



基于免训练自监督式神经网络算法实现压缩超快成像高保真图像重构

金诚挚¹, 齐大龙^{1*}, 何宇¹, 姚佳丽¹, 郭姿含¹, 许宁¹, 程龙¹, 毛佳亿¹, 姚志明², 宋岩², 姚云华¹, 沈乐成¹, 邓联忠¹, 盛亮², 孙真荣¹, 张诗按^{1,3,4*}

- 华东师范大学物理与电子科学学院, 精密光谱科学与技术国家重点实验室, 上海 200241;
- 西北核技术研究院, 强脉冲辐射环境模拟与效应国家重点实验室, 西安 710024;
- 山西大学极端光学协同创新中心, 太原 030006;
- 华东师范大学, 华东师范大学-山东师范大学光场调控科学与光子芯片器件联合研究中心, 上海 200241

* 联系人, E-mail: dlqi@lps.ecnu.edu.cn; sazhang@phy.ecnu.edu.cn

2024-01-09 收稿, 2024-04-08 修回, 2024-04-10 接受, 2024-04-12 网络版发表

国家自然科学基金(12325408, 92150301, 12074121, 62105101, 62175066, 12274129, 12274139)和上海市科学技术委员会(21XD1400900)资助

摘要 压缩超快成像(compressed ultrafast photography, CUP)是目前最快的被动式单次超快光学成像技术, 它通过数据获取和图像重构两个步骤实现超快事件的捕捉, 已发展为记录不可逆或难以重复超快事件的一种有力工具, 且能够探测荧光动力学等自发光瞬态场景. 然而, 传统的迭代优化型算法在图像重构上的保真度较低, 而端到端型深度学习算法则严重依赖训练数据, 训练复杂度高、通用性不足, 这限制了CUP对超快现象进行高空间分辨率的观测. 为此, 我们开发了一种新型的免训练自监督式神经网络算法, 其通过即插即用框架(plug-and-play, PnP)与深度图像先验(deep image prior, DIP)的结合可实现CUP的低复杂度高保真图像重建, 简称为PnP-DIP算法. PnP-DIP基于交替方向乘子法(alternating direction method of multipliers, ADMM), 利用DIP和PnP去噪器解决图像恢复子问题, 可以在防止数据过拟合和噪声累积的同时, 显著提高图像重建的精度与收敛速度. 通过数值模拟, 我们理论上证明了PnP-DIP算法在重构原始动态信息方面相比传统ADMM算法具有更高的保真度. 同时, 我们分别利用PnP-DIP对自主研制CUP系统观测的皮秒激光脉冲和X射线闪烁体的时空强度演化数据进行重构, 实验上验证了其优越的图像重构性能. 这一研究有望推动CUP在高时空分辨观测需求中的应用, 并为超快动力学的实时探测作出重大贡献.

关键词 压缩超快成像, 图像重构, 交替方向乘子法, 即插即用, 深度图像先验

超快光学成像技术^[1,2]是近年来光学领域中备受关注的研究方向. 随着超快激光技术的不断发展, 对于超快动力学过程的观测和控制需求日益增加, 超快光学成像技术的研究也受到广泛关注. 超快成像技术能够突破传统互补金属氧化物半导体(complementary metal oxide semiconductor, CMOS)或电荷耦合器件(charge-

coupled device, CCD)的探测极限, 以皮秒到飞秒级别的时间分辨率捕捉物质在空间位置上的动态变化. 通过探索电子、原子和分子在极短时间尺度下的行为, 为物理、化学、材料等多个领域的研究提供了有力的工具和平台^[3-5]. 然而, 面向不可逆或难以重复超快事件的实时观测, 对超快光学成像提出了通过单次曝光

引用格式: 金诚挚, 齐大龙, 何宇, 等. 基于免训练自监督式神经网络算法实现压缩超快成像高保真图像重构. 科学通报, 2024, 69: 2765-2776

Jin C Z, Qi D L, He Y, et al. Realizing high-fidelity image reconstruction for compressed ultrafast photography with an untrained self-supervised neural network-based algorithm (in Chinese). Chin Sci Bull, 2024, 69: 2765-2776, doi: [10.1360/TB-2024-0038](https://doi.org/10.1360/TB-2024-0038)

实现多个时刻成像的需求。现有的单次多幅超快成像技术如电子门控分幅相机^[6]、固态偏振分幅相机^[7]、频域层析成像^[8]、顺序定时全光映射摄影^[9]、飞秒时间分辨光学偏振法^[10]、多次曝光频率识别算法^[11]等,虽然能够在单次拍摄中获取几帧至约20帧成像帧数,但仍无法满足连续完整观测动态场景的需求。2014年, Gao等人^[12]开发了一项名为压缩超快成像(compressed ultrafast photography, CUP)的技术^[13],通过将压缩感知原理与时空偏转成像技术相结合,实现了1000万帧/秒的超快成像速度和超过300帧的超高成像帧数,远超传统单次多幅超快成像技术的性能。随着近十年的发展, CUP凭借其优异的性能,已经在观测光的反射和折射^[12]、飞秒脉冲时间聚焦^[14]、皮秒光场时空演化^[15]、耗散光孤子^[16]、激光烧蚀动力学^[17]、超快光学弹簧^[18]、光学混沌^[19]、电磁脉冲传播^[20]、惯性约束聚变^[21]、荧光寿命成像^[22]等领域得到应用。然而,由于CUP的高数据压缩比和欠采样特性,其重构图像的空间分辨率较低。此外,基于压缩感知理论的图像重构过程十分复杂,需要大量计算资源对重构算法进行参数优化。这些问题一定程度上限制了CUP在需要高精度成像的实际物理场景中的应用。

为了提升CUP的性能,近期的研究工作主要集中在硬件升级和算法改进两个方面。硬件方面, Yang等人^[23]提出了一种结合遗传算法(genetic algorithm, GA)和CUP技术的方法,通过GA优化空间编码,减少观测矩阵和原始场景的相关性,从而提高图像重建质量。Liang等人^[24]设计了一种双通道互补编码方案,利用数字微镜器件(digital micromirror devices, DMD)的正负一级衍射生成一对互补编码,通过保留足够多空间信息来提高图像质量。Yang等人^[25]为了解决条纹相机的电子弥散效应,发展了一种超快电光偏转成像技术,利用电光偏转晶体的光折变效应实现时空偏转,有效避免了条纹相机中光-电-光转换引起的空间分辨率损失。Qi等人^[26]设计了一种利用气体分子排列来实现压缩超快成像的方法,通过构建分子排列辅助压缩超快成像的理论模型和优化关键参数,在模拟上实现了小于6 fs的时间分辨率和约300帧的序列深度。与硬件提升相比,算法改进对CUP图像重建质量起到关键作用,且有更大的提升空间。早期发展的CUP技术中采用两步迭代收缩阈值(two-step iterative shrinkage/thresholding, TwIST)算法进行图像重构,但由于该算法对优化参数的严重依赖,导致重构图像的保真度不高。针对这个问

题, Yang等人^[27]提出了一种基于增广拉格朗日(Augmented Lagrangian, AL)的CUP重构算法,降低了对惩罚参数的依赖,有效提高了图像质量。随后,他们进一步提出了一种结合AL和深度学习(deep learning, DL)网络的混合算法AL-DL,实现了高保真图像重建^[28]。Yao等人^[29]采用广义交替投影(generalized alternating projection, GAP)结合块匹配三维滤波(block matching 3D filtering, BM3D)和全变分(total variation, TV)进行图像去噪,算法十分灵活高效。Zhang等人^[30]基于Unet网络开发了一种端到端的深度学习方法,可以一次性重构所有图像,极大地提高了计算效率。

由于CUP硬件结构相对简洁,因此发展先进算法对提升重构图像的质量尤为重要。现有的算法主要分为两类:传统迭代算法和深度学习算法。其中,传统迭代算法可解释性强,但存在计算精度低和误差大等缺点;深度学习算法计算速度快,但缺少超快场景的训练样本,且模型通用性低,难以快速迁移。为了同时结合传统迭代算法与深度卷积网络各自的优势,并克服各自缺点,我们在交替方向乘子法(alternating direction method of multipliers, ADMM)^[31]的基础上,结合即插即用框架(plug-and-play, PnP)^[32]和深度图像先验(deep image prior, DIP)^[33],开发了一种全新的用于CUP图像重构的混合算法,称为PnP-DIP。该算法具有ADMM的全局收敛性和并行处理能力,非常适合解决大规模优化问题。通过利用DIP的自监督学习,为图像逆问题提供了强大的解决方案,同时结合PnP框架充分发挥了图像去噪器的正则化作用,有效防止模型过拟合。已有研究表明,此类使用去噪正则化作为显式先验来增强免训练神经网络图像逆问题求解性能的混合算法在傅立叶相位检索、孔径编码快照光谱成像、结构光照明显微成像、同轴全息等领域产生了非常显著的性能提升效果^[34-38]。本文所提出的PnP-DIP算法无须预训练,在CUP图像重构过程中同时确保了高保真度和低复杂度。在数据模拟中,与传统ADMM算法相比,该算法在不同图像评价指标上都体现出了显著优势。在实验上,通过对皮秒激光脉冲和X射线闪烁体的CUP压缩采集数据的恢复,证实了PnP-DIP可以有效提升图像的重构精度与准确度。

1 原理

作为一种典型的计算光学成像方法, CUP的整体工作流程由数据采集与图像重构两部分构成。图1(a)显

示了CUP的数据采集流程. 首先, 一个时空三维动态场景 $I(x, y, t)$ 被空间光调制器(如DMD^[12]或透射掩模板^[39])生成的固定随机二进制掩码进行空间编码. 随后, 编码的动态场景被一个时空偏转装置(如条纹相机^[40]或电光偏转器^[25])沿某一空间轴方向进行时空偏移. 最后, 时空编码且偏转的场景通过一个图像传感器(如CMOS或CCD)进行单次曝光测量, 得到一张二维压缩图像 $E(x', y')$. 在数学上, 数据采集过程可以表示为

$$E(x', y') = TSCI(x, y, t) + n, \quad (1)$$

其中, C 表示空间编码算符, S 表示时空偏转算符, T 表示时空积分算符, n 表示图像采集过程中的测量噪声. 若令 $A=TSC$, A 表示整个系统的测量矩阵, $I(x, y, t)$ 和 $E(x', y')$ 被分别简略成 \mathbf{x} 和 \mathbf{y} , 则图像获取过程可被表示为

$$\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{n}, \quad (2)$$

其中, $\mathbf{x} = \text{Vec}(\mathbf{X}) \in \mathbb{R}^{N_x N_y N_t}$, $\mathbf{A} \in \mathbb{R}^{N_x N_y \times N_x N_y N_t}$, $\mathbf{n} = \text{Vec}(\mathbf{N}) \in \mathbb{R}^{N_x N_y}$, $\mathbf{y} = \text{Vec}(\mathbf{Y}) \in \mathbb{R}^{N_x N_y}$. \mathbf{X} , \mathbf{Y} , \mathbf{N} 分别表示对应数据的高阶矩阵形式, N_x , N_y , N_t 分别表示 x , y , t 坐标方向上的离散像素数目.

CUP图像重构的过程即是从已知信号 \mathbf{y} 计算得到待测数据 \mathbf{x} 的过程. 从数学角度出发, 已知 \mathbf{y} 和 \mathbf{A} 求解原始信号 \mathbf{x} 是一个明显的欠定问题, 因为已知数据的数量远小于未知数据的数量, 所以要准确恢复原始信号必须增加其他的正则约束条件, 从而缩小解空间的大小. 需要说明的是, 选择合适的正则化约束条件对最终成像质量有较大的影响. 同时, 由于 \mathbf{A} 的矩阵形式过于庞大, 求解 \mathbf{A}^{-1} 的过程相当耗费计算资源和时间, 因此传统迭代算法使用封闭解^[41]来近似计算逆过程, 这是导致计算误差的主要来源. DIP是一种自监督的网络模型, 它使用随机噪声作为输入, 通过深度卷积网络进行非线性映射, 自动学习如何从观测数据中恢复出高质量的图像内在结构和特征. 由于DIP不依赖于预先训练的数据集, 而是在特定的逆问题环境下动态调整, 为不完整或压缩数据的恢复问题提供了一个强大的解决方案. 在此, 我们通过引入DIP来准确学习CUP成像模型的图像逆过程, 有效降低图像重构误差. 通过引入DIP来代替求逆过程, 式(2)的逆问题可以改写为如下形式的最优化问题:

$$\begin{aligned} \min_{\theta, \mathbf{x}} & \frac{1}{2} \left\| \mathbf{y} - \mathbf{A}\mathbf{G}(\theta, \mathbf{z}) \right\|_2^2 + \lambda R(\mathbf{x}) \\ \text{s.t. } & \mathbf{x} = \mathbf{G}(\theta, \mathbf{z}), \end{aligned} \quad (3)$$

其中, $\|\mathbf{y} - \mathbf{G}(\theta, \mathbf{z})\|$ 称为保真项, $R(\mathbf{x})$ 称为先验项, λ 为正则化参数, 用来平衡保真项和先验项. $\mathbf{G}(\theta, \mathbf{z})$ 代表一个可更新参数的深度卷积神经网络, θ 为网络中可更新的权值参数, 其输入 $\mathbf{z} \in \mathbb{R}^{N_x N_y N_t}$ 是一个与原始数据 \mathbf{x} 同等大小的标准高斯分布白噪声, 并且在优化过程中保持不变, 因此可将 $\mathbf{G}(\theta, \mathbf{z})$ 简写为 $\mathbf{G}(\theta)$. 进一步, 通过引入一个可更新的辅助参数 \mathbf{u} 和一个手动设置的惩罚参数 ρ , 并构造增广拉格朗日函数, 可以将上述带约束的优化问题改写为无约束优化问题:

$$\begin{aligned} \mathcal{L}_\rho(\mathbf{x}, \theta, \mathbf{u}) = & \frac{1}{2} \left\| \mathbf{y} - \mathbf{A}\mathbf{G}(\theta) \right\|_2^2 + R(\mathbf{x}) \\ & + \frac{\rho}{2} \left\| \mathbf{x} - \mathbf{G}(\theta) + \mathbf{u} \right\|_2^2 - \frac{\rho}{2} \left\| \mathbf{u} \right\|_2^2. \end{aligned} \quad (4)$$

利用ADMM框架, \mathcal{L}_ρ 的最小化问题可以分解为以下3个子问题:

$$\begin{aligned} \mathbf{x}_{k+1} = & \underset{\mathbf{x}}{\text{argmin}} R(\mathbf{x}) + \frac{\rho}{2} \left\| \mathbf{x} - (\mathbf{G}(\theta_k) - \mathbf{u}_k) \right\|_2^2 \\ = & \text{prox}_{\frac{R}{\rho}}(\mathbf{G}(\theta_k) - \mathbf{u}_k), \end{aligned} \quad (5)$$

$$\begin{aligned} \theta_{k+1} = & \underset{\theta}{\text{argmin}} \frac{1}{2} \left\| \mathbf{y} - \mathbf{A}\mathbf{G}(\theta) \right\|_2^2 \\ & + \frac{\rho}{2} \left\| \mathbf{G}(\theta_k) - (\mathbf{x}_{k+1} + \mathbf{u}_k) \right\|_2^2, \end{aligned} \quad (6)$$

$$\mathbf{u}_{k+1} = \mathbf{u}_k + (\mathbf{x}_{k+1} - \mathbf{G}(\theta_{k+1})), \quad (7)$$

其中, 下标 k 表示最大迭代次数 O 内的当前迭代次数. 可以观察到, \mathbf{x} 的更新是输入 $\mathbf{G}(\theta) - \mathbf{u}$ 关于 R/ρ 的近端算子的形式. 为了防止DIP过拟合, 我们结合PnP设计, 使用图像降噪算法(例如TV^[42]、FFDNet^[43]和DRUNet^[44])替换近端算子. 对于 θ 的更新, 我们在每次迭代中都简单地进行一阶梯度下降步骤. 整个算法的流程如图1(b)所示. 经过有限次的迭代后, 时空三维信息 $I(x, y, t)$ 就能够被准确重建, 进而获得原始动态场景的时空演化信息.

2 数值模拟

为了定量评价算法的性能, 我们使用数值模拟的方式对所提出的PnP-DIP算法进行了测试和分析, 并与其他几种常用算法的重构性能进行了对比. 我们首先建立了CUP的空间传输模型, 用于产生模拟压缩数据. 用于数值模拟的场景数据都按照图1(a)所示的数据采集方式进行处理. 具体来说, 我们用固定的伪随机二进制掩码对动态场景的所有帧进行空间编码, 然后从第

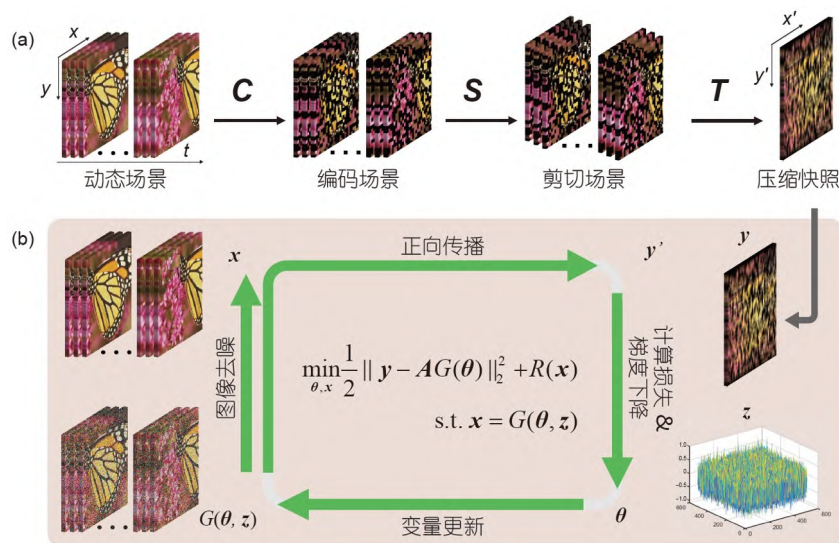


图1 CUP数据流程图. (a) CUP数据采集流程图. (b) PnP-DIP数据重构流程图
 Figure 1 Flowchart of the CUP system. (a) The data acquisition of CUP. (b) The PnP-DIP image reconstruction of CUP

二帧开始, 每帧相对于前一帧向下移动一个像素, 以模拟时间偏转. 最后, 对所有经过偏移的帧沿时间维度进行空间积分, 得到一张二维压缩测量结果. 为了更接近实际情况, 我们还在所有场景的模拟中考虑了噪声等级为 $\sigma=10$ 的加性高斯白噪声. 我们在Python环境下实现了PnP-DIP算法的开发, 其中DIP网络采用Skip-net^[45]模型, 权重优化器设置为Adam, 并使用均方误差作为损失函数. 我们使用7种方法进行了结果对比, 包括: 结合TV、FFDNet和DRUNet的传统ADMM算法, 分别标记为ADMM-TV、ADMM-FFDNet和ADMM-DRUNet; 不附加显式正则化约束的原始DIP算法, 标记为DIP; 以及结合TV、FFDNet和DRUNet的PnP-DIP算法, 分别标记为DIP-TV、DIP-FFDNet和DIP-DRUNet. 所有这些算法都在配备Core i7-12700K CPU和NVIDIA GeForce GTX 3090 GPU的服务器上运行, 以缩短图像重建的时间. 采用峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似度(structural similarity index, SSIM)作为图像评价指标(image quality assessment, IQA), 客观反映算法的重构精度.

我们选取了两种不同类型的动态场景进行仿真. 第一类场景由超高速摄像机拍摄的雷管、焊接、火花、弹簧、喷流、高尔夫、碰撞、火柴、水滴等9个视频场景组成, 每个场景包含20帧连续变化图片, 每张图片的大小为256×256像素, 并涵盖了不同的图像类别和复杂度. 表1列出了所有视频场景使用不同方法重建

结果的PSNR和SSIM值, 最佳结果以粗体突出显示. 可以看出, 在使用同样降噪器(TV、FFDNet、DRUNet)的前提下, PnP-DIP类方法的平均PSNR(SSIM)比ADMM类方法分别高出1.26 dB(0.0246), 2.52 dB(0.0189), 3.34 dB(0.0300). 而无论是在ADMM类方法还是在PnP-DIP类方法中, DRUNet均表现出了比FFDNet和TV更加优秀的结果. 此外, 由于原始DIP算法缺少合适的正则化约束, 导致算法的收敛性和稳定性较差, 且对噪声敏感, 即使在部分场景中PSNR(SSIM)数值较高, 其整体优势并不明显.

图2是分别用表1所示算法重构的雷管、焊接、火花、弹簧、喷流、高尔夫、碰撞、火柴、水滴场景的其中一帧重构图像, 并给出了与相应原始图像的视觉对比. 从重建图像和红框中放大的图像块可以看出, ADMM类方法均不能很好地恢复图像细节, 它们的重建都会产生不同程度的图像模糊和伪影. 即使使用原始DIP方法, 焊接、碰撞和火柴等几种场景下的重建结果仍然显示出明显的退化结构. 相比之下, PnP-DIP类方法可以产生更清晰的边界和更好的图像细节, 特别是对于对比度不明显的阴影结构(如喷流)和不规则结构(如高尔夫). PnP-DIP结合DRUNet可以实现当前最好的重构效果, 即使在20倍的高数据压缩比之下, 依然可以得到接近原始图像的重构结果.

为了表征算法的计算效率, 我们对比了不同方法处理相同数据的运行时间. 用于对比的算法除了上述

表 1 不同方法重构视频数据的PSNR(dB)和SSIM^{a)}

Table 1 PSNR (dB) and SSIM values of video data reconstructed by different methods

方法	IQAs	数据集									
		雷管	焊接	火花	弹簧	喷流	高尔夫	碰撞	火柴	水滴	平均值
ADMM-TV	PSNR	23.93	33.57	23.29	25.81	28.99	23.36	29.28	27.37	25.74	26.75
	SSIM	0.7502	0.9628	0.8589	0.8295	0.9166	0.7433	0.8168	0.8820	0.8430	0.8401
ADMM-FFDNet	PSNR	26.40	31.97	26.38	30.41	32.35	24.12	31.96	30.48	27.20	28.85
	SSIM	0.7653	0.9407	0.9105	0.9295	0.9171	0.7629	0.8718	0.8989	0.8698	0.8709
ADMM-DRUNet	PSNR	26.21	31.78	26.70	33.11	33.19	24.28	35.66	32.25	27.56	29.81
	SSIM	0.7587	0.9661	0.9306	0.9552	0.9316	0.7843	0.9452	0.9348	0.8928	0.8956
DIP	PSNR	24.50	35.80	22.56	29.19	33.65	22.95	27.23	27.37	28.42	28.04
	SSIM	0.6666	0.9698	0.8113	0.8324	0.9167	0.6525	0.6817	0.8365	0.8341	0.7956
DIP-TV	PSNR	25.96	36.44	23.93	28.17	27.24	25.01	30.08	34.38	27.25	28.01
	SSIM	0.6500	0.9811	0.8951	0.8964	0.9234	0.8229	0.8153	0.9760	0.9336	0.8647
DIP-FFDNet	PSNR	29.96	36.72	29.12	32.48	34.02	27.29	28.33	35.67	33.00	31.37
	SSIM	0.8724	0.9531	0.9532	0.9444	0.9635	0.8495	0.6177	0.9750	0.9649	0.8898
DIP-DRUNet	PSNR	30.50	43.49	31.44	36.22	36.52	27.44	31.98	36.42	27.59	33.15
	SSIM	0.8771	0.9918	0.9605	0.9670	0.9693	0.8520	0.8507	0.9739	0.9363	0.9256

a) 最佳结果以粗体突出显示

ADMM-TV、ADMM-FFDNet、ADMM-DRUNet、DIP、DIP-TV、DIP-FFDNet和DIP-DRUNet外,还包括在传统迭代算法中具有最佳重构性能的DeSCI算法^[41],以及代表性的端到端深度展开算法Unrolling-ADMM^[46].所有算法在相同配置的电脑上处理图2中所展示的9组原始数据大小为256×256×20的数据集,并计算不同算法的平均运行时间,结果如表2所示.值得注意的是, GPU参与加速计算的方法,其运行时间使用“*”标记.从表2中可以看出,运行时间最短的是Unrolling-ADMM,但是由于其端到端的网络结果需要预先训练,针对CUP模型其训练时间为21 h.在其他迭代型算法中,不同方法的运行时间主要与使用的去噪器相关,PnP-DIP类方法相比较ADMM类方法,在使用相同去噪器时,其运行时间约是ADMM类方法的20倍,但仍远小于使用加权核范数最小化去噪器的DeSCI算法.

第二种类型的模拟数据包含一组由泵浦探测显微镜拍摄的激光烧蚀冲击波传播过程的20帧图像序列^[5]和一组由多序列激光阴影成像法拍摄的Z箍缩成丝过程的15帧图像序列^[21],用于测试算法在真实超快场景中的表现.在真实超快场景的重建中,ADMM类方法和PnP-DIP类方法中的所有参数设置与运动图像场景中相同.图3(a, b)展示了两种场景由不同方法重建后从结果中选取的5帧,其下方数字表示当前帧相对于原始

数据的PSNR(dB)和SSIM值.由于原始DIP的重构结果不可重复且偶然性较大,此处不予展示和比较.通过对重构结果的分析,在真实超快场景下也可以得到同样的结论,即PnP-DIP类方法优于使用相同去噪器下的ADMM类方法,而且PnP-DIP类方法的重建质量展示出了明显的优势.在Z箍缩这种具有精细结构的场景中,对于背景和细节的恢复,PnP-DIP类方法具有最佳的性能.图3(c, d)展示了两种场景不同方法重构结果所有帧的平均PSNR和SSIM.从数据直方图中可以看出,在真实超快场景中,PnP-DIP类方法的提升更加明显.在使用同样降噪器(TV、FFDNet、DRUNet)的前提下,激光烧蚀场景中,PnP-DIP类方法的平均PSNR(SSIM)比ADMM类方法分别高出3.88 dB(0.0814), 3.08 dB(0.0282), 2.36 dB(0.0146); Z箍缩场景中,PnP-DIP类方法的平均PSNR(SSIM)比ADMM类方法分别高出4.42 dB(0.1465), 7.59 dB(0.0769), 10.55 dB(0.0424).数值模拟结果表明,我们的算法在所有的数据集上都优于其他算法,同时具有较高的鲁棒性和可扩展性.

3 实验结果

通过数值模拟证明了所发展PnP-DIP算法在CUP图像重建中比传统ADMM类算法具有更高的图像质量和更强的抗噪声能力.接下来,我们将该算法应用于重




图2 不同算法用于恢复视频场景的结果比较. 其中红色方框内为绿色方框对应位置的局部放大图

Figure 2 Comparison of the results of different methods used to reconstruct the video scene. The subfigures in the red boxes are the local zoomed-in images of the corresponding positions in the green boxes

构自主研制CUP系统记录的瞬态场景, 进一步实验验证其图像重构性能. 本文所使用的CUP实验装置如图4

表2 不同方法的运行时间^{a)}

Table 2 Running time of different methods

方法	运行时间(s)
DeSCI	7725.88
Unrolling-ADMM	2.64 [*] (Train 21 h)
DIP	312.93 [*]
ADMM-TV	17.54
ADMM-FFDNet	24.21 [*]
ADMM-DRUNet	227.56 [*]
DIP-TV	342.08 [*]
DIP-FFDNet	583.91 [*]
DIP-DRUNet	4606.02 [*]

a) “*”表示GPU参与加速计算的运行时间

所示. 首先, 超快动态场景被透镜1和透镜2组成的4f系统成像到透射式掩模板上, 掩模板在不同空间位置上选择性透过, 产生随机空间编码. 然后, 编码场景被透镜3和透镜4组成的4f系统成像到狭缝完全打开的条纹相机(Hamamatsu, C7700)中, 以进行时空偏转和积分. 条纹相机和瞬态场景通过数字延迟发生器(Stanford Research, DG645)在时间上精确同步. 结合所提出的PnP-DIP算法和自主研制的CUP系统, 我们测量了空间调制的E形皮秒激光脉冲的时空演变和X射线闪烁体的二维强度演化.

如图5(a)所示, 在第一个场景中, 来自锁模Ti:Sapphire激光放大器(光谱物理, 50 fs, 0.8 mJ)的单个激光脉冲被脉冲展宽器拉伸到200 ps. 被拉伸的脉冲在空间上扩束, 照亮了一个黑色尼龙板上的空心字母“E”. 空心字母内部的光子可以穿过板, 而外部的光子则被阻

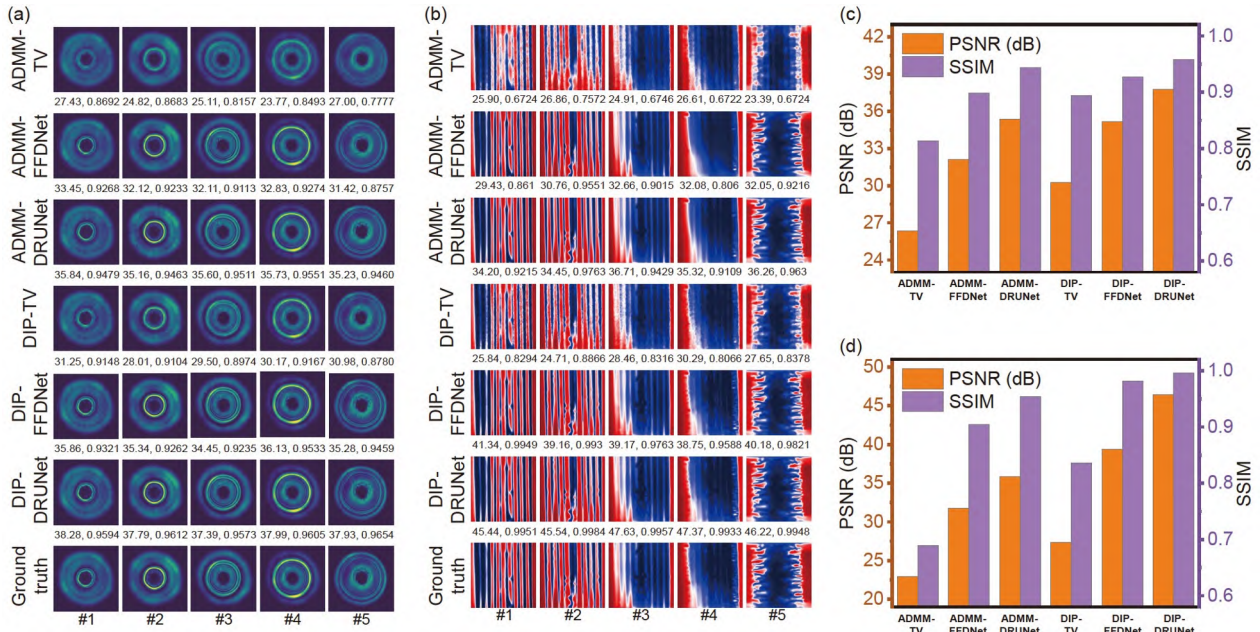


图3 不同方法用于恢复超快场景的结果比较。(a, b) 选取的采用不同方法从泵浦探针显微镜和多序列激光阴影图中超快动态场景重建图像帧, 以及用于比较的原始图像。(c, d) 不同方法的平均PSNR和SSIM直方图
 Figure 3 Comparison of results of different methods used to reconstruct ultrafast scenes. (a, b) Selected image frames of ultrafast dynamic scene reconstruction from pump-probe microscopy and multisequence laser shadowgraphs using different methods, and the ground truth used for comparison. (c, d) Average PSNR and SSIM histograms for different methods

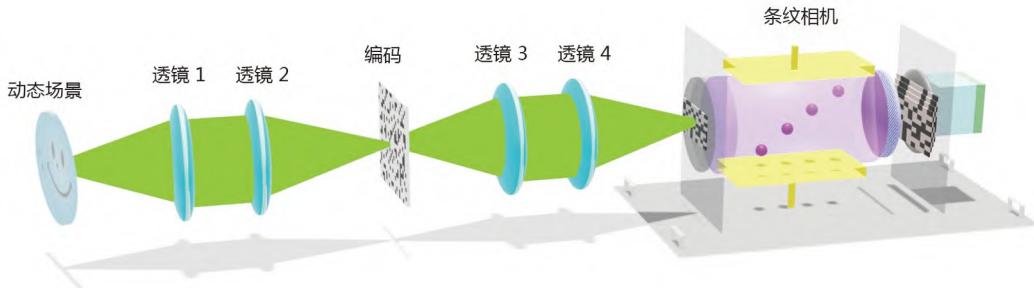


图4 CUP实验装置图
 Figure 4 Diagram of the CUP experimental setup

挡, 以此对光束进行空间调制. 得到的E形激光脉冲被投射到一张薄白纸上产生散射, 并通过CUP系统进一步观测, 采集得到的一张压缩图像如图5(b)所示. 利用所提出的PnP-DIP类方法和传统ADMM类方法, 分别重构出了21张E形激光脉冲的时空演化图像. 由于在真实数据中, TV去噪器的成像效果较卷积神经网络去噪器相差太多, 故此处仅展示使用FFDNet和DRUNet的结果. 从重构场景中选取10帧代表性帧, 每帧时间间隔为30 ps, 归一化结果如图5(c)所示. 从图5(c)可以看出, 在空间结构上, ADMM-FFDNet和ADMM-DRUNet的

结果表现出明显的不完整性, 而DIP-FFDNet和DIP-DRUNet的结果更接近真实情况. 此外, PnP-DIP类方法在提高重建图像的动态范围方面具有绝对优势, 如90和-90 ps时刻的图片所示. 同时, 可以发现DRUNet对弱光图像的重建质量明显优于FFDNet去噪器, 如120 ps时刻的图片所示. 为了对比不同算法对空间细节的还原程度, 我们在图5(c)中沿着白色虚线绘制了-30 ps帧的归一化强度, 并与条纹相机静态采集的图像进行了对比, 结果如图5(d)所示. 与前述对比结果相似, 在4个峰中, DIP-DRUNet的空间强度分布与静态结果

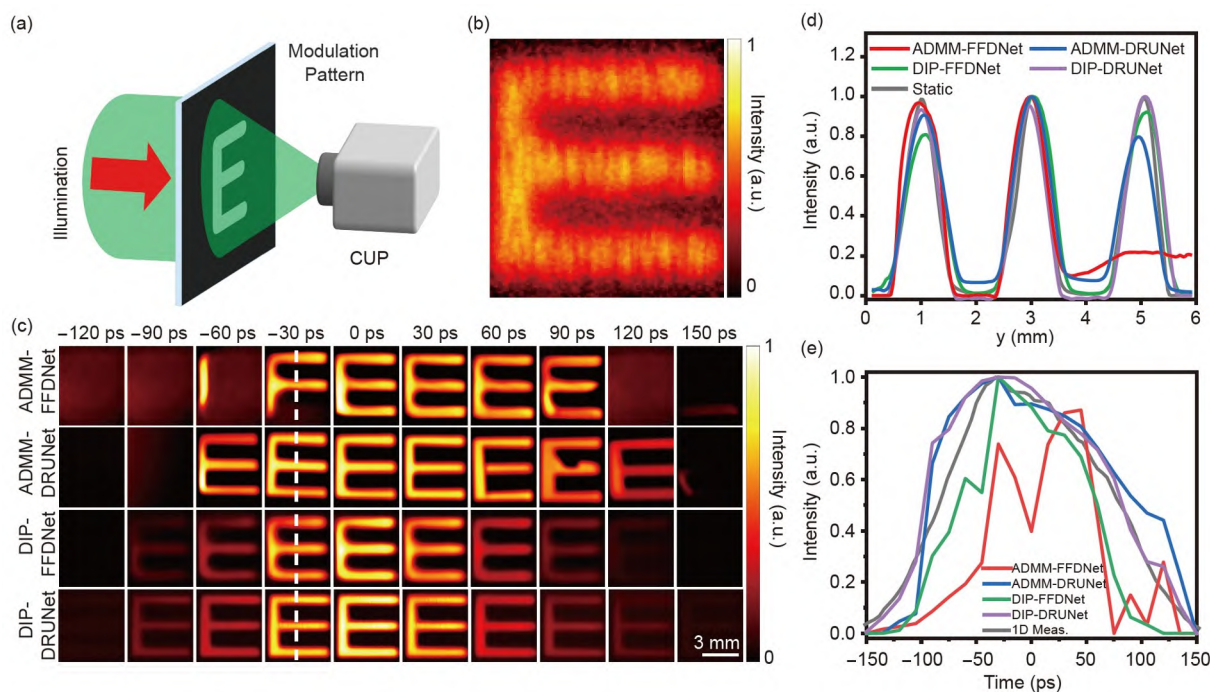


图 5 E形激光脉冲的时空测量. (a) 用于测量E形激光脉冲的实验装置. (b) E形激光脉冲的二维压缩测量图像. (c) 不同方法的重构结果. (d) 不同方法重建结果在-30 ps时刻沿(b)中白色虚线方向的归一化强度分布. (e) 不同方法重建结果的归一化强度演化, 以及条纹相机一维模式测量的强度变化结果

Figure 5 Spatio-temporal measurement of E-shaped laser pulses. (a) Experimental setup for measuring E-shaped laser pulses. (b) Two-dimensional compressed measurement image of E-shaped laser pulses. (c) Reconstruction results from different methods. (d) Normalized intensity distribution along the white dashed line direction in (b) at -30 ps frame for the reconstruction results of different methods. (e) Normalized intensity evolution of the reconstruction results of different methods, and the intensity change results measured by the streak camera in 1D mode

仍然保持最高的吻合度. 此外, 由图5(d)计算得出的ADMM-FFDNet、ADMM-DRUNet、DIP-FFDNet和DIP-DRUNet分布曲线的均方根误差(root-mean-square error, RMSE)分别为0.0519、0.0128、0.0134和0.0062, 同样表明DIP-DRUNet的重构结果最接近真实情况. 为了进一步比较不同方法还原强度演化信息的准确性, 我们计算了不同方法重构结果逐帧的二维强度积分值, 同时使用条纹相机在一维动态模式下测量了真实强度演化, 并对所有数据进行了归一化处理, 结果如图5(e)所示. 从图5(e)可以很容易地看出, DRUNet去噪器的结果优于使用FFDNet的方法, 特别是DIP-DRUNet与一维测量结果最为近似.

如图6(a)所示, 在第二个场景中, 为了观测Z箍缩过程中等离子体发射X射线的辐射参数及其时空分布特性, 通过闪烁体将等离子体辐射的X射线转换成可见光信号, 并使用CUP测量了X射线闪烁体的发光动力学. 同样, 通过利用所提出的PnP-DIP类方法和ADMM类方法重建出了60帧时空演化图像. 为了进行比较, 从中

以2 ns时间间隔挑选了30~48 ns时间延迟下的10幅代表性图像, 如图6(b)所示. 可以直观地观察到, PnP-DIP类方法的强度分布更加均匀. 此外, 在压缩测量过程中, 我们使用门控CCD记录了一张36 ns时刻X射线闪烁体的发光图像, 如图6(c)所示. 我们同样计算了不同方法重构结果逐帧的二维强度积分值归一化结果, 并与示波器直接记录的X射线强度数据进行了对比, 结果如图6(d)所示. 从图6(d)可以很容易地看出, DIP-DRUNet的结果与点测量结果最为吻合, 特别是47 ns处的小波峰, 与真实值基本一致. 这说明我们的方法在处理弱光信号时具有很好的鲁棒性和稳定性, 而弱光信号在超快光学场景中通常难以探测. 为了对比空间分布的重构准确性, 沿图6(c)中白色虚线绘制门控图像的归一化强度, 并对所有二维重构结果的36 ns帧做了相同处理, 所有结果绘制于图6(e)中. 可以看出, 门控CCD记录的X射线在轴向位置的强度呈现对称分布, 表明负载的质量与驱动电流匹配良好, 等离子体的内爆是同步的^[47]. ADMM类方法的重构结果完全不对称, 容易对原始场

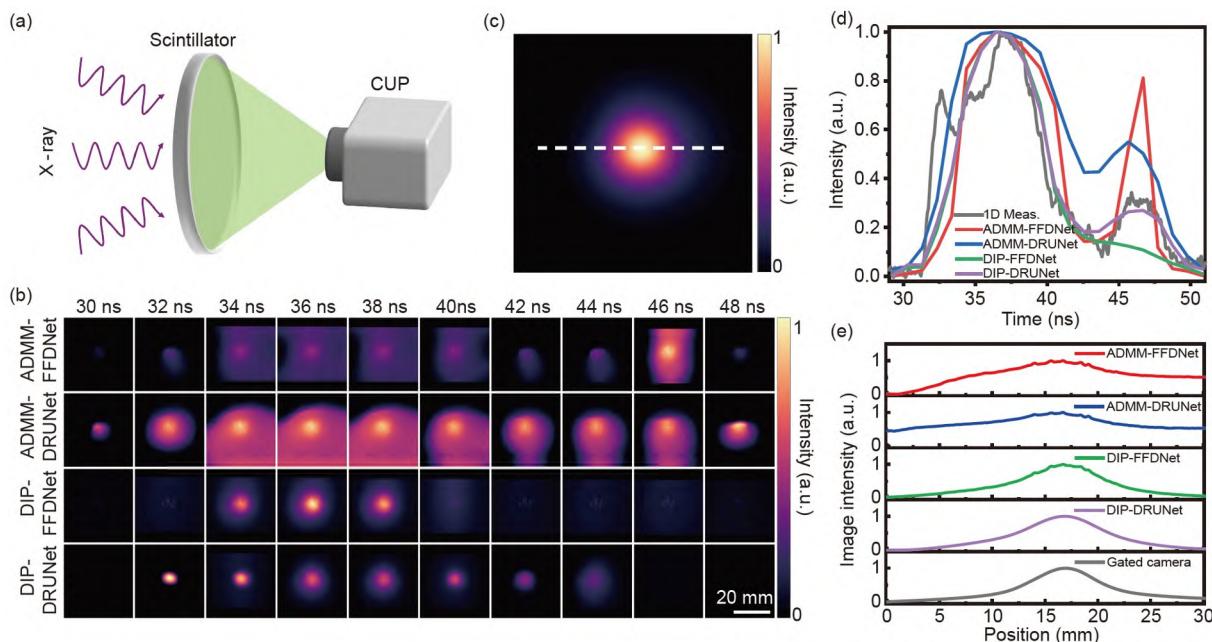


图 6 X射线闪烁体的发光强度测量. (a) X射线闪烁体探测装置示意图. (b) 不同方法的重构结果. (c) 外置门控CCD拍摄的36 ns时X射线闪烁体图像. (d) 不同方法重构的X射线辐射强度演化的归一化曲线. (e) (c)中白色虚线处和不同方法重构结果36 ns时刻图像相同位置处轴向空间上X射线辐射强度的分布曲线

Figure 6 Luminous intensity measurement of X-ray scintillators. (a) Schematic diagram of the X-ray scintillator detection. (b) Reconstruction results of different methods. (c) X-ray scintillator image of 36 ns taken by an external gated CCD. (d) Normalized curves of the evolution of X-ray radiation intensity reconstructed by different methods. (e) The distributions of X-ray radiation intensities in the axial space along the white dashed line in (c), and the corresponding positions in the image at the 36 ns moment in the reconstruction of various results

景的分析产生误导，而DIP-DRUNet在整体和局部细节上都与门控CCD的结果相同。显然，DIP-DRUNet为进一步提高X射线检测的准确性提供了一种有效的方法，这为分析X射线内部情况提供了充足的依据。实验结果表明，我们的方法在空间分辨率、空间连续性和空间异质性方面都优于其他方法，能够更准确地反映出时空数据的内在规律和特征。

4 总结

综上所述，我们在ADMM算法的基础上，开发了一种结合深度图像先验和即插即用去噪器的混合算法，简称PnP-DIP，用于实现CUP中二维压缩数据到三维原始数据的高保真度低复杂度重构。分别使用高速视频场景和真实超快场景进行了数值模拟，用于验证PnP-DIP算法的重建能力。与传统ADMM类算法相比，所提出的方法在PSNR和SSIM两种评价指标中均具有最佳

性能。此外，我们还基于自主研发的CUP系统，测量了皮秒光场的时空演化和X射线闪烁体的发光过程，并利用该算法实现了高精度的重构。实验数据的图像细节和阴影纹理重建结果表明，所提出的方法能有效改善空间细节。由于DIP的灵活性，该算法还可以推广到高光谱压缩超快成像(hyperspectrally CUP, HCUP)^[48]、光谱—立体压缩超快成像(spectral-volumetric CUP, SV-CUP)^[49]等多维成像模型，实现更高维数据的恢复，扩大CUP类技术在捕捉复杂超快物理事件方面的应用范围。当然，PnP-DIP类方法依然存在进一步提升重构质量的空间。比如，利用扩散概率模型^[50]代替DIP模型，使用视觉变换器去噪器^[51]代替卷积神经网络去噪器，二者均可以充分利用压缩数据的全局和局部稀疏特性，从而生成更高质量的重建图像。我们期望该研究可以推动CUP在高时空分辨观测需求中的应用，并为超快动力学的实时探测作出重大贡献。

参考文献

1 Liang J, Wang L V. Ultrafast optical imaging. Handbook of Laser Technology and Applications. Boca Raton: CRC Press, 2021. 315–328

- 2 Mikami H, Gao L, Goda K. Ultrafast optical imaging technology: Principles and applications of emerging methods. *Nanophotonics*, 2016, 5: 497–509
- 3 Wan Y, Stradomska A, Knoester J, et al. Direct imaging of exciton transport in tubular porphyrin aggregates by ultrafast microscopy. *J Am Chem Soc*, 2017, 139: 7287–7293
- 4 Pan C, Jiang L, Sun J, et al. Ultrafast optical response and ablation mechanisms of molybdenum disulfide under intense femtosecond laser irradiation. *Light Sci Appl*, 2020, 9: 80
- 5 Yao J, Qi D, Liang H, et al. Exploring femtosecond laser ablation by snapshot ultrafast imaging and molecular dynamics simulation. *Ultrafast Sci*, 2022, 2022: 9754131
- 6 Stanford Computer Optics Inc. High speed ICCD framing camera family: XXRapidFrame. <https://stanfordcomputeroptics.com/products/iccd-framing-camera.html>
- 7 Baker K, Stewart R, Steele P, et al. Solid-state framing camera with multiple time frames. *Appl Phys Lett*, 2013, 103: 839–829
- 8 Li Z, Zgadaj R, Wang X, et al. Single-shot tomographic movies of evolving light-velocity objects. *Nat Commun*, 2014, 5: 3085
- 9 Nakagawa K, Iwasaki A, Oishi Y, et al. Sequentially timed all-optical mapping photography (STAMP). *Nat Photonics*, 2014, 8: 695–700
- 10 Suret P, Koussaifi R E, Tikan A, et al. Single-shot observation of optical rogue waves in integrable turbulence using time microscopy. *Nat Commun*, 2016, 7: 13136
- 11 Ehn A, Bood J, Li Z, et al. FRAME: femtosecond videography for atomic and molecular dynamics. *Light Sci Appl*, 2017, 6: e17045
- 12 Gao L, Liang J, Li C, et al. Single-shot compressed ultrafast photography at one hundred billion frames per second. *Nature*, 2014, 516: 74–77
- 13 Qi D, Zhang S, Yang C, et al. Single-shot compressed ultrafast photography: A review. *Adv Photonics*, 2020, 2: 014003
- 14 Liang J, Zhu L, Wang L V. Single-shot real-time femtosecond imaging of temporal focusing. *Light Sci Appl*, 2018, 7: 42
- 15 Cao F, Yang C, Qi D, et al. Single-shot spatiotemporal intensity measurement of picosecond laser pulses with compressed ultrafast photography. *Opt Lasers Eng*, 2019, 116: 89–93
- 16 Jing J C, Wei X, Wang L V. Spatio-temporal-spectral imaging of non-repeatable dissipative soliton dynamics. *Nat Commun*, 2020, 11: 2059
- 17 Kim T, Liang J, Zhu L, et al. Picosecond-resolution phase-sensitive imaging of transparent objects in a single shot. *Sci Adv*, 2020, 6: eaay6200
- 18 Jin C, Qi D, Yao Y, et al. Single-shot real-time imaging of ultrafast light springs. *Sci China-Phys Mech Astron*, 2021, 64: 124212
- 19 Fan L, Yan X, Wang H, et al. Real-time observation and control of optical chaos. *Sci Adv*, 2021, 7: eabc8448
- 20 Zhang Y, Shen B, Wu T, et al. Ultrafast and hypersensitive phase imaging of propagating internodal current flows in myelinated axons and electromagnetic pulses in dielectrics. *Nat Commun*, 2022, 13: 5247
- 21 Yao Z M, Sheng L, Song Y, et al. Dual-channel compressed ultrafast photography for Z-pinch dynamic imaging. *Rev Sci Instr*, 2023, 94: 035106
- 22 Mishra Y N, Wang P, Bauer F J, et al. Single-pulse real-time billion-frames-per-second planar imaging of ultrafast nanoparticle-laser dynamics and temperature in flames. *Light Sci Appl*, 2023, 12: 47
- 23 Yang C, Qi D, Wang X, et al. Optimizing codes for compressed ultrafast photography by the genetic algorithm. *Optica*, 2018, 5: 147–151
- 24 Liang J, Ma C, Zhu L, et al. Single-shot real-time video recording of a photonic Mach cone induced by a scattered light pulse. *Sci Adv*, 2017, 3: e1601814
- 25 Yang C, Qi D, Cao F, et al. Single-shot receive-only ultrafast electro-optical deflection imaging. *Phys Rev Appl*, 2020, 13: 024001
- 26 Qi D, Cao F, Xu S, et al. 100-Trillion-frame-per-second single-shot compressed ultrafast photography via molecular alignment. *Phys Rev Appl*, 2021, 15: 024051
- 27 Yang C, Qi D, Cao F, et al. Improving the image reconstruction quality of compressed ultrafast photography via an augmented Lagrangian algorithm. *J Opt*, 2019, 21: 035703
- 28 Yang C, Yao Y, Jin C, et al. High-fidelity image reconstruction for compressed ultrafast photography via an augmented-Lagrangian and deep-learning hybrid algorithm. *Photon Res*, 2021, 9: B30
- 29 Yao J, Qi D, Yao Y, et al. Total variation and block-matching 3D filtering-based image reconstruction for single-shot compressed ultrafast photography. *Opt Lasers Eng*, 2021, 139: 106475
- 30 Zhang A, Wu J, Suo J, et al. Single-shot compressed ultrafast photography based on U-net network. *Opt Express*, 2020, 28: 39299–39310
- 31 Chan S H, Wang X, Elgendy O A. Plug-and-play ADMM for image restoration: Fixed-point convergence and applications. *IEEE Trans Comput Imag*, 2016, 3: 84–98
- 32 Zhang K, Li Y, Zuo W, et al. Plug-and-play image restoration with deep denoiser prior. *IEEE Trans Pattern Anal Mach Intell*, 2021, 44: 6360–6376
- 33 Ulyanov D, Vedaldi A, Lempitsky V. Deep image prior. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake City: IEEE, 2018. 9446–9454
- 34 Ma L, Wang H, Leng N, et al. Untrained neural network embedded Fourier phase retrieval from few measurements. *Signal Proc*, 2024, 219: 109396
- 35 Meng Z, Yu Z, Xu K, et al. Self-supervised neural networks for spectral snapshot compressive imaging. In: Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Montreal: IEEE, 2021. 2622–2631

- 36 He Y, Yao Y, He Y, et al. Surpassing the resolution limitation of structured illumination microscopy by an untrained neural network. *Biomed Opt Express*, 2023, 14: 106–117
- 37 Galande A S, Thapa V, Gurrum H P R, et al. Untrained deep network powered with explicit denoiser for phase recovery in inline holography. *Appl Phys Lett*, 2023, 122: 133701
- 38 Qayyum A, Ilahi I, Shamshad F, et al. Untrained neural network priors for inverse imaging problems: A survey. *IEEE Trans Pattern Anal Mach Intell*, 2022, 45: 6511–6536
- 39 Yao J, Qi D, Yang C, et al. Multichannel-coupled compressed ultrafast photography. *J Opt*, 2020, 22: 085701
- 40 Takahashi A, Nishizawa M, Inagaki Y, et al. New femtosecond streak camera with temporal resolution of 180 fs. In: *Generation, Amplification, and Measurement of Ultrashort Laser Pulses*. Los Angeles: SPIE, 1994, 2116: 275–284
- 41 Liu Y, Yuan X, Suo J, et al. Rank minimization for snapshot compressive imaging. *IEEE Trans Pattern Anal Mach Intell*, 2018, 41: 2990–3006
- 42 Yuan X. Generalized alternating projection based total variation minimization for compressive sensing. In: *2016 IEEE International Conference on Image Processing (ICIP)*. Phoenix: IEEE, 2016. 2539–2543
- 43 Yuan X, Liu Y, Suo J, et al. Plug-and-play algorithms for large-scale snapshot compressive imaging. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Seattle: IEEE, 2020. 1447–1457
- 44 Jin C, Qi D, Yao J, et al. Weighted multi-scale denoising via adaptive multi-channel fusion for compressed ultrafast photography. *Opt Express*, 2022, 30: 31157–31170
- 45 Wang X, Yu F, Dou Z Y, et al. Skipnet: Learning dynamic routing in convolutional networks. In: *Proceedings of the European Conference on Computer Vision (ECCV)*. Munich: Springer Science, 2018. 409–424
- 46 Ma J, Liu X Y, Shou Z, et al. Deep tensor admm-net for snapshot compressive imaging. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*. Seoul: IEEE, 2019. 10223–10232
- 47 Zhou S, Xie W, Huang X, et al. A scintillator-based soft X-ray streak camera system for Z-pinch experiments on the Primary Test Stand. *Rev Sci Instr*, 2019, 90: 073703
- 48 Yang C, Cao F, Qi D, et al. Hyperspectrally compressed ultrafast photography. *Phys Rev Lett*, 2020, 124: 023902
- 49 Ding P, Yao Y, Qi D, et al. Single-shot spectral-volumetric compressed ultrafast photography. *Adv Photon*, 2021, 3: 045001
- 50 Li H, Yang Y, Chang M, et al. SRDiff: Single image super-resolution with diffusion probabilistic models. *Neurocomputing*, 2022, 479: 47–59
- 51 Zamir S W, Arora A, Khan S, et al. Restormer: Efficient transformer for high-resolution image restoration. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. New Orleans: IEEE, 2022. 5728–5739

Summary for “基于免训练自监督式神经网络算法实现压缩超快成像高保真图像重构”

Realizing high-fidelity image reconstruction for compressed ultrafast photography with an untrained self-supervised neural network-based algorithm

Chengzhi Jin¹, Dalong Qi^{1*}, Yu He¹, Jiali Yao¹, Zihan Guo¹, Ning Xu¹, Long Cheng¹, Jiayi Mao¹, Zhiming Yao², Yan Song², Yunhua Yao¹, Yuecheng Shen¹, Lianzhong Deng¹, Liang Sheng², Zhenrong Sun¹ & Shian Zhang^{1,3,4*}

¹ State Key Laboratory of Precision Spectroscopy, School of Physics and Electronic Science, East China Normal University, Shanghai 200241, China;

² National Key Laboratory of Intense Pulsed Radiation Simulation and Effect, Northwest Institute of Nuclear Technology, Xi'an 710024, China;

³ Collaborative Innovation Center of Extreme Optics, Shanxi University, Taiyuan 030006, China;

⁴ Joint Research Center of Light Manipulation Science and Photonic Integrated Chip of East China Normal University and Shandong Normal University, East China Normal University, Shanghai 200241, China

* Corresponding authors, E-mail: dlqi@lps.ecnu.edu.cn; sazhang@phy.ecnu.edu.cn

Compressed ultrafast photography (CUP) is currently the fastest passive single-shot ultrafast optical imaging technology, serving as a potent tool for recording irreversible or difficult-to-repeat ultrafast events, as well as enabling the detection of self-luminescent transient scenes, such as fluorescence dynamics. CUP realizes the recording of ultrafast events through two steps, data acquisition and image reconstruction, and has achieved an ultrahigh sequence depth of over 300 frames and an ultrafast imaging speed of 10 million frames per second, significantly surpassing traditional imaging techniques. However, CUP suffers from low spatial resolution due to its high data compression ratio and undersampling characteristics. Furthermore, the image reconstruction process based on compressive sensing theory is complex and demands extensive computing resources. This limitation curtails CUP's ability to observe ultrafast phenomena with high spatial resolution. Recent efforts to enhance CUP performance have concentrated on enhancing both hardware and algorithmic components. As the hardware structure of CUP is relatively fixed, the advancement of sophisticated algorithms is particularly crucial in improving the quality of reconstructed images. Existing algorithms can be categorized into traditional iterative algorithms and deep learning algorithms. Pure deep learning algorithms face challenges related to the availability of training samples and model generality, hindering rapid transfer. Conversely, traditional iterative algorithms exhibit low computational accuracy and large errors. To address these challenges, we developed a new hybrid algorithm, which combines the plug-and-play (PnP) framework and deep image prior (DIP), named PnP-DIP, drawing upon the advantages of untrained neural networks and traditional iterative algorithms. The PnP-DIP algorithm is based on the alternating direction method of multipliers (ADMM) algorithm, which provides global convergence and parallel processing capabilities, making it highly suitable for tackling large-scale optimization problems. PnP-DIP employs self-supervised learning from DIP to provide a robust solution for image inverse problems and integrates the PnP framework for image denoising to serve as a regularizer, effectively preventing model overfitting. Notably, the proposed algorithm does not require pretraining and ensures both high fidelity and low complexity during the reconstruction process. To quantitatively evaluate the algorithm's performance, the proposed PnP-DIP algorithm is tested and analyzed using numerical simulations, and the reconstruction performance is compared with several commonly used algorithms. The simulation experimental results demonstrate that the proposed algorithm surpasses all competitors in terms of performance on all datasets, exhibiting exceptional robustness and scalability. Furthermore, the PnP-DIP algorithm was applied to reconstruct transient scenes recorded by a custom-built CUP system. This application enabled the measurement of the spatiotemporal evolution of a spatially modulated E-shaped picosecond laser pulse and the two-dimensional intensity evolution of an X-ray scintillator. The results revealed that the proposed method excelled in spatial resolution, continuity, and heterogeneity, accurately reflecting the inherent laws and features of spatial data, thus paving the way for practical applications of CUP. The flexibility of DIP allows this algorithm to be extended to multidimensional imaging models such as hyperspectral CUP and spectral-volumetric CUP, enabling the recovery of higher-dimensional data and expanding the application of CUP-based technology in capturing complex ultrafast physical events. This research is projected to promote the application of CUP in scenarios requiring high spatiotemporal resolution and make a significant contribution to the development of fundamental and applied sciences.

compressed ultrafast photography, image reconstruction, alternating direction method of multipliers, plug-and-play framework, deep image prior

doi: [10.1360/TB-2024-0038](https://doi.org/10.1360/TB-2024-0038)