

基于强化学习的免调参即插即用单光子 图像重建方法

陈 爽^{1,3}, 田 焱^{2,3}, 付 莹^{1,3*}

(1. 北京理工大学计算机学院, 北京 100081; 2. 北京理工大学信息与电子学院, 北京 100081;
3. 北京理工大学复杂环境智能感知技术工信部重点实验室, 北京 100081)

摘 要: 量子图像传感器(Quanta Image Sensor, QIS)具有超高的单光子灵敏度与空间分辨率,因此其有望成为替代 CMOS 的下一代图像传感器。然而,从 QIS 获取的原始数据是二进制的图像帧,因此需要采用图像重建算法从二进制观测值中恢复原始场景。现有的方法包括基于模型的 QIS 图像重建和基于深度学习的 QIS 图像重建,其中基于模型的 QIS 图像重建通常需要进行大量的优化迭代,且对内部参数选择高度敏感。而基于深度学习的 QIS 图像重建则往往需要对每个具有细微不同的任务设计和训练单独的网络模型,灵活性欠缺并在很大程度上限制了其实用性。为了解决上述 QIS 图像重建方法的局限性,本文提出一种基于强化学习的免调参即插即用单光子图像重建方法。该方法能够自适应地对不同输入图像、不同过采样倍率和重建所处的不同迭代轮次动态选取合适的参数,实现更好的重建效果。具体地,本文将即插即用框架下的 QIS 图像重建任务中需要手动调整的参数建模为序列决策问题,引入结合无模型强化学习和基于模型强化学习思想的算法学习一个最佳策略,以实现对于不同输入图像在每次优化迭代时的最优超参选择。在合成和真实数据集上的实验结果表明,本文提出的方法可以在过采样倍率为 4、6、8 三种情况下,在峰值信噪比上相较现有先进方法提高约 0.44~0.60 dB,在重建的视觉效果上也能够保留更多的纹理细节。真实极暗光 QIS 图像数据已在 <https://github.com/ying-fu/Real-SPAD-Dataset> 公开。

关键词: 量子图像传感器;单光子成像;即插即用;强化学习;图像重建

基金项目: 国家自然科学基金(No.62331006, No.62171038, No.62088101);中央高校基本科研业务费专项资金

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112(2024)10-3600-13

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20230343

Reinforcement Learning Based Tuning-free Plug-and-Play Image Reconstruction Method for Single Photon Imaging

CHEN Shuang^{1,3}, TIAN Ye^{2,3}, FU Ying^{1,3*}

(1. School of Computer Science and Technology, Beijing Institute of Technology, Beijing 100081, China;

2. School of Information and Electronics, Beijing Institute of Technology, Beijing 100081, China;

3. MIIT Key Laboratory of Complex-Field Intelligent Exploration, Beijing Institute of Technology, Beijing 100081, China)

Abstract: Quantum image sensor (QIS) has ultra-high single-photon sensitivity and spatial resolution, making it a promising alternative to CMOS image sensor (CIS) as the next-generation image sensor. However, image reconstruction of QIS differs from traditional image reconstruction methods, it aims to recover the original scene from binary measurements. The existing methods include model-based QIS image reconstruction and deep learning-based QIS image reconstruction. Model-based methods are largely based on optimization and are highly sensitive to the selection of hyperparameters. While deep learning-based methods require designing and training separate models for QIS image reconstruction tasks with slight variations in detail, which is inflexible and limits its usefulness to a large extent. In order to tackle the problems in QIS image reconstruction, a tuning-free plug-and-play alternating direction method of multiplier (TFpN-ADMM) QIS image reconstruction method is proposed in this paper, which can adaptively select appropriate parameters dynamically for different input images with various oversampling factors, so as to achieve better image reconstruction performance. Specifically, in

this paper, the parameters that need to be manually tuned in the QIS image reconstruction process under the plug-and-play (PnP) framework are modeled as a sequential decision problem, and a mixed model-free and model-based reinforcement learning algorithm is introduced to learn an optimal strategy, which could determine optimal hyperparameters at each iteration for different input images. The experimental results on synthetic dataset and real dataset demonstrate that, compared with existing state-of-the-art methods, the proposed method improves the peak signal-to-noise ratio by approximately 0.44~0.60 dB under oversampling rates of 4, 6, and 8. Furthermore, the visual results demonstrate the superiority of the proposed method in retaining more texture details. Real extremely low light QIS image data is available at <https://github.com/ying-fu/Real-SPAD-Dataset>.

Key words: quanta image sensor; single photon imaging; plug-and-play; reinforcement learning; image reconstruction

Foundation Item(s): National Natural Science Foundation of China (No.62331006, No.62171038, No.62088101); Fundamental Research Funds for the Central Universities

1 引言

量子图像传感器(Quanta Image Sensor, QIS)是一种新型的图像传感器,它的提出旨在克服像素尺寸不断缩小导致满阱容量变小而带来的传感器性能瓶颈的问题^[1]. 在传统的CMOS图像传感器(CMOS Image Sensor, CIS)中,通过在每个像素中累积大量光电子,并将这些电荷转换为电压,进而通过模数转换来生成数字图像. 然而,随着像素尺寸缩小,单个像素能够积累的最大电荷量(满阱容量)也会随之下降,在低弱光或是高速成像的条件下,严重的光子噪声将会使图像的信噪比急剧下降,难以获取清晰的图像.

QIS通过对场景过采样解决这个问题,如图1所示,在每个单位空间中,它使用许多具有很高光子灵敏度的微小单光子探测器(jots)来捕获通常意义上单个像素所对应的光强. 其中,每个单光子探测器都可以捕获该区域所对应的光强并转化为光子计数的形式,通过设定阈值截断光子计数值输出最终的二值观测图像,该图像服从截尾泊松分布. 由此,QIS可以实现以非常高的帧速率计数单个光子,并具有很高的空间分辨率^[2]. 在弱光信号感知探测^[3,4]、超远距离单光子三维成像^[5]、高速成像^[6]等方面,QIS均具有良好的发展前景.

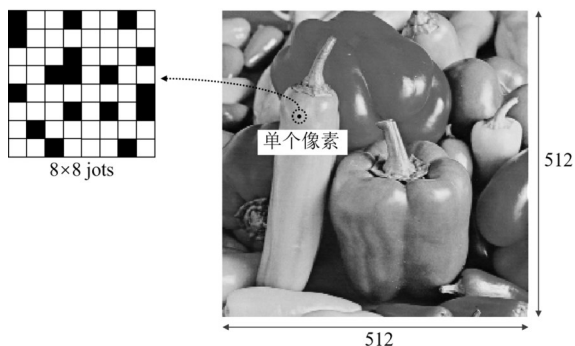


图1 QIS中 8×8 个单光子探测器检测到的二值输出(左)与重建灰度图像中单个像素(右)之间的关系

然而,从QIS获取的数据是二值图像帧,因此需要通过图像重建算法来恢复图像. 由于QIS概念提出的时间较短,目前的研究主要集中在完善QIS的理论体系方面,而与之相关的图像重建算法、高级视觉任务等的研究仍处在起步阶段. 现有的QIS图像重建方法可以分为基于优化建模的传统方法和基于深度学习的方法两大类. 大部分传统方法基于最大似然估计(Maximum Likelihood, ML)或是最大后验(Maximum A Posteriori, MAP)估计将QIS图像重建问题建模为优化问题,然后采用梯度下降^[7]、动态规划^[8]或是一阶迭代近端优化(如交替方向乘法)^[9]方法进行迭代求解. 这类方法采用成像系统的前向模型及简单的人工设计先验构建优化目标函数,具有较好的可解释性,且可以通过微调参数灵活地迁移到成像设置不同的待重建图像上. 然而,其性能往往受限于模型采用的先验信息与图像本身特性的匹配程度,导致重建图像的质量较差.

现有的基于深度学习的QIS图像重建方法^[10-13]利用深度卷积神经网络端到端地学习整个QIS图像重建流程,将学习到的先验知识隐式地嵌入到卷积神经网络的参数中. 虽然基于深度学习的QIS图像重建方法往往可以取得较传统方法更高的图像重建质量,但它必须为不同任务甚至不同设置的不同任务单独训练模型,丧失了灵活性.

为了解决上述问题,近年来一些研究人员开始考虑采用结合基于模型和基于深度学习方法优势的即插即用(Plug-and-Play, PnP)框架^[14,15]. 这类方法考虑到正则化去噪器与一阶迭代近端优化算法中近端算子的等价关系,采用基于深度学习的先进图像去噪器代替了人工设计的先验,从而在保持基于优化建模方法的灵活性的同时,借助深度学习方法显著提高了QIS图像重建的质量. 然而,这种即插即用算法的主要缺点是其性能对内部参数的选择高度敏感. 由于QIS图像重建任务中输入图像、过采样倍率与迭代所处轮次不同,最优参数也会随之变化,潜在的巨大的参数搜索空间使得通过手动调整参数得到的重建结果很难接近最优值.

针对上述不足,本文提出一种基于强化学习的免调参即插即用单光子图像重建方法(Tuning-Free Plug-and-Play Alternating Direction Method of Multiplier, TFPnP-ADMM). 该方法创新性地将强化学习应用到基于即插即用交替方向乘法(Plug-and-Play Alternating Direction Method of Multiplier, PnP-ADMM)的 QIS 图像重建框架中,并训练残差 UNet 网络作为插入的深度去噪器. 该方法可以自适应地根据不同成像条件及不同特征的待重建图像定制合适的参数序列,解决即插即用框架下的参数选择问题. 具体而言,首先,基于交替方向乘法将 QIS 图像重建任务解耦为三个独立交替求解的子问题,其中含正则化项的子问题可以视为一个独立的去噪任务;其次,提出残差 UNet 网络作为深度去噪器,在网络的训练中引入噪声图作为额外输入以处理连续的噪声级别;最后,将迭代重建流程中的参数序列选择问题构建为一个马尔可夫决策过程,并提出一种结合无模型和基于模型强化学习思想的自动调参算法. 该算法能够根据当前重建状态联合优化即插即用框架下 QIS 图像重建模型中离散的迭代停止时间和连续的降噪强度及惩罚参数. 最终,该算法可以学习到一个最佳策略,以动态地选取迭代重建流程中的超参数. 实验结果表明,与现有方法相比,本文提出的 TFPnP-ADMM 方法可以以较少的迭代次数达到更好的 QIS 图像重建质量.

本文的主要贡献包括以下 3 个方面:

(1) 提出了一种基于强化学习的免调参即插即用单光子图像重建方法(TFPnP-ADMM). 该方法能够自适应地针对不同成像条件及不同输入图像自动选取合适的参数. 与手工制定的参数选取策略相比,该算法能够以更少的迭代次数获得更高的图像重建质量.

(2) 所提方法结合了无模型强化学习和基于模型强化学习的思想,可以联合优化即插即用框架下 QIS 图像重建模型中离散的迭代停止时间和连续的降噪强度及惩罚参数.

(3) 通过在合成数据集及真实数据集上的实验验证了本文方法的有效性. 与现有先进方法相比,本文方法无需复杂的网络再训练过程,仅需一次训练便可得到用于多个过采样倍率下 QIS 图像重建的自动参数选取策略. 实验结果表明,本文方法取得了良好的 QIS 图像重建质量.

2 相关工作

2.1 QIS 图像重建

QIS 图像重建属于计算机视觉中一类典型的逆问题求解任务,即已知 QIS 系统输出二值观测数据及前向模型,求解未知目标图像. 早期的 QIS 图像重建通常采

用基于优化建模的方法. 这类方法利用成像系统的物理模型、观测数据、噪声的统计模型以及关于未知目标图像的先验知识构建优化目标函数,通过迭代地优化目标函数估计待重建的图像. 通常,其目标函数由成像系统的物理模型构成的数据保真项以及对未知目标图像特性的假设构成的正则化项组成. 对于特定重建问题,其物理模型固定,因此这类算法的核心在于图像先验的设计. 变换域稀疏性^[16]、低秩性^[17-19]、全变分^[20,21]等正则化器已被广泛应用到各种图像处理任务中. 例如,在 QIS 图像重建问题上,Chan 等人^[9]通过引入全变分(Total Variation, TV)正则化,并利用交替方向乘法解决该问题. 与迭代优化的重建方法思路不同,Chan 等人^[22]提出一种采用变换去噪(Transform Denoise, TD)的非迭代重建方法. 该方法采用方差稳定变换将服从泊松分布的观测数据转换为高斯分布,然后应用现成的去噪算法完成重建. 由于免去了通常的优化迭代过程,该方法可以有效缩短重建所需时间,但其重建质量仍亟待提升. Gnanasambandam 等人^[23]提出一种基于 QIS 的高动态范围(High Dynamic Range, HDR)图像重建算法. 该算法以曝光时间 t 内 QIS 输出的一组二值图像帧作为输入,通过迭代优化算法求取一组最优权重,加权求和得到重建的 HDR 图像. 这类方法具有较好的可解释性,且可以通过微调参数灵活地迁移到不同成像设置的待重建图像上. 然而,当重建时采用的先验与图像本身特性存在偏差时,这类方法的图像重建质量会受到较大影响.

深度学习作为一种强大的计算工具,近几年已经在 QIS 图像重建上得到广泛应用. 例如,Rojas 等人^[10]设计了一个两层前馈神经网络将 QIS 二值观测数据端到端映射到灰度图像,尽管该方法实现了重建速度的显著提升,但重建图像质量较差. 在此基础上,Choi 等人^[11]参考变换去噪方法^[22]的流程,提出两种用于 QIS 图像重建的神经网络设计,包括仅替代变换去噪流程中去噪器部分的 QISNet-TD 以及端到端的重建网络 QIS-Net,它们在加速重建的同时也实现了较好的重建质量. 此外,Chi 等人^[12]提出一个教师-学生网络用以解决极低光下动态场景的 QIS 图像重建任务. 该网络包含两个教师子网络,其中一个教师网络用于捕获场景中的动态信息,另一个教师网络用于捕获场景中的噪声. 通过将知识从去模糊和去噪教师网络迁移至学生网络,完成低弱光场景下的动态 QIS 图像重建. 近期,Goyal 等人^[13]尝试在 QIS 相机拍摄的二值图像上直接进行高级视觉任务. 他们提出光子尺度空间的概念,通过约束并引导特征提取网络从一组场景相同但每像素光子水平不同的图像中学习相似的特征表示,并在此基础上进行场景理解与推断. 深度学习类方法的缺点

在于,一旦 QIS 的成像设置与模型训练时的设置不同,图像重建质量将会受到极大影响.因此,如果过采样率、噪声类型或噪声强度等任务细节发生变化,就需要重新训练整个网络,而这个过程非常耗时.

近年来,一些工作探索了即插即用框架在 QIS 图像重建任务的应用.例如,Chan 等人^[14]利用经典的去噪算法 BM3D 作为正则化器插入优化算法.进一步,Ryu 等人^[15]利用去噪卷积神经网络(Denoising Convolutional Neural Networks, DnCNN)作为隐式正则化器,使重建性能进一步提升.该类方法的优势在于其结合了基于模型和基于深度学习方法,能够灵活地在一个统一的框架下处理不同成像设置的输入图像,同时也具有深度学习方法强大的拟合能力.

2.2 即插即用框架

即插即用是将高级图像去噪先验集成到近端算法中的一种非凸框架.这类方法兼顾基于模型与基于深度学习方法的优点,将深度学习强大的数据表征能力融入成像应用的物理框架中,具有更强的可解释性.自 2013 年 Venkatakrisnan 等人^[24]首次提出即插即用的概念后,后续许多研究工作也陆续展开.

最初,即插即用框架首次应用于交替方向乘法,随后扩展到其他近端优化算法,包括原对偶算法^[25]、半二次分裂算法^[26]以及快速迭代收缩阈值算法^[27]等.除此之外,一系列图像去噪算法都已被插入到即插即用框架中,展示出该框架的灵活性.例如,Sreehari 等人^[28]将著名的 BM3D 算法作为去噪器插入即插即用框架中解决亮场电子层析成像任务.Venkatakrisnan 等人^[24]采用非局部均值先验结合即插即用框架解决 X 射线断层成像问题.Zhang 等人^[29]受快速灵活的卷积去噪网络(Fast and Flexible Denoising convolutional neural Networks, FFDNet)^[30]的启发,提出将结合 UNet 和 ResNet 的去噪网络(Denoising Residual UNet, DRUNet)作为深度去噪先验插入半二次分裂算法^[26]中,在图像去模糊、超分辨率和去马赛克三个具有代表性的图像恢复任务中实现了优越性能.

然而,即插即用框架虽然提供了在不同任务之间迁移的灵活性并展现出较其他方法更优越的性能,但该框架的缺陷在于其性能对内部参数的选择高度敏感.当内部参数选择与具体输入图像不匹配时,会导致最终输出结果的性能大幅下降.而在以往的工作^[14, 15, 26, 29, 31]中,即插即用框架内部的参数均使用手动调整或是半自动搜索的方式确定,这些方法需要进行大量的实验调优及试错,较为繁琐且十分耗时,也很难寻找到与输入图像匹配的最优参数组合,无法展现出即插即用框架的实际性能.

本文主要关注即插即用框架在单光子成像任务上的应用.这方面的工作包括前文中提到的采用 BM3D 作为插入去噪器的 PnP-BM3D 方法^[14]及利用深度学习去噪器 DnCNN 插入即插即用框架的 PnP-DnCNN 方法^[15].与上述工作不同的是,本文提出的方法在尝试更有效的插入去噪器的同时,重点探究了即插即用框架应用于单光子成像任务时重建性能对于参数选择敏感的问题.为了解决这个问题,本文基于强化学习的方法构建自动参数选择算法,该算法能够根据 QIS 成像系统的具体设置动态地选择迭代重建流程中每一步的超参数,从而进一步提升即插即用框架的性能,实现高质量的 QIS 图像重建.

3 基于强化学习的免调参即插即用单光子图像重建方法

本节从 QIS 成像模型及重建问题引入,并将详尽地介绍本文提出的基于强化学习的免调参即插即用单光子图像重建方法(TFPnP-ADMM).

3.1 QIS 成像模型

QIS 的成像模型如图 2 所示,主要包含两个阶段:
(1)空间过采样阶段:模拟光从场景到传感器的过程;
(2)传感阶段:首先通过随机泊松过程模拟实际到达传感器的光子数目,其次通过设定的阈值截断该计数值将其转换为二进制的观测值.以下分别介绍这两个成像阶段的数学建模.

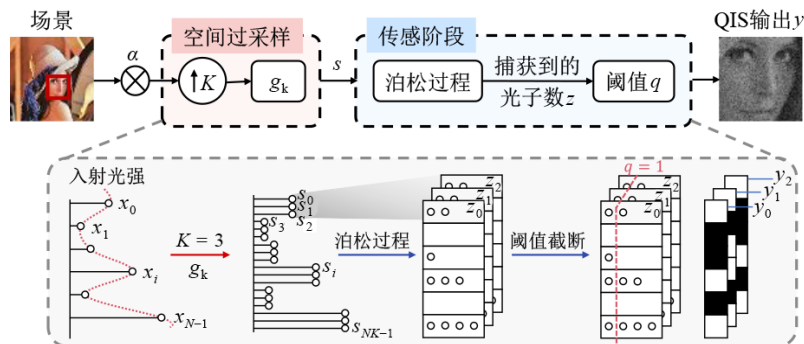


图2 单光子成像流程

(1) 空间过采样阶段

QIS是一种新型的图像传感器,它使用 K 个微小光子探测器来捕获与通常意义上的单个像素(例如CMOS中的像素)所对应的光强,其中, K 为空间过采样率.

假设使用 NK 个光子探测器过采样入射光 $\mathbf{x} \in \mathbb{R}^N$,则空间过采样阶段可由空间过采样算子 K 和一个低通滤波器 g_k 建模,表达为

$$\mathbf{s} = \alpha \mathbf{G} \mathbf{x} \quad (1)$$

其中, $\mathbf{s} = (s_0, s_1, \dots, s_{NK-1})^T \in \mathbb{R}^M$ 表示 $M=N \times K$ 个光子探测器上实际的光子到达率; $\mathbf{G} \in \mathbb{R}^{M \times N}$ 为编码了过采样过程及低通滤波器 g_k 的矩阵; α 表示传感器增益.

(2) 传感阶段

对于QIS成像系统,第 i 个光子探测器实际捕获到的光子数服从一个均值为 s_i 的泊松分布.令 z_i 为第 i 个光子探测器捕获到光子数的随机变量,其捕获到光子数的概率为

$$p(z_i) = \frac{s_i^{z_i} e^{-s_i}}{z_i!}, i=1, 2, \dots, M \quad (2)$$

通过一个设定的阈值 q 对捕获到的光子数 Z_i 进行量化,可以得到QIS最终的二进制输出 Y_i :

$$Y_i = \begin{cases} 1, & \text{if } Z_i \geq q \\ 0, & \text{if } Z_i < q \end{cases} \quad (3)$$

当阈值 $q=1$ 时,给定光子到达率 s ,观测到 $Y_i=y_i$ 的概率为

$$p(y_i | s_i) = \begin{cases} e^{-s_i}, & \text{if } y_i = 0 \\ 1 - e^{-s_i}, & \text{if } y_i = 1 \end{cases} \quad (4)$$

3.2 QIS 图像重建

QIS图像重建的目标是将二进制观测数据 \mathbf{y} 重建为原始信号 \mathbf{x} ,该问题可以表述为解决如下的最大后验估计(MAP)问题:

$$\begin{aligned} \hat{\mathbf{x}} &= \arg \max_{\mathbf{x}} p(\mathbf{x} | \mathbf{y}) \\ &= \arg \min -\log p(\mathbf{y} | \mathbf{x}) - \log p(\mathbf{x}) \end{aligned} \quad (5)$$

上述最大后验估计问题等价于解决如下无约束优化问题:

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} f(\mathbf{x}) + \lambda g(\mathbf{x}) \quad (6)$$

其中, $f(\mathbf{x}) \triangleq -\log p(\mathbf{y} | \mathbf{x})$,表示数据保真项,用于确保重建图像与观测数据的一致性, $g(\mathbf{x}) \triangleq -(1/\lambda) \log p(\mathbf{x})$ 表示正则化项.

上述优化问题通常采用一阶迭代近端优化算法解决,例如交替方向乘法:

$$\begin{aligned} \mathbf{x}_{k+1} &= \arg \min_{\mathbf{x} \in \mathbb{R}^N} f(\mathbf{x}) + \frac{\mu}{2} \|\mathbf{x} - \tilde{\mathbf{x}}_{k+1}\|^2 \\ \mathbf{v}_{k+1} &= \arg \min_{\mathbf{v} \in \mathbb{R}^N} \lambda g(\mathbf{v}) + \frac{\mu}{2} \|\mathbf{v} - \tilde{\mathbf{v}}_{k+1}\|^2 \\ \bar{\mathbf{u}}_{k+1} &= \bar{\mathbf{u}}_k + (\mathbf{x}_{k+1} - \mathbf{v}_{k+1}) \end{aligned} \quad (7)$$

其中, $\tilde{\mathbf{x}}_k \triangleq \mathbf{v}_k - \bar{\mathbf{u}}_k$, $\tilde{\mathbf{v}}_k \triangleq \mathbf{x}_{k+1} + \bar{\mathbf{u}}_k$, $\bar{\mathbf{u}}_k \triangleq (1/\mu) \mathbf{u}_k$.

3.3 即插即用的交替方向乘法

交替方向乘法的一个关键特性是其模块化的结构.由于这个特性,该算法可以结合即插即用框架,通过插入现有高级图像去噪器完成其中子问题的求解.

式(7)中 \mathbf{v} -子问题可以视为一个去噪问题,定义 $\sigma = \sqrt{\lambda/\mu}$, \mathbf{v} -子问题可重写为

$$\begin{aligned} \mathbf{v}_{k+1} &= \text{Prox}_{\sigma^2 \mathcal{R}}(\tilde{\mathbf{v}}_k) \\ &= \arg \min_{\mathbf{v} \in \mathbb{R}^N} g(\mathbf{v}) + \frac{1}{2\sigma^2} \|\mathbf{v} - \tilde{\mathbf{v}}_k\|^2 \end{aligned} \quad (8)$$

将式(8)中的 $\tilde{\mathbf{v}}_k$ 视为噪声图像,可将式(8)视作采用先验项 $g(\mathbf{v})$ 最小化噪声图像 $\tilde{\mathbf{v}}_k$ 和干净图像 \mathbf{v} 之间的差值,其中, σ 为控制降噪强度的参数.

在即插即用框架下,可以采用现有降噪强度为 σ 的去噪器 H_σ 替代式(7)中 \mathbf{v} -子问题的近端算子 $\text{Prox}_{\sigma^2 g}$.因此,式(7)可重写为

$$\begin{aligned} \mathbf{x}_{k+1} &= \text{Prox}_{\frac{1}{\mu_k} f}(\tilde{\mathbf{x}}_k) \\ \mathbf{v}_{k+1} &= \text{Prox}_{\sigma_k^2 g}(\tilde{\mathbf{v}}_k) = H_{\sigma_k}(\tilde{\mathbf{v}}_k) \\ \bar{\mathbf{u}}_{k+1} &= \bar{\mathbf{u}}_k + (\mathbf{x}_{k+1} - \mathbf{v}_{k+1}) \end{aligned} \quad (9)$$

其中, $k \in [0, \tau]$ 表示第 k 次迭代, τ 为迭代停止时间; σ_k 和 μ_k 分别表示第 k 次迭代时去噪器的降噪强度和惩罚参数.

对于式(9)中的超参数,包括降噪强度 σ_k ,惩罚参数 μ_k 以及迭代停止时间 τ ,可采用手动调整、半手工参数搜索策略(如单调减小惩罚参数)或是基于强化学习寻找最优策略的方式进行设置.然而,现有基于即插即用框架的QIS图像重建方法^[14,15]均采用手动调整参数的方式.由于即插即用框架的主要缺点在于内部参数(降噪强度 σ_k 、惩罚参数 μ_k 以及迭代停止时间 τ)的选择对于重建性能的影响较大,采用手动调整参数的方式极难找到合适的参数组合,导致图像重建质量欠佳.此外,由于每张待重建输入二值观测图像自身所处的状态、过采样倍率及噪声级别不同,因此不同输入图片的潜在最佳参数存在很大差异.现有方法仅能对相同过采样倍率下的一组图片手动调整较优参数,而不能满足对于每张输入图像设置最优参数序列的需求.由此,为了实现QIS图像的高质量重建,本文提出基于强化学习的自动参数选择算法来解决上述问题.此外,考虑到在PnP-ADMM算法迭代优化过程中每一步待更新变量 $(\mathbf{x}_k, \mathbf{v}_k, \mathbf{u}_k)$ 的差异,本文方法还将自动调整最佳参数的思路扩展到每张输入图像的不同迭代轮次中,使得在即插即用框架下可以对每张输入的待重建图像设置最佳的参数序列.

3.4 基于强化学习的免调参即插即用单光子图像重建方法

本节介绍本文提出的基于强化学习的免调参即插即用单光子图像重建方法TFnP-ADMM. 方法的总体流程如图3所示.

(1)对自动参数选择问题的建模

针对式(9)中即插即用框架下的QIS图像重建问题,目标是自动选择每一轮迭代时的内部超参,包括降噪强度 σ 、惩罚参数 μ 以及迭代停止时间 τ ,使得最终的重建结果 \mathbf{x}_τ 接近于图像的真实值 \mathbf{x} .为了解决这一问题,将其建模为一个完全可观测的马尔可夫决策过程(Markov Decision Processes,MDP),从而可以通过强化学习的方法进行求解.

马尔可夫决策过程可用一个五元组 $\langle S, A, P, R, \gamma \rangle$ 表示,其中, S 表示状态的集合,即优化变量的状态空间 $(\mathbf{x}_k, \mathbf{v}_k, \mathbf{u}_k)$; A 表示动作集合,即内部参数的选择空间.在QIS图像重建任务中,由于内部参数的选择空间既有连续的也有离散的,因此将动作分解为 $\mathbf{a} = (a_1, a_2)$ 两部分.其中,动作 a_1 表示迭代停止时间 τ 的离散动作空

间,动作 a_2 表示降噪强度和惩罚参数 (σ_k, μ_k) 的连续动作空间. P 表示状态转移函数,其将输入状态 S 映射到采取行动 \mathbf{a} 之后的下一状态 $\mathbf{s}' \in S$.在QIS图像重建任务中,状态转移函数 P 即为PnP-ADMM算法的一次迭代过程.具体地,采用已训练的残差UNet网络^[32]作为PnP-ADMM中的去噪器先验. R 表示奖励函数,为当前状态 S 下,采取行动 A 之后,下一时刻所能获得的期望奖励.该函数用于评估给定状态下的动作.为了在较少的迭代次数中获得更好的重建性能,将奖励函数定义为

$$R(\mathbf{s}_t, \mathbf{a}_t) = [\text{Re}(p(\mathbf{s}_t, \mathbf{a}_t)) - \text{Re}(\mathbf{s}_t)] - \eta \quad (10)$$

其中, $\text{Re}(\cdot)$ 表示计算峰值信噪比(Peak Signal-to-Noise Ratio,PSNR)的函数.式(10)中的第一项表示状态 \mathbf{s}_t 时执行行动 \mathbf{a}_t 所获得的PSNR增量,第二项 η 为一个固定的惩罚因子,用于对不期望的策略进行惩罚,引导智能体避免采取有损任务性能的行动.在式(10)中,如果采取当前行动后,图像PSNR的增益小于惩罚因子,则会给出负奖励,从而鼓励策略在PSNR收益微小时尽早停止迭代,以提高累计收益.在本文任务中,设置 $\eta = 0.05$.

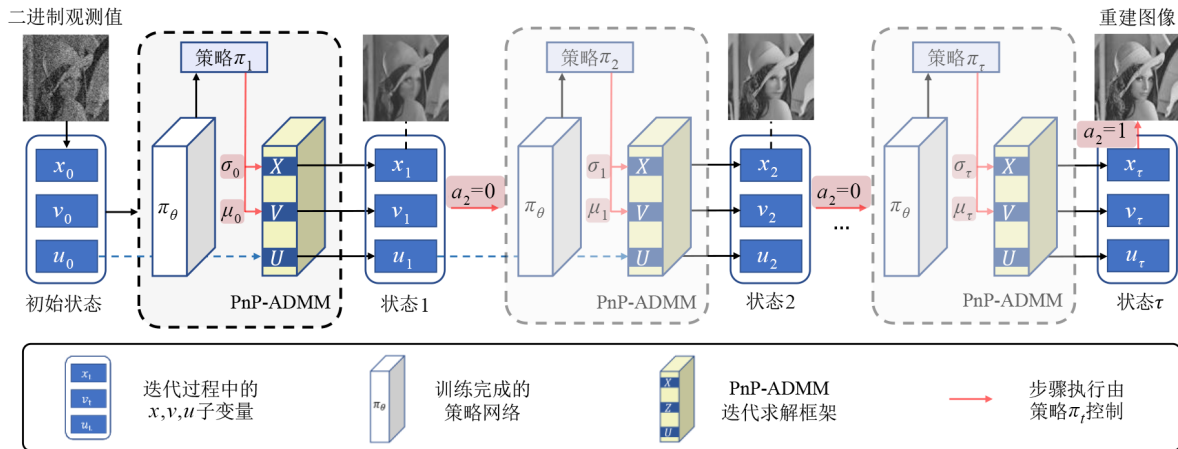


图3 基于强化学习的免调参即插即用单光子图像重建框架

将选取的参数序列 $(\sigma_0, \mu_0, \dots, \sigma_\tau, \mu_\tau)$ 作用于初始输入状态 \mathbf{s}_0 ,可得到状态、动作和奖励的序列 $T = (\mathbf{s}_0, \mathbf{a}_0, r_0, \dots, \mathbf{s}_\tau, \mathbf{a}_\tau, r_\tau)$.对于确定的序列 T ,可将策略在当前可获得的总收益 R_t 定义为状态 \mathbf{s}_t 之后产生的带折扣的奖励总和:

$$R_t = \sum_{t'=t}^{\tau} \gamma^{t'-t} R(\mathbf{s}_{t'}, \mathbf{a}_{t'}) \quad (11)$$

其中, $\gamma \in [0, 1]$ 为折扣因子,描述未来奖励的一种衰减关系,即越早获得的奖励对当前的影响越小.当 γ 取值越大,智能体往前考虑的步数越多,反之,则更注重即时利益.为了使得智能体尽量“深谋远虑”,本文在保证算法收敛的前提下使折扣因子的取值尽可能大,经过

实验,本文任务中设置 $\gamma = 0.99$.在第4.4节中,本文详细探讨了惩罚因子及折扣因子的不同设置对重建性能的影响.

将问题建模为上述马尔可夫决策过程后,目标便是学习一个有效的策略 $\pi(\mathbf{a}|\mathbf{s}) : \mathcal{S} \rightarrow \mathcal{A}$,使得遵循策略 π 所能获得的期望回报(即从初始状态出发,遵循该策略产生的所有可能轨迹上的总收益的期望)最大化.

(2)自动参数选择策略学习网络

在策略学习网络框架的设置上,本文采用参与者-评价者(Actor-Critic)框架^[33].策略网络 $\pi_\theta(\mathbf{a}_t|\mathbf{s}_t)$ 负责决定当前状态下执行的具体动作,价值网络 $V_\phi^\pi(\mathbf{s}_t)$ 负责对参与者的行为进行评估.其中,策略网络和价值网络均

采用 ResNet-18 作为特征提取器,其后使用全连接层和激活函数获取网络输出.用于自动参数选择的策略网络及价值网络总体结构如图 4 所示.

对于策略网络,为了生成动作 (a_1, a_2) ,需要将策略分解为随机策略 π_1 和确定性策略 π_2 .因此在特征提取网络之后,使用两组分离的全连接层生成停止概率 π_1 和降噪强度/惩罚参数 π_2 .离散动作 a_1 从随机策略 $\pi_1(\cdot|s)$ 中采样布尔值结果.若 $a_1=0$,该状态将进入下一次迭代计算,否则终止迭代并将该状态作为最终的重建结果输出.确定性策略 π_2 可直接决定最终动作值,即 $a_2=\pi_2(s)$.为了使得策略网络可以更全面地观测到重

建任务所处的状态,除了输入当前状态 $(\mathbf{x}_k, \mathbf{v}_k, \mathbf{u}_k)$ 外,也将 QIS 成像系统的原始二值观测 \mathbf{x}_0 ,空间过采样率 K 以及状态的当前迭代次数 k 作为额外通道输入网络.对于价值网络,将当前状态执行一次行动后得到的状态 $(\mathbf{x}_{k+1}, \mathbf{v}_{k+1}, \mathbf{u}_{k+1})$ 以及 (\mathbf{x}_0, K, k) 作为输入.需要注意,为了平滑训练数据分布,打破连续状态间的相关性,本文采用经验回放机制^[34],即输入策略网络的状态由状态缓冲区中随机采样的先前状态组成.策略和价值网络以交替的方式轮流训练,其中,策略网络使用策略梯度的方式进行训练,价值网络更新时采用软更新策略^[35]用以稳定训练.

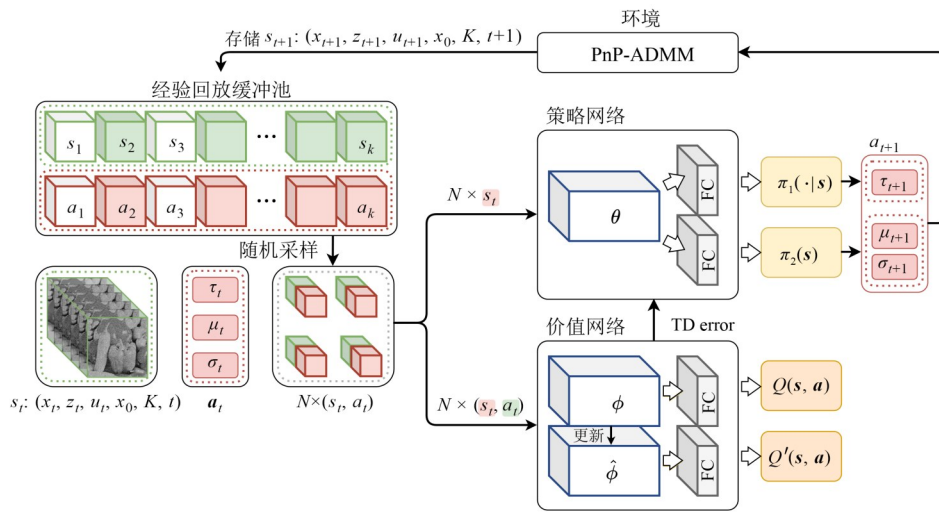


图4 策略网络及价值网络总体结构

4 实验结果

在本节中,首先介绍实验所使用的数据集、实验的具体细节、对比方法及其设置.然后展示并对对比所提出方法与现有的 QIS 图像重建方法在不同过采样倍率下的定量及可视化结果.之后进行消融实验以证明本文所提出方法的有效性.最后,详细分析所提出免调参算法学习到的策略行为以及策略对最终重建结果的影响.

4.1 实验设置

4.1.1 数据集

本文采用 3 个测试集来比较本文所提出的方法及对比方法在不同过采样倍率下的重建性能.其中,合成数据集采用文献[14]中提供的 13 张图像,采用第 3.1 节中介绍的 QIS 成像模型合成 QIS 二值观测数据用于测试,其中包含 $K=4, 6, 8$ 三种不同过采样倍率的图片.所有的图像尺寸均为 128×128 ,其每个像素均被归一化至 $[0, 1]$ 范围内.其中,传感器增益设置为 $\alpha=K^2$,阈值设置为 $q=1$.真实视频(帧)数据集采用 Burri 等人发明

的 SwissSPAD 相机^[36]构建.该相机具有 512×128 的分辨率,每秒 156 K 的帧速率.由于该相机帧速率较高,而空间分辨率较小,因此在数据预处理时采用高速拍摄下相邻的 16、36、64 帧图像求出 $K=4, 6, 8$ 三种不同过采样倍率下的待重建图像.在图像重建时,对于过采样倍率 $K=4$ 的情况,拍摄的相邻 16 帧图像中同一位置的二进制值对应重建后图像中相应位置的一个像素值,在过采样率 $K=6, 8$ 时同理.真实极暗光图像数据集采用另一种 SPAD 相机(Pi Imaging SPAD 512S)于暗室拍摄,其分辨率为 512×512 ,曝光时间为 $40 \mu\text{s}$.

4.1.2 实验细节

本文提出的 TFPnP-ADMM 需要依次进行去噪网络训练及策略-价值网络训练.遵循现有工作^[15,37]中对去噪网络通常的训练方式,本文采用从 BSD (Berkeley Segmentation Dataset) 数据集^[38]提取的 87 000 个尺寸为 128×128 的图像块训练去噪 UNet 网络,其中每个图像块随机添加了不同强度的高斯噪声.去噪网络的训练使用 L_1 损失函数及 Adam 优化器^[39].模型训练的批处

训练大小设置为 32, 训练执行 50 个轮次. 初始学习率设置为 10^{-4} , 在第 30 个轮次时衰减为 5×10^{-5} , 最后在第 40 个轮次时衰减至 10^{-5} .

策略-价值网络的训练数据来自 PASCAL VOC 数据集^[40]. 本文从数据集中提取了 17 125 个图像块(尺寸剪裁为 128×128), 同样采用第 3.1 节中的 QIS 成像模型对其进行处理, 为每个图像块生成在 $K=4, 6, 8$ 三种过采样倍率下对应的 QIS 二值观测数据. 策略-价值网络同样采用 Adam 优化器, 模型训练批处理大小设置为 48, 训练共执行 15 000 个轮次. 策略和价值网络的初始学习率分别设置为 1×10^{-4} 和 5×10^{-5} , 随后在第 10 000 个轮次时分别衰减为 5×10^{-5} 和 1×10^{-5} .

在训练阶段开始前, 首先执行 20 次环境探索过程用于状态缓冲池的预热, 此后交替进行探索和训练过程, 每次探索完成后连续执行 10 次网络梯度更新. 在训练时, 本文采用经验回放机制, 将探索阶段采集的状态存储在状态缓冲池中, 并在训练阶段使用从数据缓冲池中随机采样的状态组成的批次进行网络更新, 数据缓冲池的大小设置为 400. 除部分对比方法外, 本文实验均基于 PyTorch 框架, 在 NVIDIA TITAN Xp 型号显卡上进行训练.

4.1.3 对比方法

本文将 TFPnP-ADMM 与 5 个现有的主流 QIS 图像重建方法进行对比, 包括最大似然估计(Maximum Likelihood Estimation, MLE)方法^[7], BM3D 作为隐式先验的 PnP 方法 PnP-BM3D^[14], 基于 DnCNN 去噪网络作为先验的 PnP 方法 PnP-DnCNN^[15], 非迭代的变换去噪重建方法 TDQIS-BM3D^[22]以及基于最大似然估计调整传感器最佳设定参数的 MLM 方法^[41].

表 1 不同过采样率($K=4, 6, 8$)下各方法在合成数据集上的 QIS 图像重建定量结果对比

过采样率 K	指标	方法					
		MLE ^[7]	PnP-BM3D ^[14]	PnP-DnCNN ^[15]	TDQIS-BM3D ^[22]	MLM ^[41]	本文方法
4	PSNR	14.71	25.67	25.13	25.74	21.32	26.34
	SSIM	0.225 0	0.761 4	0.702 0	0.750 5	0.377 2	0.796 1
6	PSNR	17.93	27.33	27.53	28.36	25.10	28.80
	SSIM	0.333 7	0.817 9	0.774 9	0.829 7	0.492 5	0.847 3
8	PSNR	20.31	28.46	29.19	29.83	27.38	30.36
	SSIM	0.420 4	0.852 2	0.827 0	0.867 4	0.566 2	0.890 8

4.2.2 真实数据集上的实验结果对比

为了验证 TFPnP-ADMM 在真实场景下的重建性能, 图 6 和图 7 分别展示了不同方法在真实 QIS 视频(帧)及极暗光图像数据上的重建结果. 从图 6 可以看出, 基于最大似然估计的 MLE 及 MLM 方法在重建的图像中仍存在较大的噪声, 其原因在于当过采样率 K 较小时, QIS 输出二值观测的随机性不足以通过平均过采样

4.1.4 评估方法

本文基于峰值信噪比(PSNR)、结构相似性(Structural SIMilarity, SSIM)及重建的视觉效果对各方法的重建质量进行评估, 基于重建所需迭代次数对各方法重建效率进行评估. 评估在 $K=4, 6, 8$ 三种过采样倍率设置下进行. 为了保证评估的公平性, 为每个对比方法适配在不同过采样倍率下的超参, 使得它们在每个设置下均可以达到最优性能.

4.2 实验结果对比

4.2.1 合成数据集上的实验结果对比

为了验证 TFPnP-ADMM 对于 QIS 图像重建质量和效率的有效提升, 将 TFPnP-ADMM 与 5 种现有 QIS 图像重建方法的结果进行对比. 表 1 和图 5 展示了所有对比方法在合成 QIS 图像数据集上的定量和定性的结果. 在表 1 中, 数据集上平均 PSNR 及 SSIM 的最优结果用粗体标出. 从定量结果可以看出, TFPnP-ADMM 在三个过采样倍率设置下均达到了最优. 与此同时, 与同样基于迭代优化的方法相比, 由于本文方法可以根据当前状态动态选定每次迭代时适合的超参, 并使得迭代在 PSNR 增益较小时早停, 因此在重建效率上也有明显提升. 对于同属于即插即用框架的 QIS 重建方法 PnP-BM3D 及 PnP-DnCNN 方法, 在 $K=4, 6, 8$ 三个过采样倍率下分别需要 25、20、18 次迭代与 25、15、13 次迭代, 以达到最佳重建质量. 从数据集平均迭代次数来看, 本文方法在 $K=4, 6, 8$ 三个过采样倍率下平均仅需 19.00、12.85、5.08 次迭代, 便可达到远超上述对比方法的重建性能. 从图 5 展示的视觉结果及局部放大的细节图可以看出, TFPnP-ADMM 对于各种采样倍率设置下图片纹理细节的重建效果相较于对比方法有明显的提升, 这与从定量结果得出的结论一致.

的多个值进行消除. 基于变换去噪框架的 TDQIS-BM3D 方法虽然较好地重建了场景信息, 如示波器中间的波形, 但其图像整体对比度及亮度失真严重. 基于即插即用框架的 PnP-BM3D 及 PnP-DnCNN 方法在一些边缘丰富的区域细节信息丢失严重, 如示波器中间的波形、两侧的旋钮按键处模糊不清, 重建后的图像存在过度平滑现象. 相比之下, TFPnP-ADMM 在多个过采样倍

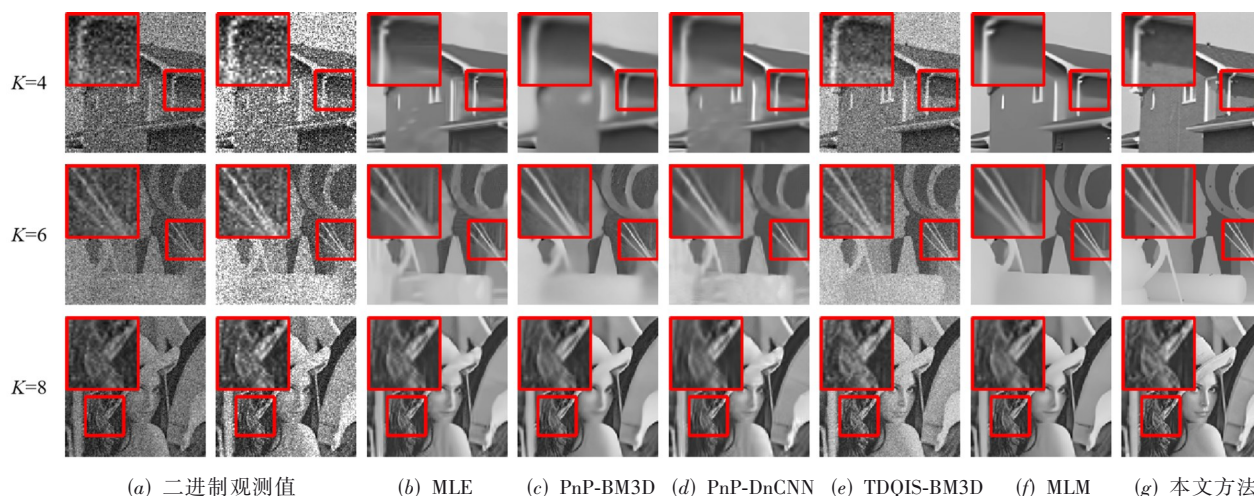


图5 不同过采样率($K=4, 6, 8$)下各方法在合成QIS数据上的重建视觉结果对比




图6 不同过采样率下各方法在真实QIS视频数据(帧)上的重建视觉结果对比

率下均能有效去除噪声,同时也较好地保留图像中的纹理细节.从图7的重建结果及局部放大细节可以看出,虽然PnP-BM3D和PnP-DnCNN方法整体重建效果较好,但在放大的局部细节处,PnP-BM3D的结果存在模糊及未去除的噪声,而PnP-DnCNN的重建结果中则存在过度平滑现象.相比之下,TFPnP-ADMM在重建图像的整体视觉效果和局部细节的保留上均具有优势.

4.3 消融实验

为了验证TFPnP-ADMM在单光子图像重建任务上的有效性,本节对比了TFPnP-ADMM与采用UNet去噪网络^[32]作为先验的PnP方法(PnP-UNet),即去掉策略学习模块,采用手动调整的方式为迭代过程选取合适

的超参.

在PnP-UNet¹中,采用半自动搜索的策略分别为每个过采样倍率下的所有图像确定一组最优的超参数,使得数据集上的平均重建性能达到最优,这种参数选择方式被大部分基于迭代的重建方法所采用.为了进一步提升迭代重建性能并与TFPnP-ADMM作比较,在PnP-UNet²中,采用穷举最优参数的方法为每个过采样倍率下的每张不同待重建图像均选取一组最优的超参数.需要注意,这种方式需要巨大的时间开销,无法实际应用.在本节实验中,采用Intel Core i7-6800K CPU及NVIDIA TITAN Xp GPU需要26 h确定合成数据集的13张图像重建所需的合适超参数.

三种实验方式的不同仅在于重建过程中的参数选

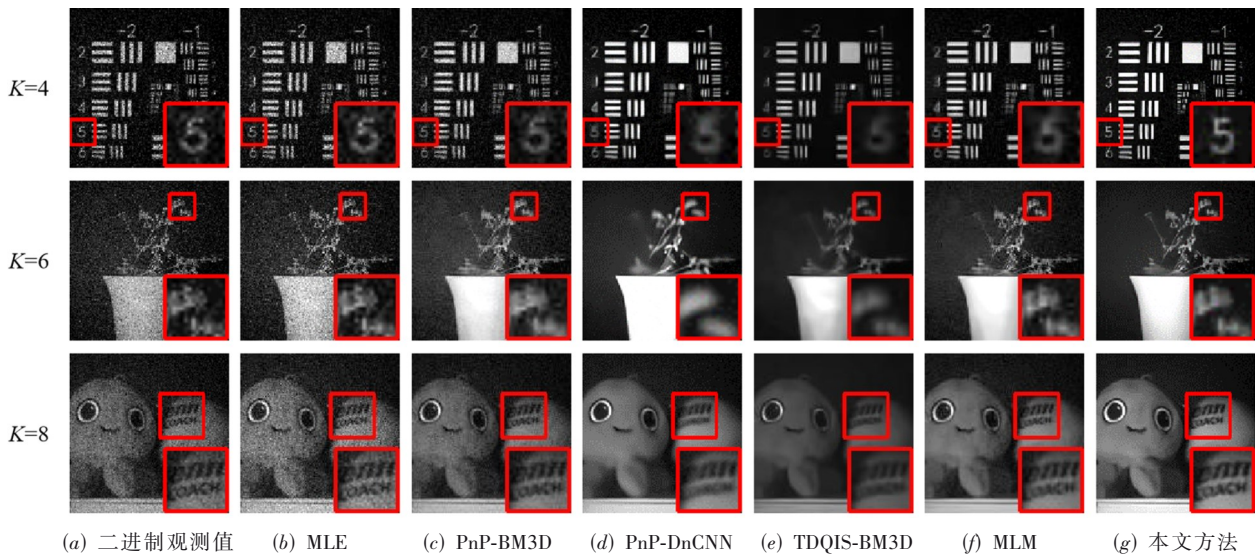


图7 不同过采样率下各方法在真实QIS图像数据上的重建视觉结果对比

取策略. 如表2所示,TFPnP-ADMM方法在所有过采样倍率下均达到了最佳的重建性能,证明本文方法学习到的策略可以对不同过采样倍率下的不同输入图像动态定制最优参数序列.

表2 消融实验的对比结果

算法	K = 4	K = 6	K = 8
	PSNR/迭代次数	PSNR/迭代次数	PSNR/迭代次数
PnP-UNet ¹	25.77 / 25	27.91 / 22	29.76 / 15
PnP-UNet ²	26.25 / 17.74	28.57 / 14.39	30.27 / 12.17
本文方法	26.34 / 19.00	28.80 / 12.85	30.36 / 5.08

4.4 超参数分析

本节讨论在基于强化学习的自动参数选取策略中式(10)和式(11)包含的惩罚因子 η 、折扣因子 γ 两个超参数对于本文方法在重建图像质量和迭代次数两方面的影响.

表3和表4分别显示了使用不同超参数设置(η 和 γ)训练在合成QIS图像数据集上的平均PSNR及算法迭代次数.在表3的实验中,固定折扣因子 $\gamma=0.99$,并更改惩罚因子 η 的值.从结果可以看出,参数 η 是控制早停行为的关键参数.当 $\eta=0$ 时,策略将微小的行动奖励也考虑在内,难以学会提早停止优化过程.而随着 η 取值的增大,策略则会倾向于过早停止,而不再关心后续对性能有较小提升的一系列行动.在表4中,固定惩罚因子 $\eta=0.05$,并更改折扣因子 γ 的值.从结果可以看出,超参数 γ 的设置也对早停行为有影响.当折扣因子较小时,策略将更加注重即时收益,而忽略长期收益,在结果中表现为算法迭代次数降低、收益(PSNR)下降.而当折扣因子 $\gamma=1$ 时,策略愿意牺牲短期回报以换取长期利益,导致结果上迭代次数升高,而此时未来奖

励的价值被高估(与即时奖励同等重要),使得PSNR下降.因此,惩罚因子 η 以及折扣因子 γ 的取值应随任务需求的不同而改变.

表3 不同惩罚因子参数设置的结果比较

超参数 η	K = 4	K = 6	K = 8
	PSNR/迭代次数	PSNR/迭代次数	PSNR/迭代次数
0	26.33 / 20.00	28.56 / 18.92	30.07 / 15.62
0.05	26.34 / 19.00	28.80 / 12.85	30.36 / 5.08
0.1	26.06 / 13.62	28.51 / 8.69	30.15 / 4.38
0.15	25.72 / 10.62	28.40 / 6.92	30.15 / 4.08

表4 不同折扣因子参数设置的结果比较

超参数 γ	K = 4	K = 6	K = 8
	PSNR/迭代次数	PSNR/迭代次数	PSNR/迭代次数
0.8	26.15 / 13.77	28.52 / 8.85	30.17 / 4.23
0.9	26.18 / 14.77	28.55 / 9.31	30.19 / 4.54
0.99	26.34 / 19.00	28.80 / 12.85	30.36 / 5.08
1	26.29 / 19.77	28.64 / 14.85	30.20 / 7.23

4.5 算法学习的策略行为分析

为了进一步验证本文提出的TFPnP-ADMM方法的有效性,本节展示了该方法学习到的策略在处理不同场景及不同过采样率的输入二进制观测图像时,表现出的完全不同的策略行为.图8和图9分别展示了TFPnP-ADMM方法在面对不同过采样率下相同输入图像和相同过采样率($K=8$)下不同输入图像的情况时,所学习到的截然不同的策略行为.图8和图9中第一行为待重建的二进制观测图像,第二、三行分别为自动参数选择网络学习到的在每次迭代时惩罚参数 μ ,降噪强度 σ 的序列.从图8和图9可以看出,自动参数选择网络会根据每一步迭代时输入图像所处的不同状态,从状态

空间中选取即插即用框架中适合的超参数值,并在适当的时候自动终止迭代.相较于PnP-BM3D以及PnP-DnCNN这两个即插即用单光子图像重建方法中手工设置的固定超参数相比,本文方法可以综合考虑原始输入图像、过采样倍率、当前重建迭代次数,动态地在巨大的状态空间中选择最优参数组合,提升单光子图像重建质量的同时降低迭代次数,实现即插即用框架下单光子图像的更优重建性能.需要注意,如此庞大的参数序列决策通过手动的进行参数调整或是半自动穷举搜索的方式均是难以完成的.

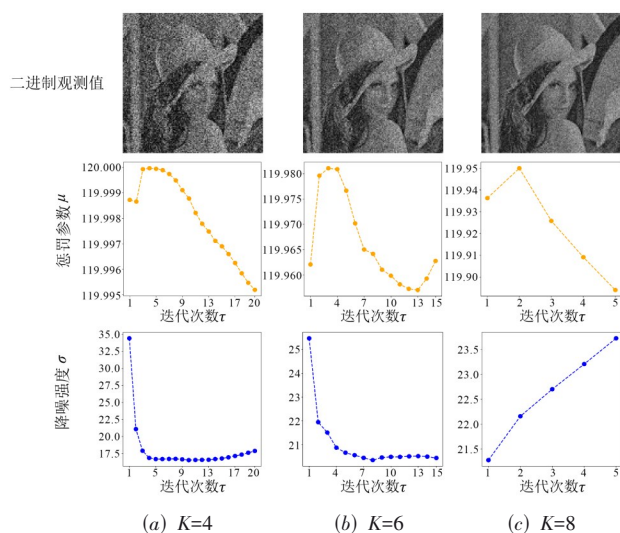


图8 相同图片在不同过采样率下,算法学习到的不同策略行为

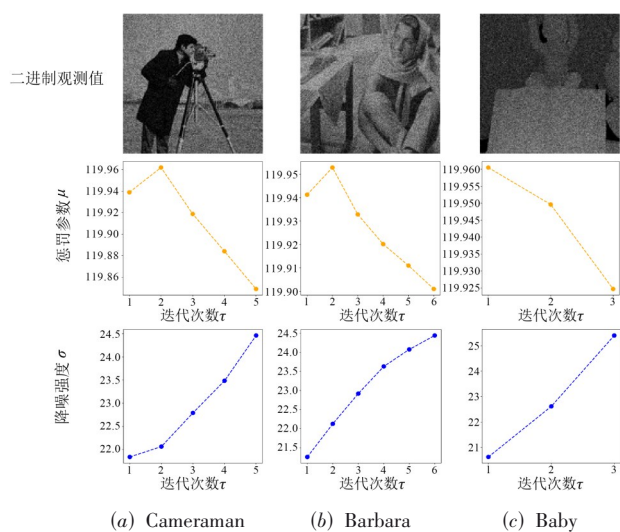


图9 不同图片在相同过采样率 $K=8$ 下,算法学习到的不同策略行为

5 结论

本文提出了一种基于强化学习的免调参即插即用单光子图像重建方法TFnP-ADMM.本文方法采用残

差UNet网络作为插入去噪器,通过将强化学习引入即插即用框架下的QIS图像重建问题中,可以学习一个最佳参数选取策略.该策略可以自适应地针对不同过采样倍率设置下的不同输入图像动态选取最优惩罚参数、降噪强度序列与迭代停止时间.此外,本文方法无需复杂的网络再训练过程,仅需一次训练便可得到适用于不同设置下输入图像的最优策略.实验结果表明,和现有先进QIS图像重建方法相比,本文提出的方法可以在多个过采样倍率下实现最佳重建质量,同时有效降低优化迭代次数.在未来,将进一步探索该QIS图像重建方法的扩展,例如对输入策略网络的当前状态更有效的表征,对其他插入去噪器的探索以及采用更高效的强化学习算法进一步提升重建性能.

参考文献


- [1] FOSSUM E R, MA J J, MASOODIAN S, et al. The quanta image sensor: Every photon counts[J]. *Sensors*, 2016, 16 (8): 1260.
- [2] CHAN S H. What does a one-bit quanta image sensor offer? [J]. *IEEE Transactions on Computational Imaging*, 2022, 8: 770-783.
- [3] GNANASAMBANDAM A, CHAN S H. Image classification in the dark using quanta image sensors[C]//*European Conference on Computer Vision*. Cham: Springer, 2020: 484-501.
- [4] MA J J, CHAN S, FOSSUM E R. Review of quanta image sensors for ultralow-light imaging[J]. *IEEE Transactions on Electron Devices*, 2022, 69(6): 2824-2839.
- [5] LI Z P, YE J T, HUANG X, et al. Single-photon imaging over 200 km[J]. *Optica*, 2021, 8(3): 344-349.
- [6] MA S Z, GUPTA S, ULKU A C, et al. Quanta burst photography[J]. *ACM Transactions on Graphics*, 2020, 39 (4): 79.
- [7] YANG F, LU Y M, SBAIZ L, et al. Bits from photons: Oversampled image acquisition using binary Poisson statistics[J]. *IEEE Transactions on Image Processing*, 2012, 21 (4): 1421-1436.
- [8] YANG F, SBAIZ L, CHARBON E, et al. Image reconstruction in the gigavision camera[C]//*2009 IEEE 12th International Conference on Computer Vision Workshops*. Piscataway: IEEE, 2009: 2212-2219.
- [9] CHAN S H, LU Y M. Efficient image reconstruction for gigapixel quantum image sensors[C]//*2014 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*. Piscataway: IEEE, 2014: 312-316.
- [10] ROJAS R A, LUO W Y, MURRAY V, et al. Learning op-

- timal parameters for binary sensing image reconstruction algorithms[C]//2017 IEEE International Conference on Image Processing (ICIP). Piscataway: IEEE, 2017: 2791-2795.
- [11] CHOI J H, ELGENDY O A, CHAN S H. Image reconstruction for quanta image sensors using deep neural networks[C]//2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE, 2018: 6543-6547.
- [12] CHI Y H, GNANASAMBANDAM A, KOLTUN V, et al. Dynamic low-light imaging with quanta image sensors[C]//European Conference on Computer Vision. Cham: Springer, 2020: 122-138.
- [13] GOYAL B, GUPTA M. Photon-starved scene inference using single photon cameras[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2021: 2492-2501.
- [14] 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.
- [15] RYU E, LIU J L, WANG S C, et al. Plug-and-play methods provably converge with properly trained denoisers[C]//Proceedings of the 36th International Conference on Machine Learning. Cambridge: JMLR, 2019: 5546-5557.
- [16] 窦诺, 赵瑞珍, 岑翼刚, 等. 基于稀疏表示的含噪图像超分辨重建方法[J]. 计算机研究与发展, 2015, 52(4): 943-951.
- DOU N, ZHAO R Z, CEN Y G, et al. Noisy image super-resolution reconstruction based on sparse representation[J]. Journal of Computer Research and Development, 2015, 52(4): 943-951. (in Chinese)
- [17] 李敏, 栗泽昊, 张卓, 等. 融合局部低秩先验与 Bloch 流形约束的磁共振指纹重建算法[J]. 电子学报, 2023, 51(2): 372-384.
- LI M, LI Z H, ZHANG Z, et al. Local low-rank and Bloch manifold regularized magnetic resonance fingerprinting reconstruction[J]. Acta Electronica Sinica, 2023, 51(2): 372-384. (in Chinese)
- [18] 孙艳敏, 郭强, 张彩明. 基于非凸低秩约束的图像修复方法[J]. 图学学报, 2021, 42(3): 414-425.
- SUN Y M, GUO Q, ZHANG C M. Image inpainting using non-convex and low-rank constraint[J]. Journal of Graphics, 2021, 42(3): 414-425. (in Chinese)
- [19] 李潇瑶, 王炼红, 周怡聪, 等. 基于四元数非局部低秩和全变分的图像混合噪声去噪算法[J]. 电子学报, 2023, 51(4): 975-983.
- LI X Y, WANG L H, ZHOU Y C, et al. Image mixed denoising using quaternion-based non-local low rank and total variation[J]. Acta Electronica Sinica, 2023, 51(4): 975-983. (in Chinese)
- [20] OSHER S, BURGER M, GOLDFARB D, et al. An iterative regularization method for total variation-based image restoration[J]. Multiscale Modeling & Simulation, 2005, 4(2): 460-489.
- [21] CHEN Y, CAO W F, PANG L, et al. Hyperspectral image denoising with weighted nonlocal low-rank model and adaptive total variation regularization[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5544115.
- [22] CHAN S H, ELGENDY O A, WANG X R. Images from bits: Non-iterative image reconstruction for quanta image sensors[J]. Sensors, 2016, 16(11): 1961.
- [23] GNANASAMBANDAM A, CHAN S H. HDR imaging with quanta image sensors: Theoretical limits and optimal reconstruction[J]. IEEE Transactions on Computational Imaging, 2020, 6: 1571-1585.
- [24] 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. Piscataway: IEEE, 2013: 945-948.
- [25] ONO S. Primal-dual plug-and-play image restoration[J]. IEEE Signal Processing Letters, 2017, 24(8): 1108-1112.
- [26] ZHANG K, ZUO W M, GU S H, et al. Learning deep CNN denoiser prior for image restoration[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2017: 2808-2817.
- [27] SUN Y, XU S Q, LI Y Z, et al. Regularized Fourier ptychography using an online plug-and-play algorithm[C]//2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE, 2019: 7665-7669.
- [28] SREEHARI S, VENKATAKRISHNAN S V, WOHLBERG B, et al. Plug-and-play priors for bright field electron tomography and sparse interpolation[J]. IEEE Transactions on Computational Imaging, 2016, 2(4): 408-423.
- [29] 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.

- [30] 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.
- [31] MEINHARDT T, MOELLER M, HAZIRBAS C, et al. Learning proximal operators: Using denoising networks for regularizing inverse imaging problems[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2017: 1799-1808.
- [32] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015: 234-241.
- [33] PETERS J, SCHAAL S. Natural actor-critic[J]. Neurocomputing, 2008, 71(7/8/9): 1180-1190.
- [34] WANG Z Y, BAPST V, HEES N, et al. Sample efficient actor-critic with experience replay[C]//International Conference on Learning Representations. Toulon: OpenReview.net, 2017: 1-20.
- [35] LILICRAP T P, HUNT J J, PRITZEL A, et al. Continuous control with deep reinforcement learning[EB/OL]. (2015-09-09)[2023-04-15]. <http://arxiv.org/abs/1509.02971>.
- [36] BURRI S, MARUYAMA Y, MICHALET X, et al. Architecture and applications of a high resolution gated SPAD image sensor[J]. Optics Express, 2014, 22(14): 17573-17589.
- [37] WEI K X, AVILES-RIVERO A, LIANG J W, et al. TF-PnP: Tuning-free plug-and-play proximal algorithm with applications to inverse imaging problems[J]. The Journal of Machine Learning Research, 2022, 23(1): 699-746.
- [38] MARTIN D, FOWLKES C, TAL D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics[C]//Proceedings Eighth IEEE International Conference on Computer Vision. ICCV. Piscataway: IEEE, 2001: 416-423.
- [39] KINGMA D P, BA J. Adam: A method for stochastic optimization[EB/OL]. (2014-12-22)[2023-04-15]. <https://arxiv.org/abs/1412.6980>.
- [40] EVERINGHAM M, ESLAMI S M ALI, VAN GOOL L, et al. The pascal visual object classes challenge: A retrospective[J]. International Journal of Computer Vision, 2015, 111(1): 98-136.
- [41] WONG H T, LEUNG C S, HO D. Theoretical analysis and image reconstruction for multi-bit quanta image sensors[J]. Signal Processing, 2021, 185: 108087.

sors[J]. Signal Processing, 2021, 185: 108087.

作者简介



陈爽女, 1999年4月出生于北京市, 硕士研究生. 本科毕业于西安电子科技大学, 硕士就读于北京理工大学. 主要研究方向为计算机视觉.

E-mail: chenshuang@bit.edu.cn



田焯女, 1995年6月出生于陕西省西安市, 博士研究生. 本科毕业于兰州大学, 硕士毕业于北京大学, 博士就读于北京理工大学. 主要研究方向为计算成像.

E-mail: 3220205110@bit.edu.cn



付莹女, 1987年8月出生于陕西省铜川市, 北京理工大学教授, 博士生导师. 2009年获西安电子科技大学电子信息工程专业学士学位, 2012年获清华大学自动化专业硕士学位, 2015年获东京大学信息科学与技术专业博士学位. 2015~2016年于东京大学从事博士后研究工作. 主要研究方向为计算机视觉、多媒体图像视频分析、计算影像学.

E-mail: fuying@bit.edu.cn