, Zhou X X, Li Y, Chen S Q, Fan D Y 2020 *Acta Phys. Sin.* **69** 014101 (in Chinese) [谢智强, 贺炎亮, 王佩佩, 苏明扬, 陈学宇, 杨博, 刘俊敏, 周欣欣, 李颖, 陈书庆, 范点元 2020 物理学报 **69** 014101]
- [9] Li A, Nie Z T, Wang X E, Teng Z L, Wu Z H, Xiong W, Gao H 2025 *Opt. Electron. Eng.* **55** 250227 (in Chinese) [李安泽, 聂中天, 王兴儿, 滕志林, 吴泽辉, 熊伟, 高辉 2025 光电工程 **55** 250227]
- [10] Liu J, Yang Q, Zhou Y, Chen S, Shu W, Chen G, Wen S, Luo H 2024 *Phys. Rev. Lett.* **132** 043601
- [11] Jack B, Leach J, Romero J, et al. 2009 *Phys. Rev. Lett.* **103** 083602
- [12] Liu X F, Yao X R, Lan R M, Wang C, Zhai G J 2015 *Opt. Express* **23** 33802
- [13] Mao T, Chen Q, He W, Zou Y, Dai H, Gu G 2016 *IEEE Photon. J.* **8** 6900810
- [14] Ren H, Zhao S, Gruska J 2018 *Opt. Express* **26** 5501
- [15] Liu Y, Yu P, Hu X, et al. 2020 *Opt. Express* **45** 4028
- [16] Zhou L, Huang X, Fu Q, Zou X, Bai Y, Fu X 2021 *Chin. Opt. Lett.* **19** 121101
- [17] Ye Z, Zheng P, Hou W, Sheng D, Jin W, Liu H C, Xiong J 2022 *Opt. Lasers Eng.* **159** 107198
- [18] Ma M, Liang W, Zhong X, Deng H, Shi D, Wang Y, Xia M 2023 *Intell. Comput.* **2** 0050
- [19] Lyu M, Wang W, Wang H, Wang H, Li G, Chen N, Situ G 2017 *Sci. Rep.* **7** 17865
- [20] Wang F, Wang C, Chen M, Gong W, Zhang Y, Han S, Situ G 2022 *Light Sci. Appl.* **11** 1
- [21] Wang C H, Li H Z, Bie S H, Lv R B, Chen X H 2023 *Photonics* **10** 158
- [22] Ulyanov D, Vedaldi A, Lempitsky V 2020 *Int. J. Comput. Vis.* **128** 1867
- [23] Bie S H, Lv R B, Chen X H 2023 *Photonics* **10** 224
- [24] Mathai A, Mengdi L, Lau S, Guo N, Wang X 2022 *Photonic Sens.* **12** 220413
- [25] Wu H, Zhao G, Chen M, Cheng L, Xiao H, Xu L, Wang D, Liang J, Xu Y 2021 *Opt. Lasers Eng.* **140** 106529
- [26] Hu Y, Cheng Z, Fan X, et al. 2021 *Optik* **227** 166099
- [27] Hoshi I, Takehana M, Shimobaba T, Kakue T, Ito T 2022 *Appl. Opt.* **61** 7793
- [28] Wang X Y 2025 *M.S. Thesis* (Shenyang: Liaoning University) (in Chinese) [王晞颜 2025 硕士学位论文 (沈阳: 辽宁大学)]

Fourier single-pixel hyperspectral edge imaging based on an untrained neural network*

YI Dengli¹⁾ ZHANG Enrui²⁾ WANG Xiyan²⁾

MENG Shaoying²⁾ CHEN Xihao^{2)†}

¹⁾ (College of Mechanical and Power Engineering, Yingkou Institute of Technology, Yingkou 115014, China)


²⁾ (School of Physics, Liaoning University, Shenyang 110036, China)

(Received 18 January 2026; revised manuscript received 24 February 2026)

Abstract

High-precision edge detection plays a crucial role in surface defect identification and quality control in industrial manufacturing; however, conventional imaging methods remain limited in resolving microscale defects due to constraints in spatial resolution and signal-to-noise ratio. In this work, we propose a physics-prior-driven generative adversarial network-based near-infrared Fourier single-pixel hyperspectral edge imaging method. By

loading measurement bases with differential-operator structures onto a spatial light modulator, the spatial response of the Laplacian of Gaussian operator is embedded into the single-pixel modulation and detection process. This design enhances the sensitivity of single-pixel measurements to higher-order spatial intensity variations, amplifying edge-related high spatial frequency information at the data acquisition stage. On the reconstruction side, a generative adversarial network incorporating the single-pixel integral measurement model is developed, with physical consistency and spectral correlation constraints imposed during optimization. This framework enables the recovery of high-resolution two-dimensional edge images from bucket signals across 512 near-infrared spectral channels. Experimental results demonstrate that, under sparse sampling conditions, the proposed method significantly improves edge resolution and spectral fidelity compared with conventional reconstruction strategies, allowing reliable identification of microscale surface scratches that are difficult to resolve with traditional approaches. This work provides a new physics-data collaborative imaging paradigm for hyperspectral single-pixel imaging in applications such as material characterization, surface defect inspection, and precision metrology.



Keywords: single-pixel imaging, hyperspectral imaging, edge detection, generative adversarial network, physics-driven neural network, near-infrared imaging

DOI: [10.7498/aps.75.20260092](https://doi.org/10.7498/aps.75.20260092)

CSTR: [32037.14.aps.75.20260092](https://cstr.cn/32037.14.aps.75.20260092)

* Project supported by the Natural Science Foundation of Liaoning Province, China (Grant No. 2024-YKLH-15), the Open Research Fund of the National Key Laboratory of Intelligent Metallurgical Manufacturing Systems, China (Grant No. QZKF2024-12), the Internal Research Project of Liaoning Provincial Key Laboratory of Energy Storage and Energy Utilization Technology, China (Grant No. CNNK202504), and the Engineering Research Center for High-value Utilization of Magnesite of Liaoning Province, China (Grant No. LMNY2025020218).

† Corresponding author. E-mail: xi-haochen@163.com

基于非训练神经网络的傅里叶单像素高光谱边缘成像

仪登利 张恩睿 王晞颜 孟少英 陈希浩

Fourier single-pixel hyperspectral edge imaging based on an untrained neural network

YI Dengli ZHANG Enrui WANG Xiyao MENG Shaoying CHEN Xihao

引用信息 Citation: *Acta Physica Sinica*, 75, 120403 (2026) DOI: 10.7498/aps.75.20260092

CSTR: 32037.14.aps.75.20260092

在线阅读 View online: <https://doi.org/10.7498/aps.75.20260092>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn>

您可能感兴趣的其他文章

Articles you may be interested in

融合注意力机制的卷积网络单像素成像

Convolutional network single-pixel imaging with fusion attention mechanism

物理学报. 2025, 74(8): 084202 <https://doi.org/10.7498/aps.74.20250010>

生成对抗网络加速超分辨率超声定位显微成像方法研究

Accelerating super-resolution ultrasound localization microscopy using generative adversarial net

物理学报. 2022, 71(22): 224301 <https://doi.org/10.7498/aps.71.20220954>

基于自校验的单像素成像系统动态干扰去除方法

Dynamic occlusion removal in single-pixel imaging system based on self-check

物理学报. 2023, 72(3): 034201 <https://doi.org/10.7498/aps.72.20221918>

基于深度神经网络的时空编码磁共振成像超分辨率重建方法

Super-resolved reconstruction method for spatiotemporally encoded magnetic resonance imaging based on deep neural network

物理学报. 2022, 71(5): 058702 <https://doi.org/10.7498/aps.71.20211754>

基于有机-无机范德瓦耳斯异质结的自供电日盲光电探测及其单像素点光学成像

Self-powered solar-blind photodetector and single-pixel optical imaging based on organic-inorganic van der Waals heterojunctions

物理学报. 2026, 75(11): 058702 <https://doi.org/10.7498/aps.75.20251632>

结合虚拟单像素成像解卷积的双边照明光片荧光显微技术

Dual-sided illumination light-sheet fluorescence microscopy with virtual single-pixel imaging deconvolution

物理学报. 2022, 71(2): 028701 <https://doi.org/10.7498/aps.71.20211358>