

用于单光子压缩成像的抗噪重建网络的设计与训练

祝志太, 鄢秋荣*, 熊乙宁, 杨晟韬, 方哲宇

南昌大学信息工程学院, 江西 南昌 330031

摘要 将光子计数技术与单像素成像结合的单光子压缩成像方法具有成本低、灵敏度高的特点, 但该方法使用传统压缩重建算法时重建时间长。基于深度学习的压缩重建网络不仅实现了快速重建, 而且可获得更好的重建质量。最近用于单像素成像的压缩重建网络主要基于光探测器工作在模拟方式, 采用无噪声或带有加性高斯白噪声的系统仿真数据进行训练。对此, 建立了单光子压缩成像系统噪声模型, 提出了一种用于单光子压缩成像的抗噪声重建网络(RN)训练方法, 使用含有泊松噪声的测量值仿真数据对神经网络进行训练, 并搭建单光子压缩成像系统进行验证。实验结果表明, RN能明显提高各种已有压缩重建网络的图像重建质量。在此基础上, 提出了一种用于单光子压缩成像的抗噪重建网络(RPN-net), 该网络采用跨越式连接结构与阶段式训练方法, 实验结果表明其重建性能优于现有的压缩重建网络。

关键词 成像系统; 压缩感知; 光子计数技术; 单光子压缩成像; 深度学习; 泊松噪声

中图分类号 O438

文献标志码 A

doi: 10.3788/LOP202259.0411003

Design and Training of Anti-Noise Reconstruction Network for Single-Photon Compression Imaging

Zhu Zhitai, Yan Qiurong*, Xiong Yining, Yang Shengtao, Fang Zheyu

School of Information Engineering, Nanchang University, Nanchang, Jiangxi 330031, China

Abstract The single-photon compression imaging method, which combines photon counting technology and single-pixel imaging technology, has the characteristics of low cost and ultra-high sensitivity, however it takes a long time to reconstruct images using the traditional compression reconstruction algorithms. Additionally, the compression reconstruction network based on deep learning not only realizes rapid reconstruction, but yields better reconstruction quality. The recent compression reconstruction network used for single-pixel imaging is primarily based on the optical detector working in an analog mode, using the system simulation data without noise or additive white Gaussian noise for neural network training. In this study, a noise model of the single-photon compression imaging system is established, and an anti-noise reconstruction network (RN) training method for single-photon compression imaging is proposed. Simulation data of the measured values with Poisson noise is used to train the neural network, and a single-photon compression imaging system is built for verification. The results show that the RN can significantly improve the image reconstruction quality of the various existing compression reconstruction networks. On this basis, this study proposes an anti-noise reconstruction network (RPN-net) dedicated to single-photon compression imaging. RPN-net adopts a leaping connection structure and progressive training method, and the

收稿日期: 2021-01-25; 修回日期: 2021-03-10; 录用日期: 2021-04-14

基金项目: 国家自然科学基金(61865010, 61565012)

通信作者: *yanqiurong@ncu.edu.cn

results show that the reconstruction performance of the RPN-net is better than that of the existing compression reconstruction networks.

Key words imaging systems; compressed sensing; photon counting technology; single-photon compression imaging; deep learning; Poisson noise

1 引言

光子计数成像是一种在微弱光条件下,利用光子计数技术完成目标成像的方法。在传统的光子计数成像中,使用阵列探测器记录光强会限制成像分辨率且造价昂贵,而使用点探测器记录光强则需要扫描,导致成像时间长、光子收集效率低。近年来压缩感知理论广泛应用于光子计数成像领域,将压缩感知应用于点探测器的光子计数成像中,能有效解决成像时间长、光子收集效率低的问题。将压缩感知与光子计数成像结合的成像方法称为单光子压缩成像。

2008年,莱斯大学(Rice University)的Romber和Baraniuk等提出了基于压缩感知原理的单像素照相方案。2012年,中国科学院俞文凯等将单像素照相技术和光子计数成像技术结合,实现单光子压缩成像,即采用单像素单光子探测器即可实现二维成像,相比于面阵单光子探测器,成本低且分辨率更高^[1],特别是在红外、太赫兹等特殊波段^[2-4]。另外单像素成像系统中的探测器可以同时收集多个像素的光强,从而信噪比大大提升,成像灵敏度超过探测器本身的超灵敏度,因此在荧光显微^[5-8]、光谱成像^[9-10]以及生物医学^[11-12]等领域都有重要应用。单像素成像的提出也为单光子计数成像提供了新思路。

但单像素成像技术非常耗时,特别是进行高分辨率成像时,图像的重建时间非常长。一般基于成像目标稀疏先验信息,采用贪婪匹配追踪或凸优化的方法重建图像时需要耗费大量的时间进行迭代运算^[13-15]。深度神经网络用于压缩测量图像的重建已成为最近的研究热点^[16-19]。训练后权重固定的重建网络将低维测量值恢复成高维的图像信号,可避免传统迭代算法带来的大量计算问题,从而实现快速重建。2016年,Adler等^[20]提出一种基于块压缩的深度学习方法,该方法在速度和质量上都有非常大的提升。Kulkarni等^[21]提出一种基于图像超分辨率重建的ReconNet模型,其重建效果优于其他传统的压缩感知重建算法。2019年,Yao等^[22]提出DR2-net,该网络引入残差优化网络^[23-25],以此提高了重建图片的质量。上述文献研究基于深度学习的压缩

重建网络,网络实现测量值与重建图像的映射,不仅避免了迭代运算,而且重建质量优于total variation augmented Lagrangian alternating direction algorithm (TVAL3)^[26]等传统的压缩重建算法。实际系统中的压缩测量伴随噪声,噪声可能来源于系统的多个方面,因此上述模型应用于实际的压缩成像系统时的性能有待进一步验证。

近年来,深度学习压缩重建网络被用于单像素成像或计算鬼成像系统研究。Xie等^[27]提出一种自适应测量网络,并将其应用于压缩感知图像重建,该网络采用全连接层代替以往的随机高斯矩阵,最终实现图像的精确重建。Shimobaba等^[28]在计算鬼成像领域提出神经网络,得到高质量的重建图像。2020年,Wu等^[29]使用神经网络降低计算鬼成像中的噪声,但训练用的数据图片为无噪声的,用加性噪声的方式引入高斯噪声。2019年,中国科学院上海光学精密机械研究所的Wang等^[30]提出一种用于计算鬼成像的端到端深度学习方法,该方法将图像与处理过的掩模相乘,得到仿真数据用于神经网络的训练。上述论文通过建立正向成像模型,进行数据仿真并训练神经网络,从而避免了花费大量时间去收集实际的测量值数据。仿真条件为,光探测器工作在模拟方式之下且仿真过程中考虑的噪声为加性高斯白噪声。

单光子压缩成像中探测器为单光子探测器,探测器输出离散的脉冲信号,除了来自成像目标的单光子脉冲外,还有极少的暗计数脉冲和背景光脉冲,因此噪声来源主要为光强闪烁和光量子效应引起的泊松噪声。考虑到正向模型越精确,仿真数据训练出的网络应用于实际系统时就越有效,受去噪自编码器(DAE)的启发^[31-32],本文在建立单光子压缩成像系统噪声模型的基础上,提出了一种用于单光子压缩成像的重建网络设计和训练方法,并搭建单光子压缩成像系统进行验证。

2 单光子压缩成像系统与神经网络设计

2.1 单光子压缩成像系统

单光子压缩成像的系统框图如图1所示,平行

单光子源发出微弱的光照射成像目标,光束经过成像透镜会聚至数字微镜器件(DMD)上。DMD由 1024×768 个微反射镜阵列组成,微镜尺寸为 $13.68 \mu\text{m} \times 13.68 \mu\text{m}$,每个微镜可以独立控制偏转。在DMD控制板上加载二值随机矩阵后可同步对每个微镜的转向进行控制,对应于矩阵中元素“1”的微镜偏转 $+12^\circ$,对应于矩阵中元素“0”的微镜偏转 -12° 。光经DMD调制后进入聚焦透镜,聚焦透镜将DMD的反射光会聚至单光子探测器(PMT; H10682-110, Hamamatsu Photonics)的光敏面上。PMT将光信号转换为离散脉冲信号,并将脉冲信号输入现场可编程门阵列(FPGA)进行计数。最后将光子计数值作为神经网络的输入,完成图像重建。




图 1 单光子压缩成像系统框图

Fig. 1 Block diagram of single-photon compression imaging system

单光子压缩成像的原理可以表示为

$$\min \left(\frac{1}{2} \| \mathbf{y} - \boldsymbol{\varphi} \mathbf{x} \|_2^2 + \tau \| \mathbf{x} \|_1 \right), \quad (1)$$

式中: \mathbf{x} 为成像目标; $\boldsymbol{\varphi}$ 为 $M \times N$ 维的测量矩阵,且 M 远小于 N ; \mathbf{y} 为测量值,包含成像目标的特征信息; τ 是一个常量; $\| \cdot \|_p$ 表示 l_p 范数,且有 $(\| \mathbf{x} \|_p)^p = \sum_{i=1}^N |x_i|^p$ 。(1)式中前一部分是最小二乘约束,后一部分是对 \mathbf{x} 的稀疏约束。用于单光子压缩成像的抗噪声网络设计与训练的原理是,根据压缩感知理论,获取成像目标的少量特征信息 \mathbf{y} ,并将其输入神经网络,从而重建出原始成像目标 \mathbf{x} 。

2.2 测量值的泊松噪声模型

在单光子压缩成像系统中,泊松噪声主要是光子不足引起的。成像目标对应像素块的光子通量与实际像素值之间存在一定的统计关系,这种统计关系可以表示为

$$P(X=k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad (2)$$

式中: X 为随机变量; k 为成像目标对应像素块的光子通量; λ 为成像目标的实际像素值。即在实验系统中,像素块的光子通量 k 是一个符合参数为 λ 的泊松分布随机数。

在二维图片中单位像素的泊松噪声的实际效果如图2所示,单位像素上的光子涨落是服从泊松分布的^[1]。




图 2 泊松噪声对二维图片中像素值的影响。(a)原始像素值;(b)受泊松噪声影响的实际像素值

Fig. 2 Influence of Poisson noise on the pixel value in a two-dimensional image. (a) Original pixel value; (b) actual pixel value affected by Poisson noise

在单光子压缩成像系统中,影响二维图片中泊松噪声大小的主要因素是测量时间的长短。在光照强度不变的情况下,测量时间越长,光子数越多,则少数光子所引起的偏差越小,泊松噪声也就越小。全采样时,不同测量时间的模拟实验结果如图3所示,可以看出,随着测量时间的增加,图像的质量越来越高,不断地趋近于原始图像。

测量值是测量矩阵与成像目标进行矩阵相乘后所得到的计算结果,改变大小为 $m \times n$ 的图像矩阵的维度至 $1 \times (m \times n)$,测量矩阵的维度与改变后的图像一致,得到成像目标在理论上进行一次测量的测量值:

$$\beta = \sum_{i=1}^{m \times n} \varphi_i \times \lambda_i, \quad (3)$$

式中: β 为理论上不考虑噪声干扰的测量值; i 表示矩阵元素的位置索引; φ_i 为测量矩阵 $\boldsymbol{\varphi}$ 中的每一个元素; λ_i 为成像目标 \mathbf{x} 中的每一个像素块的像素值。

实际受到系统噪声干扰的测量值可以表示为




图 3 不同测量时间下泊松噪声对图像的影响,平均光子计数率为 34672 s^{-1} 。(a)原始图像;(b)总采样时间为 20 s;(c)总采样时间为 50 s;(d)总采样时间为 1000 s

Fig. 3 Effect of Poisson noise on the image under different measurement time, and the average photon count rate is 34672 s^{-1} .

(a) Original image; (b) total sampling time is 20 s; (c) total sampling time is 50 s; (d) total sampling time is 1000 s

$$\alpha = \sum_{i=1}^{m \times n} \varphi_i \times k_i, \quad (4)$$

式中: k_i 为对应像素块的光子通量。

线性运算并不会改变数据的统计特性,测量值 y 依旧具有与随机变量 X 相同的统计特性:

$$P(|y| = \alpha) = \frac{\beta^\alpha}{\alpha!} \beta^{-\alpha}. \quad (5)$$

在单光子压缩成像系统中, PMT 的脉冲计数所记录的并不完全是由物体所反射的信号光子 N_{uf} , 同时被 PMT 记录的还有背景光所引起的脉冲计数 N_{bg} 以及 PMT 自身内部原因所产生的暗计数 N_{dk} 。因此每一次测量所包含的泊松噪声可以表

示为

$$n_{all}^2 = \left[\sqrt{(N_{uf} + N_{dk} + N_{bg})} \right]^2. \quad (6)$$

由信噪比(SNR)的定义,测量的信噪比可以表示为

$$R_{SN} = N_{uf} / n_{all} = \frac{N_{uf}}{\sqrt{N_{uf} + N_{dk} + N_{bg}}}. \quad (7)$$

2.3 数据集的制作与网络训练方法

图 4 为所提重建网络训练方法示意图,首先将随机二值测量矩阵与图片相卷积,得到其中一个测量值,每一个测量矩阵对应一个测量值, y_1, y_2, \dots, y_t 为 t 次测量的结果,带有噪声的测量值用

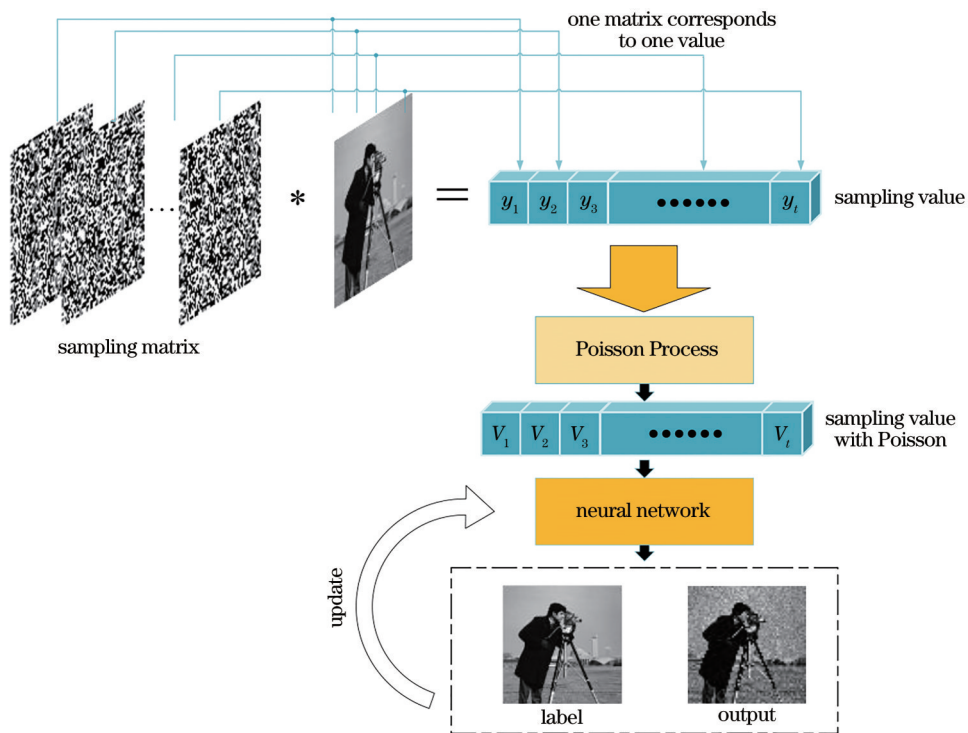


图 4 用于单光子压缩成像的抗噪声网络训练方法示意图

Fig. 4 Schematic of anti-noise network training method for single-photon compression imaging

V_1, V_2, \dots, V_t 表示。在这里,采用蒙特卡罗方法对成像目标的测量值进行仿真,生成一个均值为 y_j 的泊松分布随机数 V_j ,其中 $j \in [1, t]$ 。

假定单光子源的光强恒定,到达位于物体表面像素 (p, q) 处的光子数为 I_a ,则反射的光子数 M_{pq} 服从二项分布:

$$P(X = M_{pq}) = C_{I_a}^{M_{pq}} (1 - R_{pq})^{I_a - M_{pq}} (R_{pq})^{M_{pq}}, \quad (8)$$

式中: R_{pq} 表示像素 (p, q) 的透过率。当 $I_a \rightarrow \infty$ 时,二项分布趋于泊松分布,表达式为

$$\lim_{I_a \rightarrow \infty} C_{I_a}^{M_{pq}} (1 - R_{pq})^{I_a - M_{pq}} (R_{pq})^{M_{pq}} = \frac{\gamma_{pq}}{M_{pq}!} e^{-\gamma_{pq}}, \quad (9)$$

式中: γ_{pq} 表示像素 (p, q) 通过的平均光子数。

蒙特卡罗方法的基本思想是,从整体中模拟抽样,然后利用样本进行估计、假设检验等统计推断。




图 5 DFC-net 结构示意图

Fig. 5 Diagram of DFC-net structure

RNP-net 结合了线性映射与密集残差的优势,使用线性映射得到高质量的初步重建图像,使用密集残差完成图像优化,并通过一个跨越式连接得到最终的输出,这样可以在初步重建的基础上进一步地优化图像重建结果。

记原始图像为 \mathbf{x} , 输入图像初步重建网络 f_m 的测量值为 \mathbf{y} , 输出为 \mathbf{x}' , 那么有

已知测量值与目标像素值具有一致的数学分布,因此这种方法也完全可以用于测量值中。直接对图像的测量值进行数据处理,完成泊松噪声的添加,能够大幅度地减少计算量,从而降低数据处理所需要的时间。经泊松处理的测量值需要再次进行归一化处理:

$$\frac{[y_i - E(\mathbf{y})]}{\sigma(\mathbf{y})}, \quad (10)$$

式中: y_i 为第 i 个测量值; $E(\mathbf{y})$ 为测量值的均值; $\sigma(\mathbf{y})$ 为测量值的标准差。

2.4 神经网络的设计

所涉及到的网络包括 DFC-net(网络结构如图 5 所示)、DR2-net、自行设计的用于单光子压缩成像的抗噪声重建网络(RPN-net, 结构如图 6 所示)。

$$\mathbf{x}' = f_m(\mathbf{y}). \quad (11)$$

由于 \mathbf{x}' 为初步重建图像,那么 \mathbf{x}' 与 \mathbf{x} 之间存在的误差 ζ_x 为

$$\zeta_x = \mathbf{x} - \mathbf{x}'. \quad (12)$$

图像优化子网络实现图像的优化,输入 f_{dm} 为初步重建图像 \mathbf{x}' 输出 ζ_x' , ζ_x' 与 \mathbf{x}' 和 \mathbf{x} 间的残差十分接近,输出 ζ_x' 为

$$\zeta_x' = f_{dm}(\mathbf{x}'). \quad (13)$$

最后网络的输出结果 \mathbf{Y} 为

$$\mathbf{Y} = \mathbf{x}' + \zeta_x' = f_m(\mathbf{y}) + f_{dm}[f_m(\mathbf{y})]. \quad (14)$$

设网络的权重参数为 W_x , 损失函数为均方误差(MSE), 记原始图像为 $\mathbf{I}(p, q)$, 重建图像为 $\mathbf{K}(p, q)$, 所以 MSE 可以表示为

$$E_{MS} = \frac{1}{m \cdot n} \sum_{p=0}^{m-1} \sum_{q=0}^{n-1} \|\mathbf{I}(p, q) - \mathbf{K}(p, q)\|^2. \quad (15)$$

之后根据




图 6 RPN-net 结构示意图

Fig. 6 Diagram of RPN-net structure

$$\arg \min \|\mathbf{x} - \{f_m(\mathbf{y}) + f_{dm}[f_m(\mathbf{y})]\}\|_2, \quad (16)$$

不断训练网络优化 W_x , 使得误差最小。所使用的训练集是 DR2-net 中所使用的 91 张自然图像, 在训练网络时, 以 14 像素为步长, 将图像切割成 64×64 的小图, 对图像边缘不足 64 像素的地方, 采取补 0 操作; 最后对切割出的 64×64 的小图进行翻转镜像操作, 得到 22227 张小图。通过重建网络训练方法将小图与测量矩阵相乘, 得到一组原始测量值, 最后通过蒙特卡罗仿真方法得到带有泊松噪声的测量值, 将该测量值输入网络进行网络训练。

RPN-net 的训练过程分为两步, 分别是训练初步图像得到重建网络 f_m 以及图像优化子网络 f_{dm} 。通过初步图像重建网络, 得到初步的重建结果 \mathbf{x}' , 而

图像优化子网络则在初步重建结果的基础上获取 \mathbf{x}' 与 \mathbf{x} 之间的误差 ζ_x , 最终网络的输出为 $\mathbf{Y} = \mathbf{x}' + \zeta_x'$, 如图 7 所示。在训练初步图像重建网络 f_m 的过程中, 使用 Adam 优化器, Batch_size 的大小设置为 128, 学习率为 0.001, Epoch 为 250, 网络中的权重初始化为标准差为 0.01 的随机高斯矩阵, 此时图像优化子网络并不参与运算; 图像优化子网络 f_{dm} 的训练使用 Adam 优化器, Batch_size 的大小为 128, 学习率与初步图像重建网络相比需要减小, 以保证该部分网络的精确性, 学习率设置为 0.00001, Epoch 为 575, 网络中的权重初始化为标准差为 0.001 的随机高斯矩阵, 此刻初步图像重建网络中的参数并不发生改变。训练过程的损失值下降情况如图 8 所示。




图 7 RPN-net 输出示意图

Fig. 7 Schematic of RPN-net output




图 8 RPN-net 训练过程中损失值下降示意图

Fig. 8 Schematic of loss drop during RPN-net training

3 结果与分析

分别设计了两组对比实验, 其中一组是在相同的单光子压缩成像网络中对比不同的训练方式, 另一组是在相同的训练方法下, 对比不同的神经网络。第一组对比实验的目的是证明所提用于单光子压缩成像的抗噪声重建网络的训练方法(RN)能

够有效地提高用于单光子压缩成像的神经网络的抗噪声能力; 第二组对比实验的目的是证明 RPN-net 的抗噪声能力。在模拟实验中, 使用灰度图片作为测试图片, 在真实的系统实验中使用分辨率板作为成像目标, 如图 9 所示。泊松噪声的大小与测量率的高低并没有确切的关系, 其与单次测量的时间和光子数有关, 实验中, 通过改变 DMD 的翻转频率, 改变实验中的“平均光子数”, 通过不同的平均光子数改变实验中泊松噪声的大小。

3.1 不同训练方法的对比

1) 不考虑背景光噪声和暗计数, 只考虑泊松噪声。网络包括理想情况下训练出的 DFC-net (Ideal)、加高斯噪声训练出的 DFC-net (Gaussian)、加泊松噪声训练出的 DFC-net (Ours)、TVAL3。

采用网络所重构出的图像的峰值信噪比 (PSNR) 表征网络抗噪声性能。

$$R_{PSN} = 10 \log_{10} \left(\frac{y_{MAX}^2}{E_{MS}} \right) = 20 \log_{10} \left(\frac{y_{MAX}}{\sqrt{E_{MS}}} \right), \quad (17)$$

式中: y_{MAX} 为整张图片中像素的最大值。




图 9 掩模版照片。(a)明亮环境下的实物图;(b)黑暗环境下被照亮的实物图

Fig. 9 Mask photos. (a) Physical image in a bright environment; (b) physical image illuminated in a dark environment

实验结果如图 10 所示,可以得出,随着测量时间的不断增加,泊松噪声的影响越来越小,三种训练方法所训练出的神经网络的重建图像 PSNR 都有所上升,且 Ours 重建图片的 PSNR 一直高于其他两种训练方法与 TVAL3。在极低测量率的情况下,三种神经网络训练方法所训练出的 DFC-net 图像重建网络的重建效果相差无几,随着测量率的提升, RN 明显优于其他两种训练方法。




图 10 无背景噪声时不同训练方法在不同测量时间系数下的 PSNR。(a)测量时间系数为 60;(b)测量时间系数为 100;(c)测量时间系数为 140

Fig. 10 PSNR of different training methods under different sampling time coefficients without background noise. (a) Sampling time factor is 60; (b) sampling time factor is 100; (c) sampling time factor is 140

2) 固定光照强度下,改变暗计数大小。网络包括理想情况下训练出的 DFC-net(Ideal)、加高斯噪声训练出的 DFC-net(Gaussian)、加泊松噪声训练出的 DFC-net(Ours)、TVAL3。

对比 3 种图像重建网络的抗噪声性能,指标为各网络所重构出的图像的 PSNR,实验结果如图 11 所示。可以得出,随着暗计数率(暗计数率代表不

打开任何光源时 PMT 的光子计数率)的改变,图像的中间质量并没有发生太大的改变,据此得出结果,在测量时间系数固定的情况下,较小的暗计数的改变并不会带来图像重建质量的明显变化,且此时 Ours 重建图片的 PSNR 也一直高于其他两种训练方法与 TVAL3。由于光子暗计数直接对测量值产生加性影响,故随着暗计数的增加, Ideal 受到暗




图 11 测量时间恒定,不同背景噪声下不同训练方法的 PSNR。(a)暗计数率为 5;(b)暗计数率为 10;(c)暗计数率为 15

Fig. 11 PSNR of different training methods under different background noises when the sampling time is constant. (a) Dark count rate is 5; (b) dark count rate is 10; (c) dark count rate is 15

计数的影响明显增大,其与 Ours 曲线之间的性能差距也有所增加。综合对比图 10 和图 11 中 Gaussian 和 Ideal 的实验结果可以得出,不论在哪种测量时间

图 12 为单光子压缩成像系统的实验结果,其中平均光子个数为每进行一次测量时所采集到的光子数的平均值。对比第 1 行和第 2 行的实验结果可以看出,第 2 行重建结果的背景噪声更小,且图像的边缘更加清晰,分辨率更高。据此可以得出,在极为简单的神经网络中,RN 训练方法可以提高网络

和暗计数率下,二者的结果都十分相近,这说明加高斯噪声训练神经网络不能提高神经网络抗泊松噪声的能力。

的抗泊松噪声能力。对比第 3 行和第 4 行的实验结果,依旧可以发现相同的规律,DR2-net 是一种复杂且成熟的用于单光子压缩成像的神经网络,据此可以得出,无论是对于简单的神经网络还是较为复杂的神经网络,RN 都能够有效地增强重建网络的抗泊松噪声能力。

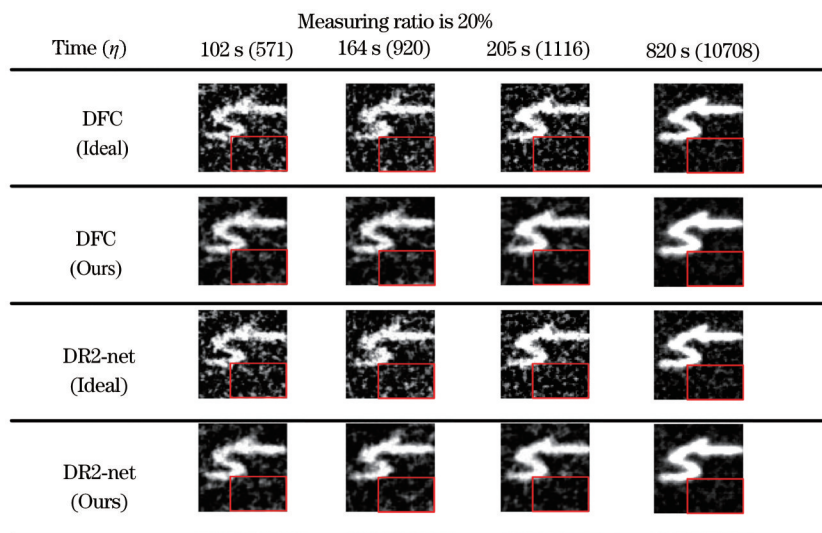


图 12 测量率固定为 20%,行代表不同的训练方法和不同的重建网络的重建结果,列代表不同测量时间(平均光子数 η)下的重建结果,所有图像的大小都是 64×64

Fig. 12 Rows represent the reconstructed results of different training methods and different reconstruction networks, the columns represent the reconstructed results at different sampling time (average number of photons η), and the size of all pictures is 64×64 when the sampling rate is a constant of 20%

3.2 不同重建方法的对比

实验中对比重建方法分别是 DFC-net, DR2-net, RPN-net 和 TVAL3。由图 13 仿真实验结果可以看出,在所有测量率下,所设计的 RPN-net 的图片

重建效果明显优于其他三种图片重建方法,远远高于传统的重建算法。由图 14 可得:RPN-net 的重建效果明显优于传统重建算法 TVAL3;与其他神经网络相比,在测量时间较低的情况下背景噪声相差




图 13 不同重建方法所重建出自然图片的平均 PSNR。(a)测量时间系数为 60;(b)测量时间系数为 100;(c)测量时间系数为 140
Fig. 13 Average PSNR of natural pictures reconstructed by different reconstruction methods. (a) Sampling time factor is 60; (b) sampling time factor is 100; (c) sampling time factor is 140

不大,这可能是由于用到的数据集是灰度图像,而重建目标却是分辨率板,不能极好地发挥RNP-net的抗噪声能力;随着测量时间的增加,图像边缘分辨率越来越高,且明显优于其他两种神经网络。据此可以得出,RPN-net的图像重建效果优于DFC-net和DR2-net。表1显示了不同重建方法重建图像的峰值信噪比与结构相似性(SSIM),表中MR代表测量率,加粗字体表示相同的图像在某一测量率下的最高PSNR与SSIM。综合分析所有数据得出,所设计的用于单光子压缩成像的网络具有非常不错的抗泊松噪声能力。

$$P_{SSIM}(\mathbf{I}, \mathbf{K}) = [\ell(\mathbf{I}, \mathbf{K})]^\alpha [c(\mathbf{I}, \mathbf{K})]^\beta [s(\mathbf{I}, \mathbf{K})]^\gamma, \quad (18)$$

$$\ell(\mathbf{I}, \mathbf{K}) = \frac{2\mu_I\mu_K + c_1}{\mu_I^2 + \mu_K^2 + c_1}, \quad (19)$$

$$c(\mathbf{I}, \mathbf{K}) = \frac{2\sigma_{IK} + c_2}{\sigma_I^2 + \sigma_K^2 + c_2}, \quad (20)$$

$$s(\mathbf{I}, \mathbf{K}) = \frac{\sigma_{IK} + c_3}{\sigma_I\sigma_K + c_3}, \quad (21)$$

式中: $\alpha > 0, \beta > 0$ 且 $\gamma > 0$; \mathbf{I} 和 \mathbf{K} 表示输入的两张图片; $\ell(\mathbf{I}, \mathbf{K})$ 是亮度比较, $c(\mathbf{I}, \mathbf{K})$ 是对比度比较, $s(\mathbf{I}, \mathbf{K})$ 是结构比较; μ_I 表示 \mathbf{I} 的平均值, σ_I 表示 \mathbf{I} 的标准差, σ_{IK} 表示 \mathbf{I} 和 \mathbf{K} 的协方差; c_1, c_2 和 c_3 均为常数。

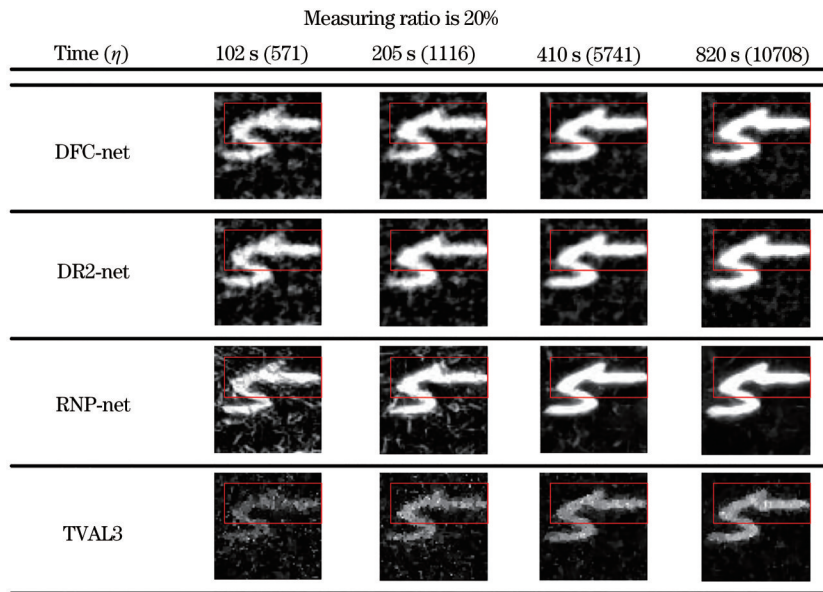


图 14 测量率固定为 20%, 行代表不同重建方法的重建结果, 列代表不同测量时间(平均光子数)的重建结果, 所有图像的大小都是 64×64

Fig. 14 Rows represent the reconstructed results of different reconstruction methods, the columns represent the reconstructed results at different sampling time (average number of photons), and the size of all pictures is 64×64 when the sampling rate is a constant of 20%

表 1 不同重建方法所重建出自然图片的平均 PSNR 与 SSIM

Table 1 Average PSNR and SSIM of natural pictures reconstructed by different reconstruction methods

Image name	Method	Parameter	MR is 0.05	MR is 0.10	MR is 0.15	MR is 0.20	MR is 0.25
Bird	DFC-net	PSNR	22.494	24.129	25.232	25.909	26.289
		SSIM	0.575	0.635	0.675	0.695	0.709
	DR2-net	PSNR	21.873	21.696	23.114	23.850	23.770
		SSIM	0.532	0.596	0.612	0.619	0.609
	TVAL3	PSNR	22.486	23.851	25.117	25.779	26.363
		SSIM	0.562	0.630	0.669	0.688	0.704
	RPN-net	PSNR	22.988	24.832	26.156	27.100	27.279
		SSIM	0.622	0.703	0.748	0.776	0.780
Monarch	DFC-net	PSNR	15.755	17.488	18.735	19.496	20.080
		SSIM	0.422	0.499	0.554	0.587	0.606

续表

Image name	Method	Parameter	MR is 0.05	MR is 0.10	MR is 0.15	MR is 0.20	MR is 0.25	
	DR2-net	PSNR	12.272	13.478	15.508	16.802	15.840	
		SSIM	0.407	0.517	0.601	0.626	0.616	
	TVAL3	PSNR	15.721	17.432	18.746	19.466	20.041	
		SSIM	0.422	0.503	0.554	0.587	0.608	
	RPN-net	PSNR	16.484	19.082	20.810	21.973	22.236	
		SSIM	0.505	0.628	0.704	0.751	0.752	
Cameraman	DFC-net	PSNR	19.724	20.869	21.535	22.031	22.410	
		SSIM	0.427	0.451	0.460	0.477	0.483	
	DR2-net	PSNR	14.818	14.564	14.403	17.760	17.323	
		SSIM	0.476	0.480	0.477	0.476	0.470	
	TVAL3	PSNR	19.693	20.748	21.530	22.058	22.458	
		SSIM	0.428	0.447	0.462	0.476	0.487	
	RPN-net	PSNR	20.567	22.250	23.080	23.900	23.963	
		SSIM	0.578	0.637	0.669	0.701	0.683	
	Fireman	DFC-net	PSNR	23.758	25.172	25.391	25.660	25.833
			SSIM	0.591	0.585	0.568	0.562	0.554
		DR2-net	PSNR	12.451	11.29	14.100	14.119	13.841
			SSIM	0.561	0.537	0.513	0.480	0.455
TVAL3		PSNR	23.910	24.691	25.581	25.704	25.814	
		SSIM	0.594	0.581	0.570	0.563	0.553	
RPN-net		PSNR	25.259	26.946	27.923	28.496	28.337	
		SSIM	0.725	0.767	0.784	0.803	0.776	
House		DFC-net	PSNR	22.413	23.964	24.432	25.162	25.262
			SSIM	0.510	0.526	0.525	0.537	0.525
		DR2-net	PSNR	15.530	16.819	16.559	16.295	16.092
			SSIM	0.533	0.531	0.497	0.487	0.458
	TVAL3	PSNR	22.634	23.481	24.573	25.059	25.285	
		SSIM	0.521	0.523	0.523	0.533	0.528	
	RPN-net	PSNR	23.668	25.889	26.983	27.760	27.641	
		SSIM	0.649	0.709	0.731	0.754	0.738	
	Lena	DFC-net	PSNR	19.622	20.825	21.511	22.040	22.339
			SSIM	0.449	0.484	0.514	0.528	0.538
		DR2-net	PSNR	16.103	16.438	13.821	16.344	18.309
			SSIM	0.444	0.482	0.462	0.500	0.462
TVAL3		PSNR	19.681	20.726	21.530	21.945	22.238	
		SSIM	0.449	0.484	0.508	0.524	0.531	
RPN-net		PSNR	20.608	22.101	22.813	23.449	23.579	
		SSIM	0.537	0.601	0.634	0.666	0.666	
Mean		DFC-net	PSNR	20.627	22.074	22.806	23.383	23.702
			SSIM	0.496	0.530	0.549	0.564	0.569
		DR2-net	PSNR	15.507	15.714	16.250	17.528	17.529
			SSIM	0.492	0.524	0.527	0.531	0.517
	TVAL3	PSNR	20.687	21.821	22.846	23.335	23.699	
		SSIM	0.496	0.528	0.547	0.562	0.569	

续表

Image name	Method	Parameter	MR is 0. 05	MR is 0. 10	MR is 0. 15	MR is 0. 20	MR is 0. 25
	RPN-net	PSNR	21. 595	23. 516	24. 627	25. 446	25. 505
		SSIM	0. 603	0. 674	0. 712	0. 742	0. 733

4 结 论

搭建了单光子压缩成像系统,推导出了测量值的泊松噪声模型,并在此基础上提出了一种用于单光子压缩成像的神经网络训练方法。通过对比不同训练方法,证明所提训练方法可有效提高各种已有压缩重建网络重建的图像质量。在此基础上,提出了一种专门用于单光子压缩成像的抗噪重建网络 RPN-net。通过实验对比 DR2-net、DFC-net、RPN-net 以及 TVAL3 算法,证明 RPN-net 具有更强的抗泊松噪声性能。

参 考 文 献

- [1] Yu W K, Yao X R, Liu X F, et al. Compressed sensing for ultra-weak light counting imaging[J]. Optics and Precision Engineering, 2012, 20(10): 2283-2292.
俞文凯, 姚旭日, 刘雪峰, 等. 压缩传感用于极弱光计数成像[J]. 光学精密工程, 2012, 20(10): 2283-2292.
- [2] Chan W L, Charan K, Takhar D, et al. A single-pixel terahertz imaging system based on compressed sensing[J]. Applied Physics Letters, 2008, 93(12): 121105.
- [3] Zanotto L, Piccoli R, Dong J, et al. Time-domain terahertz compressive imaging[J]. Optics Express, 2020, 28(3): 3795-3802.
- [4] Zhong Y F, Ren J J, Li L J, et al. Pulsed terahertz nondestructive detection tomography based on fringe suppression technology[J]. Chinese Journal of Lasers, 2020, 47(10): 1014001.
钟一帆, 任姣姣, 李丽娟, 等. 基于条纹抑制技术的脉冲太赫兹无损检测层析成像[J]. 中国激光, 2020, 47(10): 1014001.
- [5] Suhling K, Hirvonen L M, Becker W, et al. Wide-field time-correlated single photon counting-based fluorescence lifetime imaging microscopy[J]. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 2019, 942: 162365.
- [6] Zhang X, Lin D Y, Niu J J, et al. Low photon count fluorescence lifetime analysis based on alternating descent conditional gradient method[J]. Chinese Journal of Lasers, 2020, 47(2): 0207022.
张潇, 林丹樱, 牛敬敬, 等. 基于交替下降条件梯度的低光子数荧光寿命分析[J]. 中国激光, 2020, 47(2): 0207022.
- [7] Pian Q, Yao R, Sinsuebphon N, et al. Compressive hyperspectral time-resolved wide-field fluorescence lifetime imaging[J]. Nature Photonics, 2017, 11: 411-414.
- [8] Mannam V, Zhang Y D, Yuan X T, et al. Machine learning for faster and smarter fluorescence lifetime imaging microscopy[J]. Journal of Physics: Photonics, 2020, 2(4): 042005.
- [9] Liu Y X, Shi J H, Zeng G H. Single-photon-counting polarization ghost imaging[J]. Applied Optics, 2016, 55(36): 10347-10351.
- [10] Liu X F, Yu W K, Yao X R, et al. Measurement dimensions compressed spectral imaging with a single point detector[J]. Optics Communications, 2016, 365: 173-179.
- [11] Morris S A, Slesnick T C. Magnetic resonance imaging[M]//Alboliras E, Hijazi Z M, Lopez L, et al. Visual guide to neonatal cardiology. Chichester: John Wiley & Sons, 2018: 104-108.
- [12] Sun J, Li H, Xu Z. Deep ADMM-Net for compressive sensing MRI[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems, December 9, 2016, Barcelona, Spain. New York: Curran Associates, 2016: 10-18.
- [13] Candes E J, Romberg J, Tao T. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information[J]. IEEE Transactions on Information Theory, 2006, 52(2): 489-509.
- [14] Li C B, Yin W T, Jiang H, et al. An efficient augmented Lagrangian method with applications to total variation minimization[J]. Computational Optimization and Applications, 2013, 56(3): 507-530.
- [15] Kim Y, Nadar M S, Bilgin A. Compressed sensing using a Gaussian Scale Mixtures model in wavelet domain[C]//2010 IEEE International Conference on Image Processing, September 26-29, 2010, Hong Kong, China. New York: IEEE Press, 2010: 3365-3368.
- [16] Guan Y Q, Yan Q R, Yang S T, et al. Single-photon compressive imaging based on residual codec network[J]. Acta Optica Sinica, 2020, 40(1): 0111022.
管焰秋, 鄢秋荣, 杨晟韬, 等. 基于残差编解码网络的单光子压缩成像[J]. 光学学报, 2020, 40(1):

- 0111022.
- [17] Li B, Yan Q R, Wang Y F, et al. A binary sampling Res2net reconstruction network for single-pixel imaging[J]. *Review of Scientific Instruments*, 2020, 91(3): 033709.
- [18] Zhang J, Ghanem B. ISTA-net: interpretable optimization-inspired deep network for image compressive sensing[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 1828-1837.
- [19] Schlemper J, Caballero J, Hajnal J V, et al. A deep cascade of convolutional neural networks for MR image reconstruction[M]//Niethammer M, Styner M, Aylward S, et al. *Information processing in medical imaging. Lecture notes in computer science*. Cham: Springer, 2017, 10265: 647-658.
- [20] Adler A, Bublil D, Elad M, et al. A deep learning approach to block-based compressed sensing of images[EB/OL]. (2016-06-05)[2021-01-20]. <https://arxiv.org/abs/1606.01519>.
- [21] Kulkarni K, Lohit S, Turaga P, et al. ReconNet: non-iterative reconstruction of images from compressively sensed measurements[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 449-458.
- [22] Yao H T, Dai F, Zhang S L, et al. DR2-Net: deep residual reconstruction network for image compressive sensing[J]. *Neurocomputing*, 2019, 359: 483-493.
- [23] Tai Y, Yang J, Liu X M. Image super-resolution via deep recursive residual network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2790-2798.
- [24] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [25] Lee D, Yoo J, Ye J C. Deep residual learning for compressed sensing MRI[C]//2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017), April 18-21, 2017, Melbourne, VIC, Australia. New York: IEEE Press, 2017: 15-18.
- [26] Li C. An efficient algorithm for total variation regularization with applications to the single pixel camera and compressive sensing[D]. Houston: Rice University, 2010.
- [27] Xie X M, Wang Y X, Shi G M, et al. Adaptive measurement network for CS image reconstruction [M]//Yang J F, Hu Q H, Cheng M M, et al. *Computer vision. Communications in computer and information science*. Singapore: Springer, 2017, 772: 407-417.
- [28] Shimobaba T, Endo Y, Nishitsuji T, et al. Computational ghost imaging using deep learning[J]. *Optics Communications*, 2018, 413: 147-151.
- [29] Wu H, Wang R Z, Zhao G P, et al. Deep-learning denoising computational ghost imaging[J]. *Optics and Lasers in Engineering*, 2020, 134: 106183.
- [30] 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.
- [31] Vincent P, Larochelle H, Lajoie I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion[J]. *Journal of Machine Learning Research*, 2010, 11 (12): 3371-3408.
- [32] Chen M M, Xu Z X, Weinberger K, et al. Marginalized denoising autoencoders for domain adaptation[EB/OL]. (2012-06-18) [2021-01-20]. <https://arxiv.org/abs/1206.4683>.