

文章编号 1004-924X(2026)18-2872-19

Tikhonov 正则化结合深度去噪的 快照式关联成像重建

冒纯晔^{1,2,3}, 邵云天^{1,2,3}, 刘维涛^{1,2,3}, 王世勇^{1,2,3*}, 吴滢跃^{1,2,3}

(1. 中国科学院 上海技术物理研究所, 上海 200083;

2. 中国科学院 红外探测与成像技术重点实验室, 上海 200083;

3. 中国科学院大学, 北京 100049)

摘要:针对关联成像在实际场景中复杂噪声下难以兼顾结构恢复与噪声抑制的问题, 本文提出一种基于 Tikhonov 正则化与深度去噪相结合的两阶段快照式关联成像重建框架。第一阶段利用 Tikhonov 正则化求解关联成像逆问题, 通过正则化约束抑制病态性, 获得结构信息保持良好的稳定初始重建结果; 第二阶段, 本文在 Noise2VST 中引入基于成像物理的数据保真约束, 构建联合优化的自适应去噪模块。该模块利用方差稳定变换将复杂残余噪声映射为近似加性白高斯噪声, 并在自监督约束与物理数据保真约束的共同作用下实现自适应去噪, 从而在抑制残余噪声的同时有效保留图像细节与边缘结构。实验结果表明, 所提方法在不同采样条件下均具有良好的重建性能。在高采样条件下, 相较于 Tikhonov 方法, PSNR 提升 4.68 dB, SSIM 提升 0.375; 在低采样条件下, 仍保持较好的视觉质量和定量重建性能, 验证了方法的有效性与鲁棒性。

关键词: 关联成像; Tikhonov 正则化; 方差稳定变换; 图像重建

中图分类号: O431.2 **文献标识码:** A

doi: 10.37188/OPE.20263418.2872

CSTR: 32169.14.OPE.20263418.2872

Two-stage Tikhonov-deep denoising reconstruction for snapshot ghost imaging

MAO Chunye^{1,2,3}, SHAO Yuntian^{1,2,3}, LIU Weitao^{1,2,3}, WANG Shiyong^{1,2,3*}, WU Yingyue^{1,2,3}

(1. Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 200083, China;

2. Key Laboratory of Infrared Detection and Imaging Technology, Chinese Academy of Sciences,
Shanghai 200083, China;

3. University of Chinese Academy of Sciences, Beijing 100049, China)

* Corresponding author, E-mail: s_y_w@sina.com

Abstract: Ghost imaging is inevitably affected by complex noise in practical scenarios, making it difficult to simultaneously achieve structural recovery and noise suppression. To address this problem, this paper proposed a two-stage snapshot ghost imaging reconstruction framework combining Tikhonov regularization with deep denoising. In the first stage, Tikhonov regularization was employed to solve the inverse

收稿日期: 2026-04-14; 修订日期: 2026-06-02.

基金项目: 国家重点研发计划资助项目 (No. 2024YFB3614400)

problem of ghost imaging, where the regularization constraint suppressed ill-posedness to obtain a stable initial reconstruction with well-preserved structural information. In the second stage, a Noise2VST module incorporating a physics-based data-fidelity constraint was developed as an adaptive deep denoising module through joint optimization. The residual complex noise was first mapped into an approximately additive white Gaussian noise distribution via a variance-stabilizing transform. Adaptive denoising was then performed under the joint constraints of self-supervision and a physics-based data-fidelity constraint, effectively removing residual noise while preserving image details and edge structures. Experimental results demonstrate that the proposed method consistently achieves favorable reconstruction performance under different sampling conditions. Under high-sampling conditions, compared with the Tikhonov method, the proposed method improves PSNR by 4.68 dB and SSIM by 0.375. Under lower-sampling conditions, it maintains competitive visual quality and quantitative performance, demonstrating its effectiveness and robustness.

Key words: ghost imaging; Tikhonov regularization; Variance-Stabilizing Transform (VST); image reconstruction

1 引言

自 1995 年 Pittman 等^[1]利用量子纠缠光子对完成关联成像实验以来,该技术快速发展,从量子关联成像扩展到经典热光关联成像和计算关联成像等形式^[2-3]。关联成像适用于浑浊介质、散射介质等复杂成像场景^[4],在水下成像^[5]、激光雷达^[6]、图像加密通信^[7]、医学成像^[8]等领域具有应用潜力。

关联成像技术由前端成像模块和后端解算模块两部分组成。在重构算法层面,现有方案主要分为两类,分别是基于先验正则化优化方法及基于深度学习的方法。其中,基于先验正则化优化常引入如平滑、稀疏、非局部等先验^[9]约束抑制重构过程中的噪声干扰,提升解的稳定性,对应的算法包括正交匹配追踪(Orthogonal Matching Pursuit, OMP)算法^[10]、两步迭代收缩阈值(Two-step Iterative Shrinkage/Thresholding, TwIST)算法^[11]、交替方向乘子法(Alternating Direction Method of Multipliers, ADMM)和广义交替投影(Generalized Alternating Projection, GAP)算法^[12]等。先验优化的方法数理可解释性强,但是在复杂噪声场景中重构精度和噪声抑制方面难以取得较好的平衡。

基于深度学习的方法主要分为端到端式(End-to-end)与即插即用式(Plug-and-Play, PnP),端到端的方法通过大量“测量-真值”样本对学习从测量图到真实图的映射,重构图像质量

较优^[13-14],但依赖大量数据训练。且训练好的模型通常只适用于特定场景,泛化能力有限^[15]。同时,端到端的过程是一个黑盒,可解释性相对不足^[16]。而即插即用框架将迭代优化与网络先验模型融合,其核心思想是在迭代优化过程中引入通用图像去噪器作为隐式先验,从而在不显式构造正则项的情况下提升图像重建质量^[17]。与端到端相比,PnP 可解释性更强,并减少对关联成像专属训练数据的依赖。然而,PnP 方法通常需要在每次迭代过程中反复调用图像去噪器,其重建性能对去噪强度等参数较为敏感。在多次迭代去噪的情况下,若去噪强度设置不当,容易导致目标纹理与边缘细节被过度平滑,从而造成有效信息损失,影响最终的重建精度^[18-19]。

为解决复杂噪声抑制与成对训练数据依赖问题,本文将 Tikhonov 正则化重建^[20]与 Noise2VST 深度去噪^[21]相结合,并在其单图自监督优化过程中引入测量域物理数据保真约束。该方法利用盲点自监督损失与物理数据保真项联合优化 VST 参数,无需真值配对即可实现复杂残余噪声的自适应抑制。

2 系统模型

本文研究的关联成像系统基于一种快照式线性空间不变(Linear Shift-Invariant, LSI)光学系统。如图 1 所示,该光学系统的前端成像模块由前置成像镜头、散射片及 CCD 探测器组成。




图 1 快照式 LSI 光学系统

Fig. 1 Snapshot LSI optical system

光源采用宽带白光照明,光线经目标调制后进入成像镜头,经视场光阑传播至散射片。散射片对入射光场进行调制,使光场在 CCD 探测平面形成散斑图案。

在该光学系统中,散射片等效为光瞳调制元件,将目标的空间信息编码为散斑形式,使每个探测像素均包含来自不同空间位置的信息,实现信息的空间扩散。通过选取部分探测像素并结合重建算法,即可恢复目标图像。后端解算模块在计算机中实现,对测量散斑进行计算重建获得最终成像结果。由于系统具有线性空不变性质,其成像过程可以表示为:

$$Y = h * X, \quad (1)$$

其中: X 为待恢复的真实视场图像, Y 为系统测量图像, h 表示系统的单位冲激响应(即点扩散函数 PSF), $*$ 表示二维卷积运算。为了方便数值计算,上述卷积模型可以转换为矩阵的形式:

$$y = Ax, \quad (2)$$

其中: $A \in R^{M \times N}$ 是系统测量矩阵, x 和 y 分别为图像 X 与 Y 的向量化表示。实际应用中,为了降低计算量与存储开销,通常会对测量矩阵 A 和测量向量 y 进行降采样处理。

考虑到实际成像系统中各种噪声的影响,测量模型可进一步表示为:

$$y = Ax + n, \quad (3)$$

其中, n 表示系统测量过程中引入的噪声项。

测量矩阵 A 基于系统点扩散函数(Point Spread Function, PSF)构建。设 PSF 图像为 $h \in R^{h_{psf} \times w_{psf}}$,以其中心为参考,定义大小为 $h_c \times w_c$ 的滑动窗口,在 PSF 图像上进行逐点平移,得到局部子图 $S_{i,j}$ 。对每个子图进行降采样操作,记为:

$$v_{i,j} = D(S_{i,j}), \quad (4)$$

其中, $D(\cdot)$ 表示降采样算子。将所有位置对应的向量 $v_{i,j}$ 按列排列,即可构成测量矩阵:

$$A = [v_1, v_2, \dots, v_N], \quad (5)$$

其中, N 为滑动窗口的位置总数。

3 基于 Tikhonov-Noise2VST 快照关联重建去噪算法

在实际成像系统中,测量数据易受噪声干扰,而图像重建又是一个病态的逆问题,因此噪声会加剧重建结果的不稳定性。为了获得稳定可靠的重建结果,通常需要在求解过程中引入约束。其中,Tikhonov 正则化是一种基于图像平滑先验的经典正则化方法,通过二范数约束来抑制噪声对重建结果的影响。其求解的问题是:

$$x_{\min} = \arg\min_x (\|Ax - y\|_2^2 + \lambda \|x\|_2^2), \quad (6)$$

其中:第一项是数据保真项,用于约束重建结果与测量数据的一致性,第二项是 L_2 正则项, $\arg\min$ 为求解最小化问题的过程, λ 为正则化参数, $\|\cdot\|$ 代表二范数算子。

对(6)式中的目标函数关于 x 求梯度并令其等于0,可以得到 x 的闭式解:

$$x_0 = (A^T A + \lambda I)^{-1} A^T y. \quad (7)$$

在实际场景的关联成像系统中,由于探测器噪声、环境光干扰以及低采样率等因素的影响,仅通过 Tikhonov 正则化后得到的 x_0 仍存在一定噪声。此外,Tikhonov 正则化本质上是基于 L_2 范数的线性正则化,对高斯噪声有效,但对实际系统中的泊松噪声、读出噪声等非高斯混合噪声抑制能力有限,易产生伪影。因此,本文提出一种“Tikhonov 重建+深度去噪”的框架,结合传统方法的稳定性与深度学习的强大噪声建模能力。

为实现上述框架,去噪模块的选择至关重要。考虑到实际系统中噪声统计特性未知且可能随数据变化,本文选用了自监督去噪方法 Noise2VST^[21]作为核心去噪模块。该方法无需干净的真值图像进行监督训练,能直接从单次带噪观测中自适应地学习噪声模型并进行抑制。

3.1 可学习方差稳定变换

Noise2VST 的核心思想是通过学习一个参数化的方差稳定变换(Variance-Stabilizing Transform, VST) $f_\theta: \mathbf{R} \rightarrow \mathbf{R}$, VST 变换采用 N 个节点单调分段线性样条实现:依据单张输入图像像素区间 $[z_{\min}, z_{\max}]$,均匀划分 N 个横坐标锚点,而对应的 N 个 y 则决定了样条的形态,但 y 不作为直接优化变量,模型以隐式参数 θ 作为可学习量,通过指数重参数化与累积和运算生成严格单调递增的样条纵坐标 y 。对应关系为:

$$\begin{cases} y_0 = \theta_0 \\ y_k = y_{k-1} + e^{\theta_k} + \epsilon, k = 1, 2, \dots, N-1 \end{cases}, (8)$$

其中, $\epsilon = 10^{-6}$ 为数值稳定项。该构造方式天然保证 y 严格递增,是 VST 变换可逆的先决条件。

正向 VST 通过分段线性插值完成像素级灰度映射,将信号相关的复杂噪声调整为近似方差稳定的高斯噪声。逆变换引入可学习仿射补偿参数 α 和 β ,以校正值域偏移和系统偏差。训练初始阶段将 VST 设置为恒等映射,以避免破坏输入图像的初始统计特性。图 2 给出了 VST 的初始与训练后映射曲线。其中红色虚线表示初始恒等映射,蓝色实线为训练后的非线性映射曲线(彩图见期刊电子版)。




图 2 VST 变换曲线示意图

Fig. 2 Mapping curve of VST

为实现 VST 变换后的高斯去噪过程,本文引入两个经典的预训练 CNN 去噪网络作为固定图像先验:FFDNet^[22]与 DRUNet^[23]。在本文所提算法框架中,FFDNet 用于 Noise2VST 训练阶段提供去噪先验,DRUNet 则用于推理阶段生成最终重建结果。两个网络在实验中均保持预训练权重不变,仅作为固定先验使用。

3.2 自监督训练机制

设观测图像为 $z \in \mathbf{R}^N$,其对应的无噪信号为 s ,由于成像噪声与信号强度耦合,可建立如下观测模型:

$$z_i = s_i + \epsilon_i(s_i), (9)$$

其中,噪声 ϵ_i 的统计特性依赖于信号强度 s_i ,属于非高斯信号相关噪声。为消除噪声对信号强度的依赖性,Noise2VST 通过迭代优化 θ, α, β 更新样条折线形态,实现方差稳定映射:

$$\tilde{z} = f_\theta(z). (10)$$

变换后,噪声被归一化为方差近似一致的高斯噪声:

$$\tilde{z}_i \approx \tilde{s}_i + n_i, n_i \sim N(0, \sigma^2). (11)$$

在该变换域中,引入高斯去噪器 $D(\cdot)$ 对信号进行恢复,并通过带补偿的逆变换 $f_{\theta, \alpha, \beta}^{-1}$ 映射回原空间,得到最终估计:

$$\hat{s} = (f_{\theta, \alpha, \beta}^{-1} \circ D \circ f_\theta)(z). (12)$$

由于真实信号 s 无法获得,Noise2VST 采用盲点策略构造自监督训练目标。通过引入盲点去噪器 $\bar{D}$,输出在每个像素位置 i 都不依赖于输入的对应该像素 z_i ,在该条件下,有如下关系成立^[24]:

$$E \| \bar{D}(z) - z \|_2^2 = E \| \bar{D}(z) - s \|_2^2 + \text{const}. (13)$$

从而可以通过构建自监督损失:

$$\mathcal{L}_{\text{self}}(\theta, \alpha, \beta) = \left\| (f_{\theta, \alpha, \beta}^{-1} \circ \bar{D} \circ f_\theta)(z) - z \right\|_2^2. (14)$$

该损失越小,表明去噪器 $\bar{D}$ 在变换域中的去噪效果越好,即 $f_\theta(z)$ 越接近满足高斯去噪器的输入假设。

盲点约束的具体实现采用固定的 3×3 Donut 环形卷积核:

$$\begin{bmatrix} 0 & 0.25 & 0 \\ 0.25 & 0 & 0.25 \\ 0 & 0.25 & 0 \end{bmatrix}, (15)$$

中心权重置为 0,仅保留上下左右四个领域均值,

卷积参数固定不训练。训练过程中设置掩码步长 $\text{stride}=4$, 按间隔生成掩码区域, 掩码位置像素全部替换为 Donut 卷积输出的邻域均值, 从而使该位置像素信息被遮挡, 实现盲点输入构造。基于上述掩码规则改造 FFDNet 得到训练用盲点去噪器 $\bar{D}$ 。在推理阶段移除全部掩码, 取消像素遮挡, 更换性能更优的 DRUNet 去噪器 D 完成全像素去噪:

$$\hat{s} = (f_{\theta, \alpha, \beta}^{-1} \circ D \circ f_{\theta})(z). \quad (16)$$

3.3 基于成像物理的数据保真约束

原始 Noise2VST 仅依赖单幅输入图像的像素统计特性, 通过盲点自监督损失学习方差稳定变换及其补偿参数, 其优化目标中未显式引入关联成像的前向测量模型。若将其直接作为 Tikhonov 初始重建结果的后置去噪模块, 虽然能够抑制残余噪声, 但最终去噪结果可能偏离实际测量数据所对应的关联成像模型。

为此, 本文在保持 Noise2VST 中可学习 VST、盲点掩码及预训练去噪先验主体结构不变的基础上, 在单图自监督优化过程中引入基于成像物理的数据保真约束。设 Tikhonov 初始重建结果为 x_0 , 经 Noise2VST 处理后得到最终重建结果 $\hat{x}$ 。根据第 2 节建立的关联成像前向测量模型, 如式(3)所示, $\hat{x}$ 对应的预测测量为 $A\hat{x}$ 。因此, 本文以预测测量与实际观测数据 y 之间的归一化残差构建测量域数据保真损失:

$$\mathcal{L}_{\text{phy}} = \frac{\|A\hat{x} - y\|_2^2}{\|y\|_2^2}, \quad (17)$$

其中: $\hat{x} = (f_{\theta, \alpha, \beta}^{-1} \circ \bar{D} \circ f_{\theta})(x_0)$ 。 $\mathcal{L}_{\text{phy}}$ 本质上是对输出图像施加的数据保真约束, 也可视为前向一致性约束。即, 若最终重建结果符合关联成像的物理测量过程, 则其经前向算子 A 投影后应与实测数据 y 保持一致。

进一步地, 本文将该物理数据保真项与原始 Noise2VST 的盲点自监督损失联合优化, 构造总损失函数:

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{self}} + \lambda_{\text{phy}} \mathcal{L}_{\text{phy}}, \quad (18)$$

其中: $\mathcal{L}_{\text{self}}$ 用于在无真值条件下学习噪声自适应的 VST 映射, λ_{phy} 为物理数据保真项的权重系数, $\mathcal{L}_{\text{phy}}$ 用于限制去噪结果偏离关联成像前向测量模型。需要说明的是, 式(17)与 Tikhonov 初始

重建阶段的数据保真项具有相同的物理依据, 但其直接作用于 Noise2VST 去噪后的最终输出 $\hat{x}$, 从而保证后续自监督去噪过程仍与实际观测数据保持一致。所提算法简称为 TP-N2VST (Tikhonov-guided Physics-constrained Noise2VST)。算法流程如表 1 所示。

表 1 TP-N2VST 算法

Tab. 1 TP-N2VST algorithm

Input: measured values $y \in \mathbb{R}^{M \times 1}$

Sampling matrix $A \in \mathbb{R}^{M \times N}$

off-the-shelf classical and blind-spot Gaussian denoisers D and $\bar{D}$, respectively

Stage 1: Tikhonov Reconstruction

$$x_0 = (A^T A + \lambda I)^{-1} A^T y$$

Stage 2: Noise2VST Denoising

(1) Training stage

Set α, β to 0, and θ such that f_{θ} is the identity function.

While not converged, do:

Update f_{θ} and $f_{\theta, \alpha, \beta}^{-1}$ so as to minimize the loss

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{self}} + \lambda_{\text{phy}} \mathcal{L}_{\text{phy}}$$

$$\text{where, } \mathcal{L}_{\text{self}}(x_0, A, y) = \left\| (f_{\theta, \alpha, \beta}^{-1} \circ \bar{D} \circ f_{\theta})(x_0) - x_0 \right\|_2^2,$$

$$\mathcal{L}_{\text{phy}} = \frac{\left\| A(f_{\theta, \alpha, \beta}^{-1} \circ \bar{D} \circ f_{\theta})(x_0) - y \right\|_2^2}{\|y\|_2^2}$$

(2) Inference stage

$$\hat{x} = (f_{\theta, \alpha, \beta}^{-1} \circ D \circ f_{\theta})(x_0)$$

Output: Final reconstructed image $\hat{x} \in \mathbb{R}^{N \times 1}$

4 实验与分析

为验证所提方法的性能, 本文设计了系统的对比实验。本文选取了四种重建算法进行对比, 包括基于稀疏正则化方法 (Orthogonal Matching Pursuit, OMP)、基于全变分正则化方法 (Total Variation Augmented Lagrangian Alternating Direction Algorithm, TVAL3)、基于全变分和非局部稀疏联合优化方法 (Total Variation and Non-Local Sparsity, TVNLS)、基于即插即用的交替方向乘子法 PnP-ADMM (去噪器采用 DRUNet)。此外, 为验证 TP-N2VST 的优越性, 本文同时进行了一项消融实验: 分别仅使用 Tikhonov, 以及分别加上 DRUNet, Noise2VST,

Physics Noise2VST 三种去噪模块,对比这四种方法的结果。实验验证将从两方面展开:仿真实验将采用峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)和结构相似性(Structural Similarity Index Measure, SSIM)等定量指标,评估算法的重建精度;真实数据实验则旨在定性地检验本方法在实际复杂噪声场景下的适用性与鲁棒性。

实验系统结构如图 1 所示。实验中采用均匀发光板产生的宽带白光作为光源,并以特定尺寸的点靶标作为成像目标,用于获取系统的点扩散函数(PSF)。为保证点靶标在 CCD 成像面上恰好对应一个像素,其直径 l 需满足以下几何关系:

$$l = \frac{l_0 d_1}{d_2}, \quad (19)$$

其中: l_0 为 CCD 单个像元(像元为正方形)的边长, d_1 为点光源到散射片的距离, d_2 为散射片到 CCD 的距离。通过该系统获取的点靶标散斑图像如图 3 所示。本文将该图像作为系统点扩散函数(PSF),其尺寸为 2048×2448 。后续即可以根据该 PSF 构造系统真实的测量矩阵 A 进行存储。




图 3 PSF 散斑图

Fig. 3 PSF speckle image

实验参数设置:

(1) VST 训练参数设置:

逆变换修正系数 α 与 β 初始设置为 0, f_0 初始为恒等变换。VST 结点 N 设置为 128。优化器使用 Adam 优化器,初始学习率 $lr=0.01$,调度器为 StepLR(step=iteration/3, $\gamma=0.1$),仿真实验迭代总步数 500、真实实验迭代总步数 1 000。

(2) Tikhonov 参数 λ 选择:

Tikhonov 正则化参数 λ 在对数区间均匀遍

历候选值,结合重建残差 $\|Ax - y\|_2$ 与解的平滑度择优选择。在本文中,仿真场景噪声成分简单,所需正则约束偏弱,取 $\lambda=1$;真实实验噪声复杂,为抑制噪声伪影、提升解稳定性,取 $\lambda=10^7$ 。

(3) 物理损失参数 λ_{phy} 选择:

λ_{phy} 在对数区间均匀遍历候选值,常规无噪仿真实验中 λ_{phy} 取 0.01,带噪仿真实验中 λ_{phy} 取 100。不同实验设置下的参数在对应实验中保持固定。

实验硬件环境:MECHREVO jiguangX Series GM6AQ7C 笔记本电脑,处理器为 i7-12800HX,运存 16 G,显卡为 RTX 4070Laptop GPU。

4.1 仿真实验

本节通过仿真实验验证所提方法的有效性。仿真中所用的测量矩阵 A 基于真实光学系统的 PSF 构建,即采用图 3 所示的实测 PSF。具体构造过程如下:首先,选取固定尺寸为 $h_c = 3/5 h_{\text{psf}}$, $w_c = 3/5 w_{\text{psf}}$ 的滑动窗口对 PSF 图像进行分块。然后,在每个子图像内沿行方向和列方向进行等间距降采样,以构造不同采样率下的测量矩阵 A 。仿真测试了 $1/18^2$, $1/24^2$, $1/30^2$, $1/36^2$, $1/42^2$, $1/48^2$ 六种采样率,其中采样率 $1/n^2$ 表示在子图像的行、列方向上每隔 n 像素取一个采样点。实验选用 100×100 pixels 大小的标准灰度图“house”和“靶标”图作为目标图像 x ,测量图像即为 $y = Ax$ 。分别使用不同方法在不同采样下进行重建去噪,比较重建图像 PSNR/SSIM 以证明本文方法的有效性。图 4 展示了“house”在不同方法下的实验结果。

由图 4 可见,OMP 方法能大致呈现房屋主体轮廓与部分细节,但重建结果存在明显的伪影与噪声。TVAL3 与 TVNLS 方法的正则化先验约束较强,重建图像过度平滑,大量细节丢失。PnP-ADMM(DRUNet)方法在保证轮廓清晰的同时恢复更多结构信息。Tikhonov 方法能够较为完整地重建图像并保留较多细节,但图像中仍残留噪声。Tikhonov+DRUNet 方法在各个采样率下有效抑制了噪声,但在一定程度上模糊了部分精细结构。相比之下,TP-N2VST 方法在去噪与细节保留之间实现了平衡,相较于 Tikhonov+DRUNet,保留了烟囱、屋檐等细节,为更直观地对比两者差异,图 5 对图




图4 “house”在不同方法下的重建结果

Fig. 4 Results of "house" under different methods

4中 $1/18^2$ 采样率对应结果的红框标注局部子图进行放大展示, TP-N2VST 在细节上表现更优

(彩图见期刊电子版)。表2展示了“house”在不同方法及采样率下的 PSNR 与 SSIM。由表2可

知,所提方法在不同采样率设置下均取得最高的 PSNR,其中最高值为 28.34 dB。在 6 组设置中的 5 组取得最高 SSIM(表 2 中加粗和下划线分别表示最优和次优结果)。




图 5 不同方法下“house”图像的重建细节

Fig. 5 Reconstruction details of the “house” image obtained using different methods.

表 2 不同方法和采样率下“house”图像的 PSNR/SSIM 对比

Tab. 2 PSNR/SSIM comparison of different methods on the “house” image at different sampling rates						
Sampling rate	1/18 ²	1/24 ²	1/30 ²	1/36 ²	1/42 ²	1/48 ²
OMP	9.66/0.269 7	9.66/0.280 4	9.71/0.277 5	9.75/0.243 0	9.59/0.250 5	9.79/0.265 4
TVAL3	15.21/0.425 3	14.89/0.422 5	15.36/0.418 3	15.45/0.403 3	15.65/0.386 4	16.01/0.386 7
TVNLS	14.49/0.482 8	14.54/0.455 6	14.71/0.435 8	14.56/0.424 6	14.63/0.415 8	14.91/0.418 0
PnP-ADMM	18.78/0.373 9	17.56/0.399 6	17.22/0.412 1	16.94/0.384 4	16.88/0.389 5	16.87/0.362 9
Tikhonov	23.66/0.543 8	22.09/0.454 2	21.59/0.433 4	21.93/0.423 3	21.46/0.407 6	20.66/0.375 5
Tikhonov+DRUNet	27.42/0.889 6	25.30/0.798 9	23.23/0.732 7	23.13/0.699 2	22.53/0.674 9	21.73/0.653 2
Tikhonov+Noise2VST	28.20/0.917 1	25.77/0.820 4	23.59/0.755 6	23.58/0.722 7	22.87/0.691 9	21.87/0.660 8
TP-N2VST	28.34/0.918 5	25.78/0.820 7	23.67/0.756 4	23.61/0.723 3	22.89/0.692 7	21.92/0.653 5

Note: Bold and underlined values indicate the best and second-best results, respectively.

图 6 展示了“靶标”在不同方法及采样率下的重建对比,OMP 算法能分辨出各类三靶结构,但背景噪声严重,数字无法分辨。TVAL3 与 TVNLS 方法降低了背景噪声,但存在过度平滑的问题。PnP-ADMM(DRUNet)方法能够较好地分离背景与目标,但细节分辨能力仍不足。Tikhonov 方法能还原靶标结构,但仍存在较多噪点。Tikhonov+DRUNet 方法整体上能够较好地还原图像细节,不过在较低采样率下,观察到数字区域存在伪影。相比之下,本文提出的 TP-N2VST 方法去除了这类伪影。图 7 对图 6 中 1/18² 采样率对应结果的红框标注局部子图进行放大展示。表 3 给出了靶标在不同方法及采样率下的 PSNR 与 SSIM 量化指标。如表 3 所示,在 6 组采样率设置中,TP-N2VST 在 4 组设置下取得最高 PSNR,在其余 2 组设置下与最优结果的差异均小于 0.03 dB。同时,在全部设置下取得最优或并列最优的 SSIM。

为考察物理数据保真项的贡献,本文进一步

比较 Tikhonov+Noise2VST 与 TP-N2VST。两种方法采用相同的 Tikhonov 初始重建、VST 结构、盲点自监督策略、预训练去噪先验及优化参数,唯一差异在于是否加入测量域物理数据保真项。如表 2 和表 3 所示,加入物理约束后,多数采样条件下的 PSNR 或 SSIM 有所提升,例如在 1/18² 采样率下,引入物理约束后“靶标”图像的 PSNR/SSIM 提升了 0.4 dB/0.0057。

表 2 和表 3 中部分数据随采样率下降呈非单调趋势,主要源于两类原因:一是 OMP、TVAL3、TVNLS 等传统方法依赖固定稀疏/全变分先验,其先验与场景特征适配性较差,采样率变化时难以稳定恢复结构。二是纯 Tikhonov 与 PnP-ADMM 分别受全局 L2 平滑约束和去噪参数敏感性的影响,在特定采样条件下会出现指标波动。

此外,相较于 Tikhonov+DRUNet, TP-N2VST 除在 PSNR/SSIM 指标上表现出优势外,在图像伪影抑制方面也具有更好的性能。为




图6 “靶标”在不同方法的重建结果

Fig. 6 Results of "usaf" under different methods

定量评价该感知质量差异,本文引入 LPIPS (Learned Perceptual Image Patch Similarity) 指标

衡量该感知质量差异,LPIPS取值[0,1],数值越小表示重建图像与真实图像越接近。表4给出了




图 7 不同方法下“靶标”图像的重建细节

Fig. 7 Reconstruction details of the “usaf” image obtained using different methods.

表 3 不同方法和采样率下“靶标”图像的 PSNR/SSIM 对比						
Tab. 3 PSNR/SSIM comparison of different methods on the “usaf” image at different sampling rates.						
Sampling rate	1/18 ²	1/24 ²	1/30 ²	1/36 ²	1/42 ²	1/48 ²
OMP	3.53/0.095 0	3.50/0.091 8	3.56/0.096 6	3.47/0.080 7	3.64/0.090 5	3.49/0.088 8
TVAL3	8.81/0.214 8	8.06/0.184 5	8.44/0.194 1	8.55/0.193 6	8.61/0.201 2	7.78/0.173 7
TVNLS	10.23/0.341 2	10.25/0.335 7	10.21/0.332 8	10.17/0.331 9	10.21/0.338 2	10.01/0.314 1
PnP-ADMM	8.53/0.228 0	8.36/0.227 0	7.77/0.202 0	7.45/0.181 6	6.88/0.167 2	6.93/0.158 9
Tikhonov	9.38/0.492 4	7.98/0.362 1	8.45/0.317 3	7.93/0.272 9	8.47/0.256 1	8.19/0.221 4
Tikhonov+DRUNet	20.12/0.921 7	15.31/0.780 7	13.27/0.648 3	12.39/0.572 3	<u>11.75/0.510 3</u>	<u>11.10/0.408 6</u>
Tikhonov+Noise2VST	<u>20.62/0.925 2</u>	15.74/0.794 1	<u>13.44/0.659 5</u>	<u>12.51/0.576 6</u>	11.69/0.499 1	10.98/0.398 5
TP-N2VST	21.02/0.930 9	<u>15.71/0.794 1</u>	<u>13.43/0.660 6</u>	12.53/0.583 9	11.81/0.520 7	11.12/0.414 3

两种方法在不同采样率下的 LPIPS 对比结果。可见 TP-N2VST 在所有采样率下均稳定优于 Tikhonov+DRUNet,验证了其在抑制伪影、保持结构方面的感知优势。

为进一步验证所提方法在噪声干扰条件下的重建鲁棒性,在测量域叠加高斯-泊松复合噪声开展仿真实验。泊松噪声采用信号相关建模方式,其方差在测量均值处设为 0.05,同时叠加均值为零、标准差为 0.05 的加性高斯噪声。对于同一测试图像和采样间隔,所有对比方法均采用完全相同的固定带噪测量数据进行重建。

表 4 两种方法 LPIPS 对比		
Tab. 4 LPIPS comparison between the two methods		
Sampling rate	TP-N2VST	Tikhonov+DRUNet
1/18 ²	0.059 7	0.071 7
1/24 ²	0.233 4	0.243 4
1/30 ²	0.375 3	0.397 0
1/36 ²	0.432 3	0.475 4
1/42 ²	0.521 5	0.538 8
1/48 ²	0.608 7	0.645 0

表 5 和表 6 分别给出了“house”和“靶标”图像在带噪条件下的定量对比结果。

表 5 “house”在带噪条件下的重建结果对比						
Tab. 5 Reconstruction results of “house” under noisy conditions						
Sampling rate	1/18 ²	1/24 ²	1/30 ²	1/36 ²	1/42 ²	1/48 ²
OMP	9.56/0.276 3	9.55/0.252 5	9.63/0.218 3	9.42/0.225 9	9.47/0.213 0	9.43/0.215 4
TVAL3	16.72/0.422 9	15.26/0.411 4	15.35/0.417 2	16.66/0.399 9	15.56/0.404 7	15.68/0.396 1
TVNLS	13.74/0.451 0	13.61/0.450 5	13.91/0.455 6	14.09/0.440 0	14.05/0.452 2	14.37/0.441 2
PnP-ADMM	17.45/0.398 0	15.74/0.420 8	15.50/0.444 1	15.35/0.414 3	15.44/0.426 2	15.57/0.408 9
Tikhonov	20.31/0.322 5	19.93/0.329 0	20.05/0.333 0	20.07/0.317 8	19.96/0.332 4	19.55/0.317 0
Tikhonov+DRUNet	23.40/0.710 3	22.13/0.683 6	21.75/0.649 8	<u>21.48/0.615 1</u>	<u>20.98/0.598 8</u>	<u>20.55/0.583 6</u>
Tikhonov+Noise2VST	<u>23.61/0.719 9</u>	22.29/0.689 9	<u>21.83/0.636 1</u>	<u>21.48/0.584 9</u>	20.96/0.566 3	20.42/0.539 0
TP-N2VST	23.70/0.721 9	<u>22.82/0.687 6</u>	21.90/0.651 7	21.64/0.615 3	21.18/0.599 7	20.79/0.587 2

表 6 “靶标”在带噪条件下的重建结果对比

Tab. 6 Reconstruction results of “usaf” under noisy conditions

Sampling rate	1/18 ²	1/24 ²	1/30 ²	1/36 ²	1/42 ²	1/48 ²
OMP	7.81/0.108 4	7.71/0.099 6	7.82/0.114 7	7.87/0.101 5	7.86/0.088 7	7.84/0.088 2
TVAL3	<u>11.11</u> /0.337 0	11.41 /0.280 1	<u>10.95</u> /0.333 4	11.21 /0.328 0	11.44 /0.320 4	11.18 /0.320 5
TVNLS	10.39/0.298 9	10.35/0.302 9	10.50/0.296 3	10.53/0.295 8	10.73/0.301 0	10.59/0.297 3
PnP-ADMM	9.69/0.237 7	9.71/0.246 6	9.56/0.232 3	9.38/0.222 4	9.28/0.223 5	9.13/0.218 6
Tikhonov	9.97/0.372 2	9.66/0.303 2	9.21/0.274 3	9.16/0.244 4	8.41/0.224 1	8.77/0.203 0
Tikhonov+DRUNet	10.08/0.561 7	9.66/0.465 7	9.25/ <u>0.430 3</u>	9.18/ <u>0.388 9</u>	8.43/ <u>0.362 5</u>	8.78/ <u>0.324 7</u>
Tikhonov+Noise2VST	10.13/ <u>0.567 3</u>	9.74/ <u>0.473 6</u>	9.30/0.423 6	9.23/0.382 6	8.48/0.343 6	8.84/0.312 9
TP-N2VST	12.24 /0.594 0	11.11 /0.484 4	11.15 /0.453 8	<u>10.76</u> /0.405 6	<u>10.69</u> /0.391 9	<u>10.40</u> /0.347 6

对于“house”图像,TP-N2VST在全部采样条件下均取得最高的PSNR,并在5个采样条件下取得最高的SSIM。仅在采样条件1/24²下,Tikhonov+Noise2VST的SSIM略高于TP-N2VST。总体来看,TP-N2VST在带噪条件下表现出更好的重建精度和较稳定的结构保持能力。

对于“靶标”图像,TP-N2VST在全部采样条件下均取得最高的SSIM,表明其在密集条纹和高频边缘结构保持方面具有较好的稳定性。相较于Tikhonov+Noise2VST,TP-N2VST在所有采样条件下均取得更高的PSNR和SSIM,其中PSNR提升1.37~2.21 dB。尽管TVAL3在部分采样条件下获得了更高的PSNR,但其SSIM始终低于TP-N2VST,说明TP-N2VST在结构恢复和细节保持方面具有优势。

综合两幅测试图像的结果,TP-N2VST在带噪条件下表现出较好的重建性能。对于“house”图像,TP-N2VST在全部采样条件下取得最高PSNR,并在大多数条件下取得最高SSIM。对于“靶标”图像,TP-N2VST在全部采样条件下均取得最高SSIM,且相较于Tikhonov+Noise2VST始终具有更高的PSNR和SSIM。上述结果表明,测量域物理数据保真约束能够有效增强复杂噪声条件下的结构恢复能力和重建稳定性。

4.2 算法特性与定量分析

为定量验证所提算法的理论特性,本节从自适应建模能力、算法收敛性及重构误差界三个维度对TP-N2VST展开系统分析。其中,Noise2VST的自适应建模能力通过学习到的VST变换及其逆变换曲线、变换前后残差的统计

分布,以及残差方差与信号强度的相关性进行评估。

4.2.1 方差稳定性分析

此外,为定量衡量VST的方差稳定化效果,本文定义方差稳定性指标(Variance Stabilization Quality, VSQ)。将真值图像的像素强度均匀划分为 n 个区间,计算每个区间内残差的局部方差并记为 $\{\sigma_i^2\}_{i=1}^n$,令 μ 为全部局部方差的均值,MAD为各个局部方差相对于 μ 的平均绝对偏离, Δx 为区间划分宽度,其中平均绝对偏离满足公式:

$$MAD = \frac{1}{n} \sum_{i=1}^n |\sigma_i^2 - \mu|. \quad (20)$$

最终方差稳定性指标定义为:

$$VSQ = \frac{\mu \times MAD}{\Delta x}. \quad (21)$$

该指标同时反映局部方差的整体水平与平坦程度,除以区间宽度 Δx 能够消除分箱粒度对计算结果的影响。VSQ数值越小,则说明不同信号强度下的噪声方差越接近、整体噪声水平越低,代表方差越稳定。图8以“靶标”在采样率1/30²下的仿真重建实验为例,定量展示Noise2VST的自适应建模能力。

图8(a)~8(b)各给出训练习得的前向VST曲线 f_θ 及其补偿逆变换 $f_{\theta,a,\beta}^{-1}$,可见样条参数已根据测量数据完成自适应调整。图8(c)对比了变换前后残差的概率分布:Raw域残差标准差为0.271,经VST映射后降至0.177;分布范围从1.471缩减至0.995,表明VST对残差的数值分布和动态范围进行了重整,将信号依赖的非高斯噪声转化为近似零均值高斯噪声,满足了经典高




图 8 Noise2VST 自适应建模能力定量分析

Fig. 8 Quantitative analysis of the adaptive modeling capability of Noise2VST

斯去噪器的前提假设。图 8(d)进一步通过“方差-信号强度”关系验证 VST 的方差稳定化性能。可以看到,Raw 域中的局部残差方差随信号强度呈明显上升趋势,表现出较强的异方差性,经过 VST 变换后,该曲线整体幅值降低且走势趋于平缓,对应的方差稳定性指标 VSQ 从 3.34×10^{-4} 降至 1.05×10^{-4} 。VSQ 的降低表明,图像不同亮度区间的噪声波动得到均衡抑制,残余噪声对信号强度的方差依赖性被削弱,有利于后续高斯去噪器发挥作用。

4.2.2 迭代收敛性与计算效率分析

同样以“靶标”在采样率 $1/30^2$ 下的仿真实验为例,图 9 给出了整个算法训练的收敛过程。

从图 9 的迭代曲线可以看出,算法的联合优化过程表现出良好的收敛特性:自监督掩码损失主导了迭代前期的总损失下降,实现了噪声抑制

的核心目标,物理数据保真损失的快速收敛则保证了重建结果与成像模型的一致性约束。随着迭代推进,重建 PSNR 在约 100 轮迭代后趋于饱和,同时 VST 样条参数 θ 与仿射系数 α, β 均在 200 轮内进入稳态,无参数漂移或性能退化现象,说明所提算法的训练过程稳定可控,能够可靠学习到适配目标噪声的方差稳定变换。

为比较 TP-N2VST 与其他经典算法的实际运行开销,本文在配备 NVIDIA RTX 4070 Laptop GPU, Intel Core i7-12800HX 处理器及 16 GB 内存的笔记本电脑上,以 256×256 标准灰度图“靶标 256”为测试对象,在 PSF 子图采样率为 $1/18^2$ 条件下进行重建实验。不同方法的重建结果及运行时间如图 10 所示。

在运行时间方面,TP-N2VST 的总耗时为 10.54 s,与 Tikhonov+Noise2VST 的 10.52 s 基




图9 算法迭代收敛过程

Fig. 9 Iterative convergence of the algorithm




图10 “靶标 256”在不同算法下重建结果及耗时对比

Fig. 10 Comparison of reconstruction results and runtime for different algorithms on "usaf256"

本相当,说明引入物理数据保真约束未带来明显额外开销。相比 PnP-ADMM 的 61.21 s 和 TVNLS 的 2.74 h, TP-N2VST 具有更低的实际

运行开销。虽然其运行时间高于 Tikhonov 和 Tikhonov+DRUNet,但获得了更好重建效果。对于 OMP 方法,本文采用的显式 DCT 字典实现

需要构造 $65\,536 \times 65\,536$ 的稠密字典矩阵,因此,基于显式稠密字典的 OMP 实现不适合直接用于整幅大尺寸图像重建,故未将其纳入运行时间统计。

为进一步评估本文方法的计算效率,表 7 给出了所提算法与近年来端到端深度学习方法在参数量、训练模式、训练时间及重建机制等方面的对比。端到端方法通常需要对整个重建网络进行大规模参数优化:典型 U-Net/GAN 类关联

成像网络的参数量在 10^6 量级甚至更高,而大模型增强的计算鬼成像方法 GILM^[25]更是将参数量提升至 14 亿。与需要基于大量成对样本进行离线训练的端到端方法不同,TP-N2VST 不需要针对关联成像数据集重新训练完整去噪网络,而是在单幅重建图像上仅优化 VST 样条及补偿参数。该特点降低了方法对成对训练数据的依赖,但引入了单图参数自适应的迭代开销。

表 7 不同重建方法的参数与训练特性对比

Tab. 7 Comparison of parameters and training characteristics of different reconstruction methods

Category	Representative work	Reconstruction strategy	Trainable parameters	Training mode	Training time
End-to-end U-Net	Wang et al. ^[26]	Direct measurement-to-image mapping	$\sim 5.8 \times 10^6$ (estimated)	Supervised	—
End-to-end GAN	MsGAN ^[27]	GAN generator direct reconstruction	$10^7 \sim 10^8$ order (estimated)	Supervised/adversarial	—
Deep unrolling network	ADMMNet-GI ^[28]	ADMM unrolling + learnable sparse transform	$\sim 1 \times 10^5$ (estimated)	Supervised	~ 8 h
Transformer deep unrolling	HATNet ^[29]	Kronecker SPI + HAT denoising	10^7 order (estimated)	Supervised	Several to tens of hours, A100 required
Large model method	GILM ^[25]	Physics-embedded Transformer/ResNet	1.4×10^9	Self-supervised pretraining	Several hours to days, A100 required
TP-N2VST	This work	Tikhonov + learnable VST	130	Self-supervised	~ 7.46 s per image

需要强调的是,两类方法代表了不同的技术类型。端到端深度学习方法通过强大的网络表征能力在极低采样率或复杂退化场景下取得了优异的重建性能,但依赖于充足的训练数据与计算资源,泛化能力受训练数据分布限制。本文方法将物理成像模型作为显式约束,通过少量可学习参数实现噪声自适应抑制,具有参数量小、训练速度快、无需成对真值、物理可解释性强等优势,适用于数据获取困难的情形。两类方法各有所长,未来的研究方向之一是将端到端网络强大的表征能力与模型驱动框架的物理约束进行有机融合。

4.2.3 重建误差界分析

图 11 为“靶标”在不同欠采样率下的重建误差界对比结果。其中,红、蓝色线分别为 Tikhonov 与 TP-N2VST 对真值的 RMSE(彩图见期刊电子版)。而黑色虚线为基于奇异值分解与偏差-方差分解推导的 Tikhonov 正则化理论重建误




图 11 误差界分析图

Fig. 11 Error bounds analysis

差下界,公式如(22)所示:

$$\text{RMSE}_{\text{theo}}(\hat{x}) = \sqrt{\text{Bias}^2(\hat{x}) + \text{Var}(\hat{x})}, \quad (22)$$

其中: $\text{Bias}^2(\hat{x}_\lambda) = \frac{1}{N} \sum_{i=1}^M \left(\frac{\lambda \cdot (\mathbf{v}_i^T \mathbf{x})}{s_i^2 + \lambda} \right)^2 + \frac{1}{N} \left(\|\mathbf{x}\|_2^2 - \sum_{i=1}^M (\mathbf{v}_i^T \mathbf{x})^2 \right)$, 反映了正则化系统偏

差。 $Var(\hat{x}_\lambda) = \frac{\sigma_n^2}{N} \sum_{i=1}^M \left(\frac{s_i}{s_i^2 + \lambda} \right)^2$ 反映了测量噪声在重建中被放大的随机误差。

结果表明, Tikhonov 正则化的实际误差高于其理论下界。而 TP-N2VST 的重建误差在所有欠采样条件下均低于 Tikhonov 方法, 且突破了其理论误差下界, 展现出更优的重建精度。

4.3 复杂光照、噪声下仿真实验

实际压缩感知关联成像中, 非均匀光照通常与探测器噪声、光子噪声等共同存在。非均匀光照会改变场景不同区域的信号强度, 使噪声呈现信号相关和空间变化特性。为验证 TP-N2VST 在复杂退化条件下的鲁棒性, 本节以“house”图像为例, 同时引入非均匀光照和中等强度泊松-高斯复合噪声。在测量均值处, 泊松噪声方差设为 0.5, 加性高斯噪声标准差设为 0.2。非均匀光照包括线性渐变 (Linear)、径向渐变 (Radial)、高斯光斑 (Gaussian) 及三者的随机组合 (Mixed), 光照强度设置为 0.3, 0.5 和 0.7。以采样率为 $1/24^2$ 和 $1/36^2$ 的结果为例, 比较 Tikhonov, Tikhonov+DRUNet 及 TP-N2VST 的重建性能, 结果如表 8 和表 9 所示。表 8 对两种采样率和四种光照模式取平均, 表 9 对两种采样率和三种光照强度取平均。物理数据保真项的独立贡献已在第 4.1 节的消融实验及带噪定量对比中验证, 本节重点考察所提整体框架在复杂光照-噪声耦合条件下的鲁棒性。

表 8 各光照模式下的平均 PSNR/SSIM

Tab. 8 Average PSNR/SSIM under different illumination modes

Mode	Tikhonov	Tikhonov+ DRUNet	TP-N2VST
Gaussian	13.63/0.098	16.24/0.195	19.16/0.496
Mixed	15.69/0.161	15.33/0.211	16.85/0.445
Radial	13.01/0.097	15.02/0.203	16.89/0.467
Linear	11.67/0.097	12.72/0.199	13.89/0.446

由表 8 可见, TP-N2VST 在所有光照模式下均取得最优。其中高斯光斑下的 PSNR 与 SSIM 增益最大, 这表明所学习的 VST 对局部光照变化引起的信号相关噪声具有较好的适应能力。即使在混合光照条件下, TP-N2VST 仍能稳定优

表 9 各光照强度下的平均 PSNR/SSIM

Tab. 9 Average PSNR/SSIM under different intensities

Intensity	Tikhonov	Tikhonov+ DRUNet	TP-N2VST
0.3	14.28/0.119	16.25/0.211	18.73/0.495
0.5	13.49/0.113	14.75/0.200	16.49/0.466
0.7	12.74/0.107	13.48/0.194	14.88/0.429

于两种基线, 说明其对多种非均匀光照的复合场景具有良好泛化能力。线性渐变仍然是最困难的情形, 因其强度变化全局且单调, TP-N2VST 仍取得最优结果。

由表 9 可见, 随着光照不均匀性增强, 各方法绝对指标均下降, 但 TP-N2VST 始终保持最大优势。相对于 Tikhonov+DRUNet 的 PSNR/SSIM 增益从强度 0.3 时的 2.48 dB/0.29 下降到 0.7 时的 1.40 dB/0.24。上述结果表明, TP-N2VST 在非均匀光照与中等强度泊松-高斯噪声共同作用下仍能保持较好的重建性能。其优势可能与可学习 VST 对信号相关噪声的自适应变换、盲点自监督去噪以及测量域物理数据保真约束的协同作用有关。相比采用固定噪声水平的 Tikhonov+DRUNet, TP-N2VST 能够更好地保持图像结构信息。

4.4 真实实验

在仿真实验验证算法有效性的基础上, 为进一步检验算法对真实场景复杂噪声的适应性, 本文开展真实成像实验。实验选取四靶作为测试目标, 成像系统采集的原始散斑图像如图 12 所示。

在进行重建前, 为明确实测散斑图像的噪声




图 12 四靶散斑图

Fig. 12 Speckle image of four target

统计特性,本文选取该场景下连续采集的稳定测量帧进行差分分析。具体而言,将图像划分为 64×64 像素的局部区域,以相邻帧平均值作为局部信号强度,以帧差方差的二分之一作为噪声方差估计:

$$\begin{aligned}\mu &= \text{mean}[(I_i + I_j)/2], \\ v &= \text{Var}(I_i - I_j)/2.\end{aligned}\quad (23)$$

在此基础上拟合方差-均值关系 $v = a\mu + b$ 。如图 13 所示,真实测量数据的噪声方差随局部平均灰度近似线性增加,拟合结果为 $v = 0.02574\mu + 0.07914$, 决定系数为 $R^2 = 0.9892$ 。

该结果表明,真实测量噪声具有信号相关分量和信号无关分量,其统计特性与泊松-高斯复合噪声模型相容。因此,后续仿真和重建实验采用泊松-高斯模型对真实测量噪声进行近似描述。

测量矩阵 A 的构造流程与仿真实验一致,但根据真实系统的成像条件调整了采样率。与仿真实验不同,真实实验的测量向量 $\mathbf{y}^*$ 来自实际采集的散斑图像。具体构造方式如下:

(1) 测量矩阵 A 的构造:固定尺寸为 $h_c = 3/5 h_{\text{psf}}$, $w_c = 3/5 w_{\text{psf}}$ 的滑动窗口,在预先存储的 PSF 散斑图上进行滑动分块,并在每个子图像内分别以采样率 $1/6^2, 1/9^2, 1/12^2, 1/15^2$ 沿行、列方向





图 13 真实测量数据的噪声方差-信号均值关系

Fig. 13 Relationship between noise variance and signal mean for real measurement data

进行等间距降采样,构造不同采样率下的测量矩阵 A 。

(2) 测量向量 $\mathbf{y}^*$ 的构造:在目标散斑测量图的中心位置截取与滑动窗口相同尺寸 ($h_c \times w_c$) 的区域,采用与构造 A 时相同的采样率和采样位置进行等间距降采样,得到对应的测量向量 $\mathbf{y}^*$ 。值得注意的是 A 与 $\mathbf{y}^*$ 的降采样位置必须严格对应以匹配矩阵方程,否则将无法正确重建目标图像。此外,由于四靶标在整个成像视场中仅占据较小区域,为降低计算复杂度,将待重建图像尺寸设置为 100×100 大小。分别使用不同重建方法进行对比实验,成像结果如图 14 所示。






图 14 不同算法对四靶重建结果

Fig. 14 Reconstruction results of four target by different algorithms

在真实场景实验中,OMP 算法基本无法还原出图像。TVAL3 和 TVNLS 算法能够恢复整体形状,但存在过于平滑、细节结构丢失的问题。PnP-ADMM(DRUNet)和 Tikhonov 重建能够恢复部分的条纹结构,但是仍然存在噪声残留与周期性伪影。Tikhonov+DRUNet 比 PnP 效果更加稳定,去噪效果较好,但仍然存在周期性伪影,原因是 DRUNet 主要针对加性白高斯噪声训练,在复杂真实混合噪声条件下可能存在统计失配。TP-N2VST 重建质量较好,在较高采样率下去除了周期性伪影,需要指出的是,在低采样率条件下,由于观测信息严重不足, Tikhonov 初始重建结果本身已高度退化并混叠严重,此时后续去噪的提升空间有限,即使引入 Noise2VST 等,重建质量的改善也受到根本性限制。

5 总结与展望

为了提升关联成像在复杂噪声环境下的重建性能,本文提出一种 Tikhonov 正则化与 Noise2VST 结合的双监督协同重建框架。利用盲点自监督损失与基于成像物理的数据保真损失联合优化机制,有效提升了传统算法在复杂噪声场景的性能,提升了关联成像重建质量。

本文方法的核心优势源于模块协同特性与双监督约束机制。Tikhonov 正则化可有效抑制欠采样逆问题的结构性伪影,提供贴合成像物理规律的初始重建结果,约束重建病态性。Noise2VST 通过可学习单调样条变换自适应拟合复杂残留噪声,将非高斯噪声高斯化,发挥深度去噪器的性能。同时,双监督机制形成有效互补:盲点自监督损失实现无标注下的自适应噪声建模,物理保真损失约束重建结果贴合真实观测

模型,降低自监督优化结果偏离测量模型的风险,兼顾图像结构与噪声抑制。

本文所提方法仍存在一定局限性。在极低采样率、强复杂噪声等极端工况下,有效观测信息不足,先验约束效能减弱,图像畸变超出模型校正范围,易引发结构失真、细节模糊等问题。

针对上述不足,后续将从多方面开展优化与新工作。一是构建自适应权重双监督机制,根据采样率与噪声强度动态平衡约束损失,提升极端工况下的重建稳定性。二是优化 VST 变换与重建结构,强化模型对重度畸变、复杂光照及强噪声场景的适配校正能力。三是开展与数

据驱动成像算法的融合研究,利用主流端到端深度学习成像方法,进一步提升复杂场景下的重建性能。

作者贡献声明:

冒纯晔:论文构思,验证,可视化呈现,初稿写作;

邵云天:指导,提供资源;

刘维涛:审核与编辑写作;

王世勇:指导,方法论,提供资源,审核与编辑写作;


吴滢跃:提供资源。

参考文献:

- [1] PITTMAN T, SHIH Y, STREKALOV D, *et al.* Optical imaging by means of two-photon quantum entanglement[J]. *Physical Review A, Atomic, Molecular, and Optical Physics*, 1995, 52(5): R3429-R3432.
- [2] BENNINK R S, BENTLEY S J, BOYD R W. “Two-photon” coincidence imaging with a classical source [J]. *Physical Review Letters*, 2002, 89(11): 113601.
- [3] SHAPIRO J H. Computational ghost imaging [J]. *Physical Review A*, 2008, 78(6): 061802.
- [4] KATZ O, BROMBERG Y, SILBERBERG Y. Compressive ghost imaging [J]. *Applied Physics Letters*, 2009, 95(13): 131110.
- [5] YANG X, YU Z Y, XU L, *et al.* Underwater ghost imaging based on generative adversarial networks with high imaging quality [J]. *Optics Express*, 2021, 29(18): 28388.
- [6] ERKMEN B I, SHAPIRO J H. Ghost imaging: from quantum to classical to computational [J]. *Advances in Optics and Photonics*, 2010, 2(4): 405-450.
- [7] KONG L J, LI Y N, QIAN S X, *et al.* Encryption of ghost imaging [J]. *Physical Review A*, 2013, 88: 013852.
- [8] HUANG W Y, TAN W, QIN H, *et al.* Edge detection based on ghost imaging through biological tissue [J]. *Journal of the Optical Society of America B*, 2023, 40(7): 1696.
- [9] 马祥天,王立志,黄华. 编码孔径快照光谱成像重建算法综述 [J]. *计算机学报*, 2024, 47(1): 190-212.
- [10] MA X T, WANG L Z, HUANG H. A survey of reconstruction algorithms for coded aperture snapshot spectral imaging [J]. *Chinese Journal of Computers*, 2024, 47(1): 190-212. (in Chinese)
- [11] TROPP J A, GILBERT A C. Signal recovery from random measurements via orthogonal matching pursuit [J]. *IEEE Transactions on Information Theory*, 2007, 53(12): 4655-4666.
- [12] BIOUCAS-DIAS J M, FIGUEIREDO M A T. A new TwIST: two-step iterative shrinkage/thresholding algorithms for image restoration [J]. *IEEE Transactions on Image Processing*, 2007, 16(12): 2992-3004.
- [13] YUAN X. Generalized alternating projection based total variation minimization for compressive sensing [C]. 2016 *IEEE International Conference on Image Processing (ICIP)*. September 25-28, 2016, Phoenix, AZ, USA. IEEE, 2016: 2539-2543.
- [14] 顿雄,张健,冯诗淇,等. 光学系统与图像处理端到端协同设计及其应用 [J]. *光学精密工程*, 2022, 30(21): 2827-2838.
- [15] DUN X, ZHANG J, FENG S Q, *et al.* End-to-end co-design of optics and image processing and its applications [J]. *Opt. Precision Eng.*, 2022, 30(21): 2827-2838. (in Chinese)
- [16] HE Y C, WANG G, DONG G X, *et al.* Ghost imaging based on deep learning [J]. *Scientific Reports*, 2018, 8: 6469.
- [17] BIAN T, YI Y X, HU J L, *et al.* A residual-based deep learning approach for ghost imaging [J]. *Scientific Reports*, 2020, 10: 12149.

- [16] LI Y J, ZHANG L H, ZHANG D W. Computational ghost imaging for atmospheric turbulence using physic mode-drive deep learning [J]. *Optics and Lasers in Engineering*, 2025, 190: 108953.
- [17] VENKATAKRISHNAN S V, BOUMAN C A, WOHLBERG B. Plug-and-play priors for model based reconstruction[C]. 2013 *IEEE Global Conference on Signal and Information Processing*. December 3-5, 2013, Austin, TX, USA. IEEE, 2014: 945-948.
- [18] CHAN S H, WANG X R, ELGENDY O A. Plug-and-play ADMM for image restoration: fixed-point convergence and applications [J]. *IEEE Transactions on Computational Imaging*, 2017, 3 (1): 84-98.
- [19] 孙潇雨, 雷腾, 丁源, 等. 一种基于 PnP-ADMM 的快照式关联成像图像重构算法[J]. *半导体光电*, 2025, 46(1): 135-141.
SUN X Y, LEI T, DING Y, *et al.* Snapshot ghost imaging reconstruction algorithm based on plug-and-play ADMM framework[J]. *Semiconductor Optoelectronics*, 2025, 46 (1): 135-141. (in Chinese)
- [20] TIKHONOV A N, ARSENIN V Y. *Solutions of Ill-Posed Problems* [M]. New York: Wiley, 1977.
- [21] HERBRETEAU S, UNSER M. Self-calibrated variance-stabilizing transformations for real-world image denoising [C]. 2025 *IEEE/CVF International Conference on Computer Vision (ICCV)*. October 19-25, 2025, Honolulu, HI, USA. IEEE, 2026: 10496-10506.
- [22] ZHANG K, ZUO W M, ZHANG L. FFDNet: toward a fast and flexible solution for CNN-based image denoising[J]. *IEEE Transactions on Image Processing*, 2018, 27(9): 4608-4622.
- [23] ZHANG K, LI Y W, ZUO W M, *et al.* Plug-and-play image restoration with deep denoiser prior[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(10): 6360-6376.
- [24] BATSON J, ROYER L. Noise2Self: blind denoising by self-supervision [C]. *Proceedings of the 36th International Conference on Machine Learning*, 2019: 524-533.
- [25] CHEN Y F, AN H J, SUN Z, *et al.* Large model enhanced computational ghost imaging[J]. *Science China Technological Sciences*, 2025, 68 (11): 2120403.
- [26] WANG F, WANG H, WANG H C, *et al.* Learning from simulation: an end-to-end deep-learning approach for computational ghost imaging[J]. *Optics Express*, 2019, 27(18): 25560-25572.
- [27] ZHANG H, DUAN D Y. Turbulence-immune computational ghost imaging based on a multi-scale generative adversarial network [J]. *Optics Express*, 2021, 29(26): 43929.
- [28] HE Y C, ZHOU Y, YU J M, *et al.* ADMMNet-based deep unrolling method for ghost imaging[J]. *IEEE Transactions on Computational Imaging*, 2024, 10: 233-245.
- [29] QU G, WANG P, YUAN X. Dual-scale transformer for large-scale single-pixel imaging [C]. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 16-22, 2024, Seattle, WA, USA. IEEE, 2024: 25327-25337.

作者简介:



冒纯晔(2002—),男,湖南邵阳人,硕士研究生,主要从事计算光学成像、数字图像处理的研究。E-mail:maochunye24@mail.ucas.ac.cn

通讯作者:



王世勇(1972—),男,吉林人,研究员,博士生导师,2002年于中国科学院长春光学精密机械与物理研究所获得博士学位,主要从事红外光电系统技术、红外图像信号处理等方面的研究。E-mail:s_y_w@sina.com