光电技术及应用

DOI：10.16818/j.issn1001－5868.20241125002

一种基于PnP-ADMM的快照式关联成像图像重构算法

孙潇雨[1,2]，雷　腾[1,2]，丁　源[1,2]，李元戎[1,2]，王世勇[1,2*]

（1. 中国科学院上海技术物理研究所，上海 200083；2. 中国科学院大学，北京 100049）

摘　要： 针对现有关联成像图像重构算法难以兼顾重建能力和适用性，提出一种基于即插即用交替方向乘子法（PnP-ADMM）框架的快照式关联成像图像重构算法。该算法通过模拟化架构设计，允许灵活嵌入先进去噪先验模型，在低采样率和高采样率条件下均显著提升重建效果。当采用深度卷积神经网络FFDNet作为去噪器时，成功融合了模型驱动和学习驱动方法的优势，克服了传统压缩感知与深度学习方法的局限性。实验结果表明，与基于全变分和低秩约束的TVNLR相比，PnP-ADMM（FFDNet）重构结果的峰值信噪比提升超过2 dB，结构相似性提升超过0.15，在抑制重构噪声的同时保留了图像细节。

关键词： 计算成像；关联成像；图像重构；交替方向乘子法；即插即用

中图分类号： TP391.41　**文章编号：** 1001－5868(2025)01－0135－07

Snapshot Ghost Imaging Reconstruction Algorithm Based on Plug-and-Play ADMM Framework

SUN Xiaoyu[1,2], LEI Teng[1,2], DING Yuan[1,2], LI Yuanrong[1,2], WANG Shiyong[1,2]

(1. Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 200083, CHN;
2. University of Chinese Academy of Sciences, Beijing 100049, CHN)

Abstract: Existing image reconstruction algorithms for ghost imaging often struggle to balance reconstruction performance and broad applicability. To address this issue, we propose a snapshot ghost imaging reconstruction algorithm based on the Plug-and-Play Alternating Direction Method of Multipliers (PnP-ADMM) framework. By seamlessly integrating high-performance denoisers, the algorithm significantly enhances reconstruction quality across both low and high sampling rates. Specifically, when employing the deep convolutional neural network FFDNet as the denoiser, the method effectively combines the strengths of model-driven and learning-driven approaches, surpassing the limitations of traditional compressed sensing and deep learning methods. Experimental results show that, compared to TVNLR, which utilizes total variation and low-rank constraints, PnP-ADMM (FFDNet) achieves a PSNR improvement exceeding 2 dB and an SSIM improvement greater than 0.15, while effectively suppressing reconstruction noise and preserving intricate image details.

Key words: computational imaging; ghost imaging; image reconstruction; alternating direction method of multipliers; plug-and-play

收稿日期：2024－11－25.

*通信作者：王世勇

0 引言

关联成像又称鬼成像，是一种基于光场二阶或高阶关联特性，通过间接重构目标图像的成像技术。在典型关联成像系统中，具有空间相关性的照明光被分为两路：一路为参考光路，直接由面阵探测器探测；另一路为信号光路，经目标反射或透射后由桶探测器探测。最终，目标物体的图像是通过对两路探测结果进行关联运算重构得到的。自1995年Pittman等[1]首次利用纠缠光子对实现关联成像以来，关联成像的研究不断取得进展。2002年，Bennink等[2]提出基于经典光源的关联成像，证明量子纠缠并非实现关联成像的必要条件。2008年，Shapiro[3]进一步提出利用空间光调制器的计算鬼成像系统，简化了实验系统的配置，提高了关联成像的实用性。关联成像具有透过散射介质成像的能力，相较于其他计算成像方法，其不仅具备更强的适应性，而且对设备要求更低[4-6]。此外，关联成像有很强的抗干扰能力，在水下成像[7]、激光雷达[8]、生物医学成像[9]等领域有很强的应用潜力。

根据关联成像的原理可知，其成像结果在很大程度上依赖于重构算法的性能，当前常用的重构算法主要分为两类：基于压缩感知的方法和基于深度学习的方法[10]。压缩感知方法通过求解欠定逆问题进行信号重构，常见方法包括贪婪算法、凸优化算法和基于图像空间稀疏性的方法等。尽管这些方法物理意义明确，但在重构精度和噪声抑制方面不能同时达到理想效果。深度学习方法通过将传统的二阶关联计算结果作为初始图像输入卷积神经网络[11]，或直接建立桶探测器信号与真实图像的映射关系，通过训练端到端的神经网络实现图像重构[12]。这类方法在重构图像质量上优于传统算法，但通常需要大量数据训练，在采样率变化时还需要再次训练网络，适用性差。

交替方向乘子法（Alternating Direction Method of Multipliers, ADMM）[13]是一种高效的迭代优化算法，广泛应用于解决压缩感知问题。Venkatakrishnan等[14]提出的即插即用（Plug-and-Play，PnP）框架将现代去噪先验与迭代优化算法结合，使PnP-ADMM在图像重建领域取得了广泛的应用[15]，如压缩成像[16]、快照压缩光谱成像[17]、磁共振成像[18]等。针对以上问题，本文将PnP-ADMM引入关联成像图像重构算法中，提出一种基于PnP-ADMM的关联成像图像重构算法，并结合不同的去噪算法作为先验。这种方法一方面通过插入高性能去噪器显著提高了重建性能，另一方面在利用去噪卷积神经网络作为去噪器时不需要大量数据的训练，突破了传统压缩感知和深度学习方法的局限，为关联成像领域提供了一种新的解决方案。经实验验证，基于PnP-ADMM的快照式关联成像图像重构算法，尤其是选择深度去噪卷积神经网络作为去噪器时可以有效提升关联成像的重构质量，并在欠采样条件下显著提高图像重构的效率和鲁棒性。

1 快照式关联成像实验系统

为解决传统桶探测器关联成像系统成像时间较长的问题，搭建了一套快照式关联成像系统，能够在单次曝光下实现成像。如图1所示，该系统主要由三个模块组成：前置成像模块、调制模块以及重构解调模块。前置成像模块包含窄带滤波片和前置成像镜头（lens1）：宽带白光作为光源照射目标物体，窄带滤波片对其反射或透射的光进行滤波，再由前置成像镜头汇聚到一次像面上；调制模块包含空间随机相位调制器（此处为散射片）：一次像面被划分为N个小面元，每个小面元发出的光经自由传输后由散射片进行相位调制，在散射片后面形成强度叠加的散斑干涉场，最终由显微物镜（lens2）将该散斑干涉场放大并成像至像元数为M（$M \ll N$）的光电探测阵列CCD上[19]；重构解调模块主要指在计算机中实现的图像重构算法。

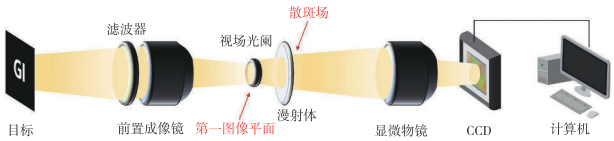

图1 快照式关联成像系统示意图

调制模块中一次像面上的像经空间随机相位调制器调制后被探测的过程可以描述为：

$$\begin{pmatrix} y_1 \\ y_2 \\ \cdots \\ y_M \end{pmatrix}_M = \begin{pmatrix} A_{11} & \cdots & A_{1i} & \cdots & A_{1N} \\ A_{21} & \cdots & A_{2i} & \cdots & A_{2N} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ A_{M1} & \cdots & A_{Mi} & \cdots & A_{MN} \end{pmatrix}_{M\times N} \begin{pmatrix} x_1 \\ x_2 \\ \cdots \\ x_N \end{pmatrix}_N \tag{1}$$

简写为矢量形式可以表示为：

$$\boldsymbol{y} = \boldsymbol{A}\boldsymbol{x} \tag{2}$$

式中，$\boldsymbol{y}=(y_1,y_2,\cdots,y_M)^{\mathrm{T}}$为将CCD采集到的信号排成一列得到的图像矢量，称为测量值。$\boldsymbol{x}=(x_1,x_2,\cdots,x_N)^{\mathrm{T}}$为将一次像面划分为$N$个面元，并将这些面元按顺序排列成的列矢量，称为信号值。$\boldsymbol{A}$为测量矩阵，第i列元素$(A_{1i},A_{2i},\cdots,A_{Mi})^{\mathrm{T}}$对应的是一次像面上第$i$个面元产生的散斑场光强分布排成的列矢量，该测量矩阵可以通过对散射片进行预先标定的方式获得。

标定之前在一次像面处放置固定在电动位移台上的针孔光阑，由计算机进行控制。将一次像面划分为N个小面元，小面元的尺寸与针孔光阑的孔径相同，计算机通过电动位移台控制针孔光阑在一次像面上依次移动，散射片对通过针孔光阑的光进行相位调制，CCD依次记录每个小面元对应的散斑场。标定完成后将针孔光阑移除，就可以直接对目标物体场景进行成像以获得测量信号。在得到测量矩阵$\boldsymbol{A}$和测量信号$\boldsymbol{y}$值之后，通过图像重构算法就可以得到$\boldsymbol{x}$，将$\boldsymbol{x}$排列成$N\times N$大小的二维矩阵，即一次像面上的像。由于目标物体的像和一次像面上的像存在点对点的对应关系，得到$\boldsymbol{x}$就相当于恢复了目标物体的图像。

2　基于PnP-ADMM的快照式关联成像图像重建算法

ADMM算法作为一种优化算法求解器，能够将复杂问题分解为多个更易求解的子问题，有效降低优化难度。PnP-ADMM通过将去噪先验集成到迭代优化算法中，使ADMM更适用于处理图像重建的问题。在图像重建问题中，该算法通过迭代最小化由数据保真项和正则化项组成的损失函数来逼近真实目标图像。在成像模型的约束下，数据保真项强制重建图像与测量值匹配，而正则化项强化对目标图像的先验知识。

2.1　算法原理

在关联成像图像重构过程中，目标图像、测量矩阵、测量值三者之间的关系可由公式(3)表示。由于欠采样条件下的关联成像光电探测阵列的像元数远小于一次像面面元数量(即$M\ll N$)，欠采样条件下的鬼成像实质上是一个欠定问题。

根据PnP-ADMM图像重建框架，欠采样下的关联成像图像重构问题可以被建模为：

$$\hat{\boldsymbol{x}}=\arg\min_{\boldsymbol{x}}\frac{1}{2}\left\|\boldsymbol{y}-\boldsymbol{A}\boldsymbol{x}\right\|_2^2+\lambda g(\boldsymbol{x}) \tag{3}$$

式中，第一项是由图像重构问题确定的数据保真项，目的是确保最终图像与实测数据保持一致，第二项是包含先验信息的正则项，argmin为求解最小化问题的过程，λ为正则化参数，$\|\cdot\|_2^2$是l_2范数算子。

通过引入辅助变量，将上述无约束优化问题转化为有约束优化问题，有约束优化问题可描述为：

$$(\hat{\boldsymbol{x}},\hat{\boldsymbol{u}})=\arg\min_{\boldsymbol{x},\boldsymbol{u}}\frac{1}{2}\left\|\boldsymbol{y}-\boldsymbol{A}\boldsymbol{x}\right\|_2^2+\lambda g(\boldsymbol{u}),\text{subject to}\ \boldsymbol{x}=\boldsymbol{u} \tag{4}$$

式中，$\boldsymbol{u}$为重构图像对应的辅助变量，与目标图像$\boldsymbol{x}$等价。

公式(4)对应的增广拉格朗日函数为：

$$L(\boldsymbol{x},\boldsymbol{u},\boldsymbol{v})=\frac{1}{2}\left\|\boldsymbol{y}-\boldsymbol{A}\boldsymbol{x}\right\|_2^2+\lambda g(\boldsymbol{u})+\boldsymbol{v}^T(\boldsymbol{x}-\boldsymbol{u})+\frac{\rho}{2}\left\|\boldsymbol{x}-\boldsymbol{u}\right\|_2^2 \tag{5}$$

式中，$\boldsymbol{v}$为拉格朗日乘子，ρ为一个正的拉格朗日参数。

根据ADMM算法，上述优化问题可以分解成不同变量的子问题进行求解：

$$\begin{aligned}\boldsymbol{x}^{k+1}&=\arg\min_{\boldsymbol{x}}\frac{1}{2}\left\|\boldsymbol{y}-\boldsymbol{A}\boldsymbol{x}\right\|_2^2+\frac{\rho}{2}\left\|\boldsymbol{x}-\boldsymbol{u}^k+\frac{1}{\rho}\boldsymbol{v}^k\right\|_2^2\\ \boldsymbol{u}^{k+1}&=\arg\min_{\boldsymbol{u}}\lambda g(\boldsymbol{u})+\frac{\rho}{2}\left\|\boldsymbol{u}-\boldsymbol{x}^{k+1}-\frac{1}{\rho}\boldsymbol{v}^k\right\|_2^2\\ \boldsymbol{v}^{k+1}&=\boldsymbol{v}^k+\rho(\boldsymbol{x}^{k+1}-\boldsymbol{u}^{k+1})\end{aligned} \tag{6}$$

式中，k和$k+1$分别表示算法的第k次和第$k+1$次迭代。

2.1.1　$\boldsymbol{x}$子问题的求解

$\boldsymbol{x}$子问题是一个二次优化问题，可以简化为一个快速闭式解：

$$\boldsymbol{x}^{k+1}=(\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A}+\rho\boldsymbol{I})^{-1}(\boldsymbol{A}^{\mathrm{T}}\boldsymbol{y}+\rho\boldsymbol{u}^k) \tag{7}$$

式中，$\boldsymbol{I}$为一个单位矩阵。

2.1.2　$\boldsymbol{u}$子问题的求解

由PnP-ADMM图像重建框架可知，可以用一个去噪算法对$\boldsymbol{u}$子问题的求解进行替换，看作是对$\boldsymbol{x}^{k+1}+\frac{1}{\rho}\boldsymbol{v}^k$的去噪求解问题，表示为：

$$\boldsymbol{u}^{k+1}=\mathrm{D}(\boldsymbol{x}^{k+1}+\frac{1}{\rho}\boldsymbol{u}^k) \tag{8}$$

式中，D表示一个去噪器。

在获得x^{k+1},u^{k+1}之后更新拉格朗日乘子,并利用两个迭代式继续求解关于x,u的子问题,直至满足算法迭代的停止条件,将最后一次迭代输出的u^{k+1}作为关联成像图像重建的最终结果。表1将所提出的算法步骤进行整合。

表1 基于PnP-ADMM的关联成像重构算法

Input: measured values $y \in R^{M\times 1}$
sampling matrix $A \in R^{M\times N}$

1: Initialization x^0, u^0, v^0, ρ_0
(1) Solve the following least-squares problem using the conjugate gradient method to obtain the initial estimated image:
$$\hat{u} = \arg\min_{u} \frac{1}{2}\| y - Au \|_2^2$$
(2) $u^0 = \hat{u}, x^0 = \hat{u}, k = 0$
2: **while** Not Converge **do**
3: Solve the subproblem x
$$x^{k+1} = (A^{\mathrm{T}}A + \rho I)^{-1}(A^{\mathrm{T}}y + \rho u^k)$$
4: Solve the subproblem u using a denoiser
$$u^{k+1} = \mathrm{D}(x^{k+1} + \frac{1}{\rho}u^k)$$
5: Update the Lagrange multipliers:
$$v^{k+1} = v^k + \rho(x^{k+1} - u^{k+1})$$
6: $k = k + 1$
7: **end while**

Output: reconstructed signal $u^{k+1} \in R^{N\times 1}$

2.2 去噪器

在PnP-ADMM框架下进行图像重构时,所选择的去噪器对重构质量和噪声抑制性能具有重要影响。传统去噪器包括全变分(Total Variation,TV)去噪器[20]和块匹配与3D滤波(BM3D)去噪器[21]。TV去噪器基于图像的局部平滑性假设,通过最小化图像的全变分来实现去噪。文献[22]采用PnP-ADMM算法结合TV去噪,成功实现视频和高光谱图像的压缩成像重建。BM3D去噪器则通过相似图像块分组、联合去噪和逆变换等步骤,有效抑制了噪声;文献[23]将其与PnP-ADMM算法结合,应用于磁共振成像的高分辨率图像重建。

近年来,深度学习在图像去噪领域取得了显著进步。以FFDNet为代表的深度卷积神经网络去噪器,在处理复杂纹理和高噪声环境时,表现出了优于传统方法的性能[24]。因此,选择TV,BM3D和FFDNet三种去噪器,分别探讨它们在PnP-ADMM框架下对关联成像图像重构的效果。

3 实验与分析

选择三种常用的压缩感知算法作为对比方法,分别是基于稀疏正则化方法(OMP)、基于全变分正则化方法(TVAL3)以及基于全变分和低秩约束结合方法(TVNLR),通过仿真和实验对比验证基于PnP-ADMM的关联成像图像重建算法和以上常用算法的性能。同时,还比较了在PnP-ADMM框架下使用不同去噪器对重建性能的影响。

3.1 仿真实验

为了测试基于PnP-ADMM的快照式关联成像重构算法的效果,首先进行数值仿真。选择100×100像素的"Lena""House"图像作为仿真中需要重建的目标图像,并通过峰值信噪比(PSNR)与结构相似性(SSIM)对重构图像质量进行客观评价。

为了可视化图像重建的质量,图2分别展示了不同重构算法在不同采样率下重建的"Lena"和"House"图像. 图3分别展示了"Lena"和"House"重构结果对应的PSNR和SSIM曲线图。

结果表明,采用不同的去噪先验对基于PnP-ADMM方法的重建性能影响很大。当采用TV和BM3D作为PnP-ADMM框架下的去噪器时,在低采样率条件下,其重建性能未能超越基于压缩感知的方法,但在提高采样率后表现有所改善;然而,当采用深度卷积去噪网络FFDNet作为去噪器时,无论在低采样率还是高采样率的条件下都取得了优异的重构效果,不仅较好地恢复出了图像的细节,也有效抑制了重构噪声。在采样率为0.062 5时对"Lena"进行重建,PSNR相比压缩感知方法中表现最好的TVNLR提高了至少2 dB,SSIM提高至少0.15,表现出优异的重构效果。

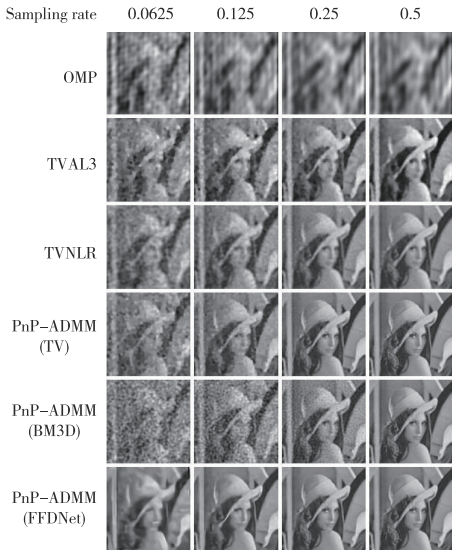

(a) "Lena"

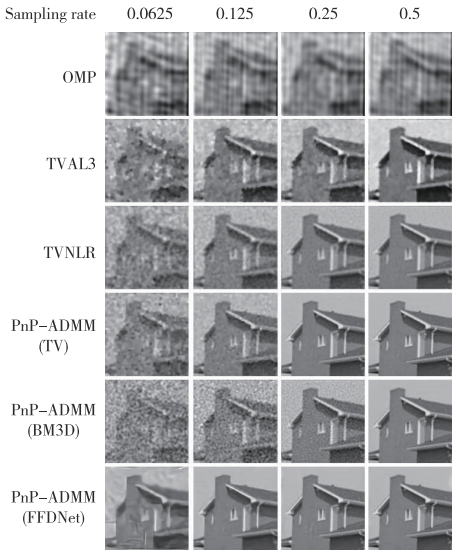

(b)“House”

图 2　不同算法不同采样率下对“Lena”和“House”重构结果

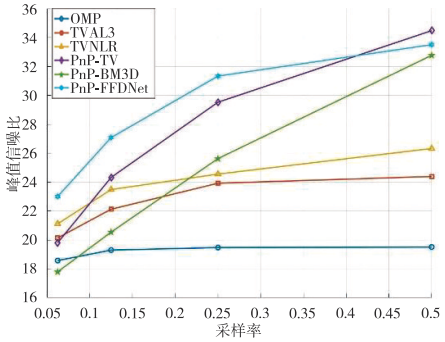

（a）“Lena”重构结果对应的 PSNR 曲线图

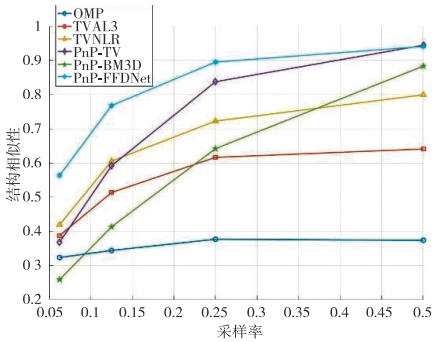

（b）“Lena”重构结果对应的 SSIM 曲线图

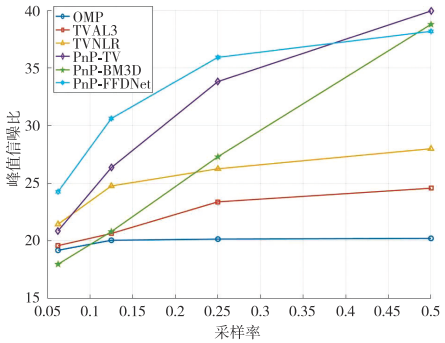

（c）“House”重构结果对应的 PSNR 曲线图

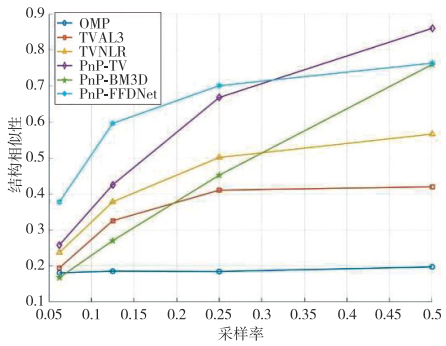

（d）“House”重构结果对应的 SSIM 曲线图

图 3　快照式关联成像系统示意图

两幅图像重构结果在 0.062 5 采样率下的 PSNR 和 SSIM 数值如表 2 和表 3 所示。

表 2　两幅图像重构结果在 0.062 5 采样率下的 PSNR

目标图像	算法类别					
	OMP	TVAL3	TVNLR	PnP-TV	PnP-BM3D	PnP-FFDNet
Lena	18.567 7	20.134 7	21.115 3	19.800 8	17.785 9	23.211 1
House	19.183 0	19.588 2	21.447 1	20.864 6	17.974 6	24.257 5

表 3　两幅图像重构结果在 0.062 5 采样率下的 SSIM

目标图像	算法类别					
	OMP	TVAL3	TVNLR	PnP-TV	PnP-BM3D	PnP-FFDNet
Lena	0.322 8	0.387 3	0.418 7	0.367 8	0.258 4	0.569 3
House	0.180 5	0.194 2	0.237 1	0.257 9	0.167 2	0.397 7

3.2　真实实验

为了对比不同算法的性能，将基于 PnP-ADMM 框架的重构方法与三类常用的压缩感知重构方法在实际成像场景中进行实验。实验系统如图 1 所示。采用 LED 灯（KM-2FL400400，400 mm×400 mm）作为照明光源，成像目标透射出来的光经前置成像镜头（LBMT-1，f = 200 mm）聚焦于一次像面，散射片（GCL-201123，1 500）将光场信息随机编码至干涉场中，最后由显微物镜（KP-10A035X，β = 22）将干涉场成像至 CCD（TRI050S-MC，3 μm×3 μm）上。成像目标为十字靶标和刻有“SITP”的靶标，关联成像系统收集两种靶标的散斑场信息并送入计算机中，结合预先标定获取的测量矩阵的信息，利用关联成像图像重构算法进行图像重构。

不同重构算法对真实场景的重构效果如图 4 所示。结果表明，选择 TV 作为去噪器的 PnP-ADMM 算法能有效恢复图像细节信息，但是重构噪声较

大;选择BM3D和FFDNet作为去噪器时,不仅可以较好地恢复目标的细节,还具有较强的抑制重构噪声的能力,相比而言,选择FFDNet作为去噪器时重构噪声更低,对图像细节的重构能力更强。

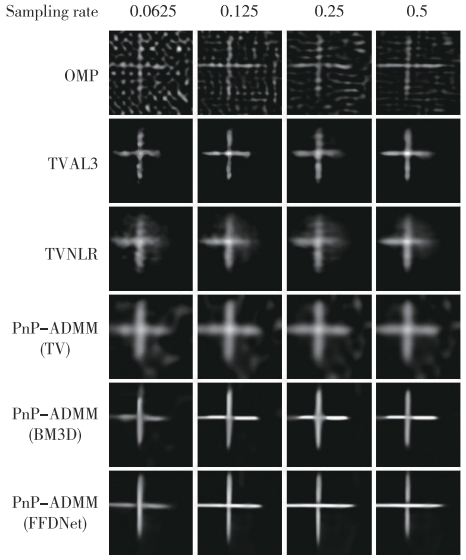

(a)十字靶标重构结果

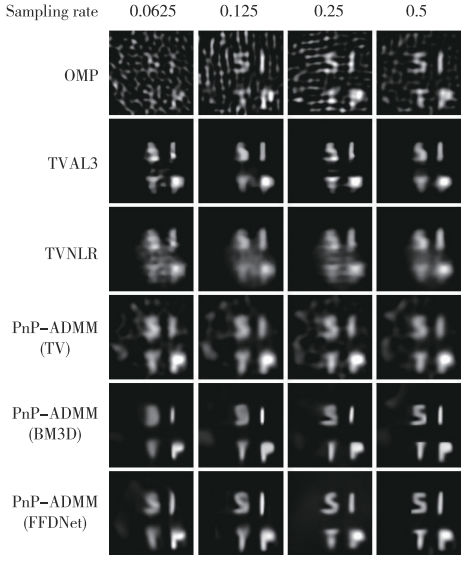

(b)“SITP”靶标重构结果

图4 不同重构算法在不同采样率下对真实场景的重构效果

4 结论

为了同时提高关联成像图像重构算法的重构性能和适用性,本文提出了一种基于PnP-ADMM框架的快照式关联成像图像重构方法。该方法通过灵活插入不同的去噪器,可以实现高效的关联成像图像重建。本文进一步通过实验对比了在该框架中插入不同去噪器时的算法性能,发现当选择深度卷积神经网络FFDNet作为去噪器时,成功结合了基于模型的方法与基于学习的方法的优势,无论是在仿真实验还是真实场景实验中,均取得了优异的重构效果,在细节重构与噪声抑制之间实现了良好平衡。研究分析表明,FFDNet相比于其他去噪器表现优异的原因,是其作为深度卷积神经网络,具备强大的非线性建模能力,能够通过大规模数据训练,学习更复杂的噪声模式和图像细节。实际成像场景的重构结果表明,该重构方法因其对去噪器的高度灵活适配性,非常适合于关联成像的实际应用。并且,随着更先进去噪器的不断涌现,该算法框架可轻松将新的去噪器进行集成,进一步提升重构性能。

参考文献:

[1] Pittman T B, Shih Y H, Strekalov D V, et al. Optical imaging by means of two-photon quantum entanglement[J]. Physical Review A, 1995, 52(5): R3429.

[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] Yu Z, Li H, Zhong T, et al. Wavefront shaping: A versatile tool to conquer multiple scattering in multidisciplinary fields[J]. The Innovation, 2022, 3(5): 100292.

[5] Matveev L A, Sovetsky A A, Matveyev A L, et al. Refined speckle contrast estimation in OCT based on compensation of scattering-related distortions of speckle pattern parameters[J]. Laser Physics Letters, 2025, 22(1): 1-8.

[6] Song Q, Liu Q H, Chen W. High-resolution ghost imaging through dynamic and complex scattering media with adaptive moving average correction[J]. Applied Physics Letters, 2024, 124(21): 211104.

[7] 杨莫愁, 吴 仪, 冯国英. 水下鬼成像的研究进展[J]. 光学学报, 2022, 42(17): 54-73.
Yang Mochou, Wu Yi, Feng Guoying. Research progress on underwater ghost imaging[J]. Acta Optica Sinica, 2022, 42(17): 54-73.

[8] Zhao C, Gong W, Chen M, et al. Ghost imaging lidar via sparsity constraints[J]. Applied Physics Letters, 2012, 101(14): 141123.

[9] Huang W, Tan W, Qin H, et al. Edge detection based on ghost imaging through biological tissue[J]. Journal of the Optical Society of America B: Optical Physics, 2023, 40(7): 1696-1702.

[10] 孙鸣捷, 闫崧明, 王思源. 鬼成像和单像素成像技术中的重建算法[J]. 激光与光电子学进展, 2022, 59(2): 1-16.

Sun Mingjie, Yan Songming, Wang Siyuan. Reconstruction algorithms for ghost imaging and single-pixel imaging[J]. Laser & Optoelectronics Progress, 2022, 59(2): 1-16.

[11] Lyu M, Wang W, Wang H, et al. Deep-learning-based ghost imaging[J]. Scientific Reports, 2017, 7(1): 17865.

[12] Wang F, Wang H, Wang H, et al. Learning from simulation: An end-to-end deep-learning approach for computational ghost imaging[J]. Optics Express, 2019, 27(18): 25560-25572.

[13] Boyd S, Parikh N, Chu E, et al. Distributed Optimization and Statistical Learning via the Alternating Direction Method of Multipliers[M]. New York: New Foundations and Trends, 2011.

[14] Venkatakrishnan S, Bouman C A, Wohlberg B, et al. Plug-and-Play priors for model based reconstruction[C]// 1st IEEE Global Conference on Signal and Information Processing (GlobalSIP), 2013: 945-948.

[15] Chan S H, Wang X, 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.

[16] Yuan X, Liu Y, Suo J, et al. Plug-and-Play algorithms for large-scale snapshot compressive imaging[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 1444-1454.

[17] Zheng S, Liu Y, Meng Z, et al. Deep plug-and-play priors for spectral snapshot compressive imaging[J]. Photonics Research, 2021, 9(2): B18-B29.

[18] Ahmad R, Bouman C A, Buzzard G T, et al. Plug-and-Play methods for magnetic resonance imaging: Using denoisers for image recovery[J]. IEEE Signal Processing Magazine, 2020, 37(1): 105-116.

[19] 陈　喆. 基于相位调制的被动热光源多光谱鬼成像研究[D]; 北京: 中国科学院大学, 2014.
Chen Zhe. The research of the multi-spectral ghost imaging with passive thermal light by phase modulation[D]. Beijing: University of Chinese Academy of Sciences, 2014.

[20] Rudin L I, Osher S, Fatemi E. Nonlinear total variation based noise removal algorithms[J]. Physica D: Nonlinear Phenomena, 1992, 60(1/4): 259-268.

[21] Dabov K, Foi A, Katkovnik V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering[J]. IEEE Transactions on Image Processing, 2007, 16(8): 2080-2095.

[22] Yuan X. Generalized alternating projection based total variation minimization for compressive sensing[C]// The 23rd IEEE International Conference on Image Processing (ICIP), 2016: 2539-2543.

[23] Yuan X, Jiang M, Zhu L, et al. The application of Plug-and-Play ADMM framework and BM3D denoiser for compressed sensing MR image reconstruction[J]. International Journal of Computer Applications in Technology, 2021, 65(4): 304-315.

[24] Zhang K, Zuo W, 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.

作者简介：

孙潇雨(1999—)，女，山东省德州市人，硕士研究生，主要从事关联成像图像重构算法相关研究；

王世勇(1972—)，男，吉林省长春市人，研究员，博士生导师，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。