

基于深度学习的单光子非视域成像泊松降噪

涂敏¹, 鄢秋荣^{1*}, 郑勇健¹, 熊贤成¹, 邹荃¹, 戴钱玲¹, 卢孝强²¹南昌大学信息工程学院, 江西 南昌 330031;²中国科学院西安光学精密机械研究所, 陕西 西安 710119

摘要 在非视域成像场景中,有效的回波光子大量减少,泊松噪声对非视域成像的质量影响较大。传统图像泊松降噪算法存在迭代时间长、模式固定和手动设置参数等问题。为提高非视域成像质量,设计一种基于深度学习的单光子非视域成像泊松降噪方法。为解决训练样本不足的问题,利用几何光学近似和蒙特卡罗方法对非视域场景下的光子运动轨迹进行追踪建模,对非视域成像过程进行仿真,利用仿真数据重建的泊松噪声图像制作数据集。设计基于注意力机制的特征增强降噪网络(AEF-Net),利用仿真数据对网络进行优化训练。最后,搭建一套非视域成像系统对网络的泊松降噪性能进行验证。实验结果表明所提 AEF-Net 去除非视域场景下的泊松噪声效果优于传统降噪算法。

关键词 非视域成像; 仿真分析; 深度学习; 泊松降噪

中图分类号 O438

文献标志码 A

DOI: 10.3788/LOP222969

Poisson Noise Suppression for Single-Photon Non-Line-of-Sight Imaging Based on Deep Learning

Tu Min¹, Yan Qiurong^{1*}, Zheng Yongjian¹, Xiong Xiancheng¹, Zou Quan¹, Dai Qianling¹,
Lu Xiaoqiang²¹School of Information Engineering, Nanchang University, Nanchang 330031, Jiangxi, China;²Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Sciences,

Xi'an 710119, Shaanxi, China

Abstract In non-line-of-sight imaging scenes, while effective echo photons are reduced to a great extent, Poisson noise largely impacts the non-line-of-sight imaging quality. Moreover, issues such as long iteration time, fixed mode, and manual parameter setting have been identified with traditional image Poisson noise suppression algorithms. Therefore, to improve the quality of non-line-of-sight imaging, this study designed a deep learning-based Poisson noise suppression method for single-photon non-line-of-sight imaging. First, geometrical optics approximation and Monte Carlo methods were implemented to track and model the photon motion trajectory in the non-line-of-sight scene, simulate the non-line-of-sight imaging process, produce a dataset using the Poisson noise images reconstructed from the simulation data, and address the problem of insufficient training samples. Subsequently, we designed an attention-based feature-enhanced noise suppression network (AEF-Net), followed by optimization and training of the network using simulation data. Furthermore, we built a non-line-of-sight imaging system to verify the Poisson noise suppression performance of the network. The experimental results show an outperformance of our designed noise suppression attention-based feature-enhanced noise suppression network than the conventional noise suppression algorithms for removing Poisson noise from non-line-of-sight scenes.

Key words non-line-of-sight imaging; simulation analysis; deep learning; Poisson noise suppression

1 引言

非视域成像技术^[1]是一种能够有效地对隐藏在拐角处的目标物体进行成像^[2-3]的技术。近些年来,非视

域成像已经在灾难救援、无人驾驶、反恐防爆、医学成像等领域有着广泛的研究^[4-5]。

非视域成像的手段与方法,主要包括激光测量飞行时间方法^[6]、激光散斑相关方法^[7]以及深度学习方

收稿日期: 2022-11-04; 修回日期: 2022-12-04; 录用日期: 2022-12-28; 网络首发日期: 2023-02-06

基金项目: 国家自然科学基金(61865010,62165009)、江西省研究生创新专项基金(YC2021-S146)

通信作者: *yanqiurong@ncu.edu.cn

法^[8]。2009年, Kirmani等^[9]首次提出了非视域成像的概念, 该研究成功使用玻璃窗对30 m之外的车牌进行了成像。2012年, 许凯达等^[10]搭建了距离选通的非视域成像系统, 该系统成功对50 m和20 m处的非视域目标进行了成像。2012年, Velten等^[11]利用条纹相机采集飞行时间数据, 并进行非视域成像。在此之后, 大量研究使用飞行时间数据对非视域目标进行重建。2015年, Buttafava等^[12]使用摆镜对非视域目标进行扫描, 利用单光子雪崩二极管(SPAD)收集飞行时间信息, 并进行非视域目标的重建, 重建分辨率可达几厘米量级。2015年, Jin等^[13]利用小孔式和盖革式的单光子探测器提取隐藏目标的三维信息, 三维重建的精度达到了厘米量级。2018年, 邱京耀等^[14]提出了一种基于单光子阵列探测器的隐藏目标瞬态成像方法, 通过仿真验证了该方法的可行性。2021年, Wu等^[15]采用了一种基于双望远镜共焦光学设计近红外波长的非视域成像系统, 该系统实现了对1.43 km内非视域目标的远距离成像。上述非视域成像方法对硬件设备的要求较高, 由于泊松噪声的影响, 测量飞行时间方法普遍存在非视域重建质量低的问题。

非视域成像过程中, 往往探测到的回波光光子数较少, 泊松噪声较大, 这些因素都制约着非视域成像质量的提高。研究非视域成像泊松降噪方法, 建立符合真实场景的非视域仿真模型, 对提高非视域成像质量有着十分重要的意义。对于传统的泊松图像降噪算法, 2011年, Luisier等^[16]提出了泊松无偏风险估计阈值的线性扩展(PURE-LET)算法, 该算法通过对泊松噪声强度进行估计, 在真实图像上获得降噪结果。2016年,

Azzari等^[17]使用迭代算法对泊松图像进行降噪, 该算法逐步提高了高斯降噪滤波器的方差稳定变换(VST)的有效性, 具有更好的降噪效果。但传统的泊松降噪算法无法避免数据计算量大、迭代时间较长等问题。

目前基于深度学习的图像降噪算法具有良好的降噪性能, 有效地避免了计算量大、迭代时间长的问题。2021年, Jo等^[18]使用深度图像先验信息对泊松图像进行降噪, 保留了大量的细节信息。2022年, Zha等^[19]提出了一种同时使用非局部低秩和深度先验进行泊松降噪的新方法, 该方法具有更好的降噪效果。但上述深度学习方法使用的泊松噪声数据集都不符合非视域场景的要求, 无法实现更好的非视域成像泊松降噪效果。

传统降噪算法迭代时间长, 且符合非视域场景的数据集较少, 另外, 考虑到越精确的数据集训练出来的网络应用于实际系统时的效果越好, 因此, 本文建立一种基于双向散射分布函数的非视域成像系统的仿真模型, 制作数据集, 提出了一种用于非视域成像泊松降噪的基于注意力机制的特征增强泊松降噪网络(AEF-Net)。分别使用仿真数据和搭建非视域成像系统对所设计的仿真模型和降噪网络进行验证, 实验结果表明所提模型具有实际的应用价值。

2 非视域成像系统的仿真设计

2.1 非视域成像系统

非视域成像系统的原理如图1所示。激光器发出的脉冲式激光首先通过分束立方体, 被分成两束偏振方向相互垂直的线偏振光, 线偏振光通过四分之一波

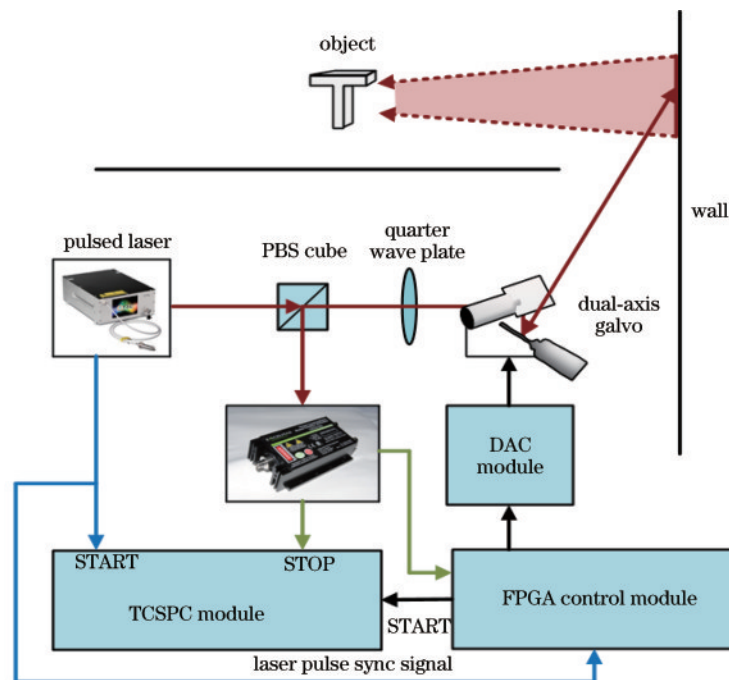


图1 非视域成像系统的实验装置

Fig. 1 Experimental setup of the non-line-of-sight imaging system

片后变成圆偏振光,通过 field programmable gate array (FPGA)控制二维振镜翻转对中介面进行扫描,光在中介面发生第 1 次漫反射后,漫反射到隐藏的目标物体上。在目标物体上发生第 2 次漫反射后,光子再次反射到中介面,并在中介面发生第 3 次漫反射,之后再通过二维振镜、四分之一波片和分束立方体,返回的光子经分束立方体分束后,以 90°射入单光子探测器中。单光子探测器将光信号转换成离散的电脉冲信号,输入 time-correlated single-photon counting (TCSPC) 采集卡中,对光子的飞行时间进行测量。最后使用获取的非视域场景下的光子飞行时间数据对非视域目标场景进行重建。

2.2 非视域成像系统仿真设计

在对非视域场景进行仿真的过程中,中介面场景多种多样,不同表面的粗糙度不同,导致不同中介面的光子散射分布不同。为了简化模型,被测目标和中介面均设置为具有相同散射分布特性的材料,并只考虑散射后的角度分布。

双向散射分布函数反映了单位投影面积上单位立体角上散射能量与入射能量之比。使用入射光线和散射光线的能量分布模型来代替入射光线和散射光线的角度分布模型。其中所有反射点的双向散射分布函数为

$$\rho''(\Omega_s, \Omega_i) = \frac{\pi}{\cos \theta_s} \left(\frac{d\Phi_s}{d\Omega_s} / \frac{d\Phi_i}{d\Omega_i} \right), \quad (1)$$

式中: Φ 为每一个角度的能量; Ω 为散射区域的立体角; s 和*i*分别表示散射和入射; $\cos \theta_s$ 是散射角的余弦值。在得到光子在非视域场景中的散射角度分布后,建立以光源位置为坐标原点、光源与探测器之间的平面为*xy*平面、光源中心轴线为*z*轴的三维坐标系。初始化光子的位置坐标为(0, 0, 0)。在光子与中介面发生碰撞的过程中,光子会发生吸收衰减或者散射作用,衰减比例表示为

$$\eta = \sqrt{v_a + v_s}, \quad (2)$$

式中: v_a 和 v_s 分别表示吸收系数和散射系数。根据得到的光子散射角 θ ,计算得光子运动步长为

$$s = d / \cos \theta, \quad (3)$$

式中: d 是两次碰撞所在平面的垂直距离。光子在运动相应步长后发生散射和吸收的概率分别为

$$p_s = (1 - e^{-s}) \cdot (1 - \eta), \quad (4)$$

$$p_a = (1 - e^{-s}) \cdot \eta. \quad (5)$$

光子每一次碰撞后的运动方向都会发生变化,因此需要对光子发生碰撞后的散射角 θ 和方位角 ω 进行更新。散射角 θ 是由光线追踪得到的,方位角 ω 表示为

$$\omega = 2\pi\sigma, \quad (6)$$

式中: σ 是在[0, 1]内的服从均匀分布的随机数,即方位角 ω 在三维坐标系中服从[0, 2 π]范围内的均匀分

布。则光子沿*z*轴方向更新的方向余弦为

$$\begin{cases} u_x = \sqrt{1 - \cos^2 \theta} \times \cos \omega \\ u_y = \sqrt{1 - \cos^2 \theta} \times \sin \omega, \\ u_z = \cos \theta \end{cases}, \quad (7)$$

则可得到光子碰撞之后的位置坐标:

$$\begin{cases} x_{n+1} = x_n + s \times u_x \\ y_{n+1} = y_n + s \times u_y. \\ z_{n+1} = z_n + s \times u_z \end{cases} \quad (8)$$

经过三次碰撞之后,光子到达接收端,根据探测器的位置和接收孔径的大小,确定最终能够被探测器接收的光子,并同时记录光子飞行时间。

3 神经网络的设计及数据集的制作

3.1 AEF-Net的架构

所设计的 AEF-Net 整体架构如图 2(a)所示,网络由稀疏模块(sparse block)、特征增强模块(feature enhancement block)、注意力机制模块(CBAM block)组成。

为了兼顾模型的降噪性能和计算复杂度,设计了一个稀疏模块,如图 2(b)所示,将空洞卷积与稀疏卷积相结合,模块中的卷积通道数设置为 32,卷积核大小设置为 3 × 3。空洞卷积的引入在一定程度上增大了网络的感受野,并且在保证网络降噪性能的同时降低了计算复杂度。

为了进一步提升模型的性能,使用特征增强模块对图片进行特征信息增强,其结构如图 3(c)所示。经过三层卷积融合特征图信息,获得降噪后的图像并将其输入循环神经网络(RNN)中,RNN在一段时间上对特征进行循环提取,该模块每一个时刻的输出都由上一个时刻的输出和隐藏状态矩阵决定。RNN模块由 2 个 ConvRNNcell 单元构成,每个单元的结构如图 2(e)所示,每个 ConvRNNcell 的输出由隐藏状态矩阵(记忆信息)和当前时刻的输入决定。对于每个 ConvRNNcell,输入的图像信息与记忆信息进行通道拼接,再经卷积融合数据特征后获得最终输出。不同于普通的卷积操作,模块中的 Depthwise 卷积将输入特征图的通道数量扩展为 2 倍,并对每个通道的信息进行单独提取,最后由卷积核大小为 1 × 1 的 Pointwise 卷积对每个特征通道的信息进行像素级的融合。图 2(d)所示的 RNN 模块中, x 为输入图像, H_t 为上一个时刻的记忆信息, H_{t+1} 为新产生的记忆信息,实质上是通道数为 32、与输入图片长宽相同的特征图。RNN 的特征之一是权重共享,所设计的 RNN 模块在循环提取输入特征信息的同时,还可以有效地减少整个网络的参数量,减轻计算终端的存储压力。最后,特征增强模块的输出是 RNN 模块输出的图像与稀疏模块、模型输入进行通道拼接后产生的。

对得到的 3 通道图像使用一个 3 × 3 的卷积,直到

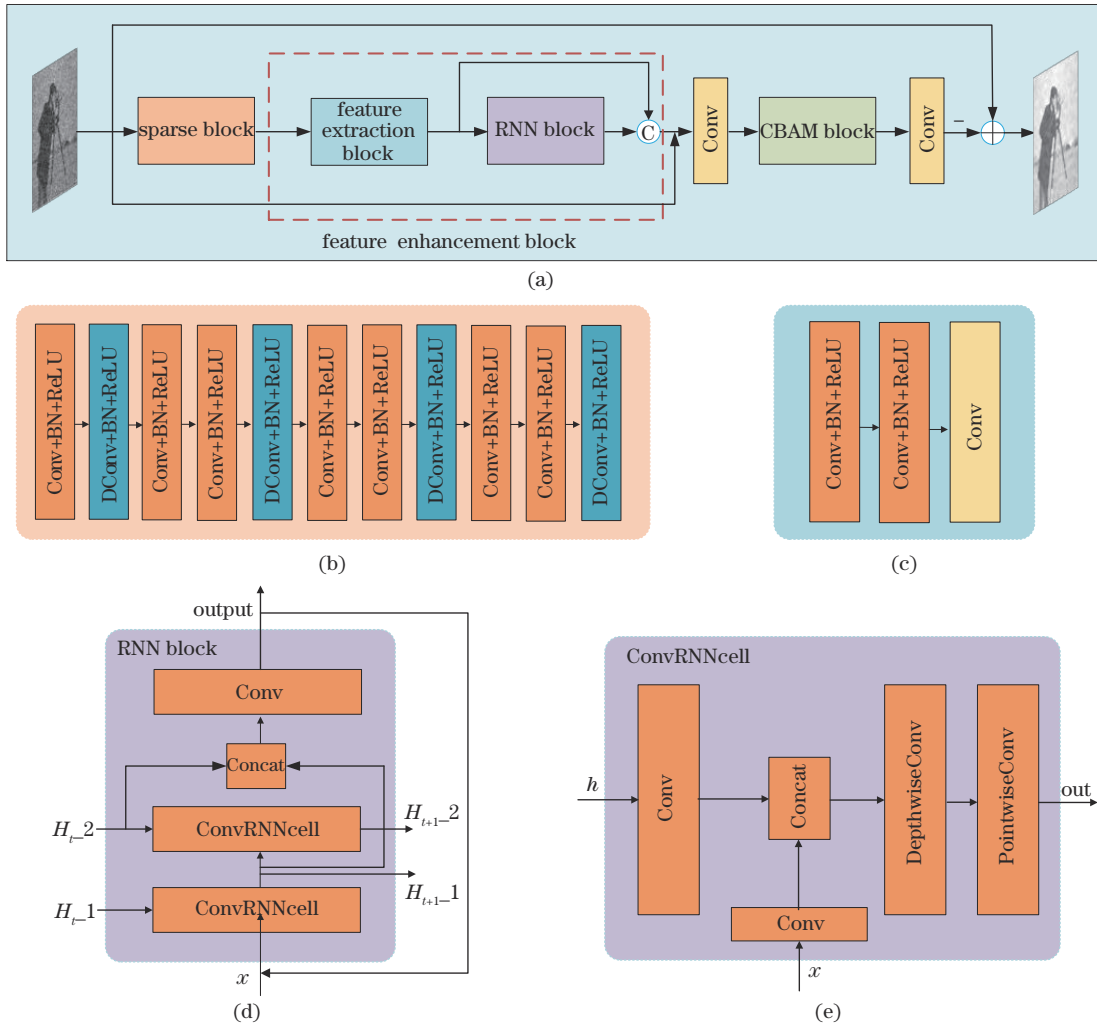


图2 网络结构。(a) AEF-Net结构；(b) 稀疏模块；(c) 特征提取模块；(d) RNN模块；(e) ConvRNNcell单元

Fig. 2 Network structures. (a) Structure of AEF-Net; (b) sparse block; (c) feature enhancement block; (d) RNN block; (e) ConvRNNcell

获得 32 通道图像，并将其放进一个 CBAM 中。CBAM 是文献[20]提出的轻量级注意力模块，其中包含 2 个独立的子模块、通道注意力模块和空间注意力模块，分别进行通道与空间上的注意力提取，能够更好地关注图像的某些重要特征。最后对输出结果与输入噪声进行差值处理，即可得到网络的降噪图像。

3.2 非视域目标的重建算法及数据集的制作

由于探测器中接收到的单光子脉冲不仅包含三次反射的单光子脉冲，还包括环境光噪声和探测器暗计数所引起的噪声脉冲。因此，为了减少环境光噪声对成像质量的影响，根据时间门控滤波算法的思路，将光子飞行时间低于设定的阈值的光子判定为噪声光子，光子飞行时间高于阈值的光子则判定为有效光子。假设光子从非视域目标表面发出到被探测器接收的直线距离为 r ，非视域目标的中心平面位置坐标为 $(0, 0)$ ，重建图像的分辨率为 $m \times n$ 像素， c 为光速，实际系统中，二维振镜最大的扫描角度为 $\theta_0 = \pm 10^\circ$ ，接收器的视场角为 $\theta_{\text{rec}} = \pm 10^\circ$ ，则光子在非视域目标对应的像素点 (x, y) 上的位置距离 (r_x, r_y) 可表示为

$$\begin{cases} r_x = \frac{r \tan 20^\circ}{m/2} \times \left(\frac{m}{2} - x + \frac{1}{2} \right) \\ r_y = \frac{r \tan 20^\circ}{n/2} \times \left(y - \frac{n}{2} - \frac{1}{2} \right) \end{cases}, \quad (9)$$

则可计算出光子飞行的最大距离，对应时间阈值为

$$\Delta t_{xy} = 2 \frac{\sqrt{r_x^2 + r_y^2 + r^2}}{c}. \quad (10)$$

去除背景光噪声后，需要对非视域目标的反射率进行估计，得到非视域目标的灰度图。假设某一像素点 (x, y) 上对应的扫描时间为 $[0, T_{\text{pix}}]$ ，对应到实际距离，可近似平均分成 N 份，每等份的时间间隔记为 T ，对于每一像素点而言，时间间隔内探测到的光子数为 Z_1, Z_2, \dots, Z_N ，完成一次完整的扫描光子数为 z_1, z_2, \dots, z_N ，使用极大似然估计法可得到时间间隔 T 内的该像素上的平均光子数：

$$p(Z_1 = z_1, Z_2 = z_2, \dots, Z_N = z_N) = \prod_{i=1}^N \frac{W_{xy}^{z_i}}{z_i!} e^{-W_{xy}} = L(z_1, \dots, z_N; W_{xy}), \quad (11)$$

$$\ln L(z_1, \dots, z_N; W_{xy}) = \sum_{i=1}^N z_i \ln W_{xy} - NW_{xy} - \ln \left(\prod_{i=1}^N z_i! \right), \quad (12)$$

式中: W_{xy} 表示非视域物体对应点的光子数服从参数为 W_{xy} 的泊松分布。则 T 时间内探测到的光子数的极大似然估计值为

$$\hat{W} = \frac{1}{N} \sum_{i=1}^N z_i. \quad (13)$$

对于某一像素点 (x, y) , 在整个时间间隔 T_{pix} 内探测器检测到的光子总数的极大似然估计为

$$R_{xy} = \frac{\ln M - \ln(M - W_{xy})}{CI}, \quad (14)$$

式中: I 是激光每个脉冲的光子数; C 表示一个常数; M 是每个像素上有 M 个激光周期。计算出每个像素点上探测到的光子总数, 即可得到带有泊松噪声的非视域重建结果。

利用非视域仿真和实际实验获得的光子飞行时间数据, 使用非视域重建算法对获取的光子飞行时间数

据进行重建, 将 BSD200 数据集和 SET11 数据集的仿真重建结果分别制作为训练集和测试集, 并将实际实验重建结果用来测试, 来检验降噪效果。在 AEF-Net 训练阶段, 将 BSD200 数据集作为成像目标, 利用构建的非视域成像模型进行仿真, 产生了 153 张图像。训练时的 batch size 设置为 4, 优化器为 Adam, 学习率为 0.0001, epoch 数为 120, 损失函数为均方误差。训练网络的电脑所搭载的环境为 Inter i7-11700K CPU 3.60 GHz, NVIDIA RTX3060 GPU, 64 GB RAM, 训练所需时间约为 85 min。训练完成后的网络在 SET11 数据集上的平均处理时间约为每张图片 12 ms。

4 结果与讨论

4.1 不同光子数对仿真重建结果的影响

将非视域目标、中介面、探测器直线距离均设置为 0.6 m, 使用相同的中介面, 使用大写字母“NCU”非视域物体进行仿真。比较不同的光子数量对仿真结果的影响, 仿真结果如图 3 所示。




图 3 不同光子个数下非视域仿真重建结果。(a) 光子数为 1×10^4 ; (b) 光子数为 5×10^4 ; (c) 光子数为 1×10^5 ; (d) 光子数为 5×10^5

Fig. 3 Reconstruction results of non-line-of-sight simulation at different photons. (a) Number of photons is 1×10^4 ; (b) number of photons is 5×10^4 ; (c) number of photons is 1×10^5 ; (d) number of photons is 5×10^5

由图 3 的仿真重建结果可知, 随着光子数量的依次增多, 仿真重建的质量也越来越好, 当光子数大于 1×10^5 时, 字母“NCU”的清晰度也越来越高。在非视域成像过程中, 随着光子数的增多, 相应的回波光子的数量也越来越多, 探测器接收到的有效光子数也越来越多, 进而重建质量得到提升。

4.2 不同距离对仿真重建结果的影响

使用大写字母“NCU”非视域物体进行仿真, 使用同一中介面, 光子个数固定为 1×10^5 , 依次改变中介面和探测器之间的距离, 其他距离均设置为 0.6 m, 验证不同距离对仿真结果的影响, 仿真重建结果如图 4 所示。




图 4 不同距离下的非视域仿真重建结果。(a) 0.5 m; (b) 1 m; (c) 2 m; (d) 4 m

Fig. 4 Reconstruction results of non-line-of-sight simulation at different distances. (a) 0.5 m; (b) 1 m; (c) 2 m; (d) 4 m

由图 4 的仿真重建结果可知, 当增大探测器和中介面之间的距离时, 仿真重建的质量越来越差。在非视域成像过程中, 对于相同的中介面, 光子与中介面发生碰撞后, 其发生散射的角度分布相同, 随着探测器与

中介面之间的距离增大, 探测器的有效孔径接收到回波光子的数量也越来越少, 成像质量随之下降。

4.3 不同数据集对泊松降噪的结果对比

固定选取探测器、中介面、非视域目标之间的距离

为 0.6 m, 使用 5×10^6 、 1×10^7 和 1×10^8 个光子对 BSD200 数据集进行非视域仿真, 制作数据集, 并使用不同噪声类型的数据集来训练 AEF-Net, 其中包括仿真数据集训练出来的网络 AEF-Net(Ours)、加标准差为 $\delta = 30$ 的高斯噪声训练出来的 AEF-Net($\delta = 30$)、加标准差为 $\delta = 45$ 的高斯噪声训练出来的 AEF-Net($\delta = 45$)。网络的抗噪声性能使用降噪之后图像的峰值信噪比(PSNR)进行表征。

$$N_{\text{PSNR}} = 10 \log_{10} \frac{y_{\text{max}}^2}{E_{\text{MS}}} = 20 \log_{10} \frac{y_{\text{max}}}{\sqrt{E_{\text{MS}}}}, \quad (15)$$

式中: E_{MS} 为均方误差; y_{max} 为整张图片中的像素最大值。对比两种不同的噪声类别的数据集训练出来的网络, 图像质量评价指标为降噪后的 PSNR, 实验结果如图 5 所示。

分析图 5 可知: 在非视域场景下, 对于相同的降噪网络 AEF-Net, 仿真生成的数据集训练的网络比噪声水平分别为 $\delta = 30$ 和 $\delta = 45$ 的高斯噪声训练的网络具有更好的降噪效果; 在仿真光子数较多时, 此时泊松噪声的影响相对减小, 泊松噪声训练的网络能够更好地学习到数据集中的噪声信息, 重建质量有着明显的提升。即本次设计的非视域仿真生成的数据训练的神经网络能够更好地提高泊松噪声去除效果。

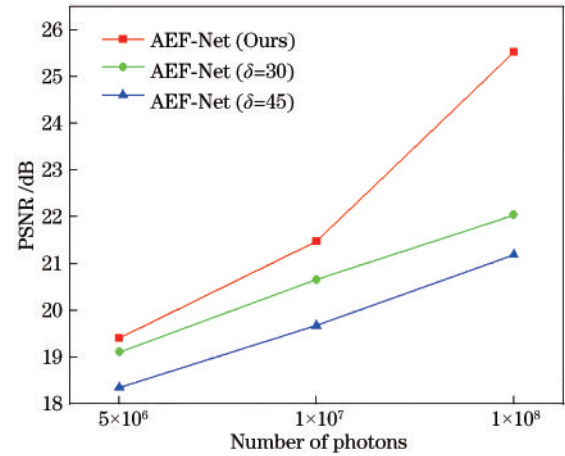


图 5 不同噪声类型数据集训练网络降噪的平均 PSNR 值比较
Fig. 5 Comparison of average PSNR of networks trained by dataset with different noises

为了验证所提非视域仿真模型的有效性与实用性, 设计搭建了基于单光子的非视域成像的硬件实验系统。固定激光频率为 4 MHz。以瓷砖为中介面, 亚克力板材质的“光”字为非视域目标, 使用 512 s、1024 s、2048 s 时间进行扫描, 并将带有实际泊松噪声的重建结果输入到上述 3 种噪声模型训练的网络中进行降噪处理, 实验结果如图 6 所示。




图 6 不同 AEF-Net 的降噪结果。(a) 扫描时间为 512 s; (b) 扫描时间为 1024 s; (c) 扫描时间为 2048 s

Fig. 6 Noise suppression results obtained by different AEF-Net; (a) Scan time of 512 s; (b) scan time of 1024 s; (c) scan time of 2048 s

分析图 6 可知: 随着扫描时间的增加, 探测器接收到的光子数越多, 非视域目标轮廓也越来越清晰, 重建

质量也越来越高; 使用三种不同的噪声模型训练的网络对实际非视域重建图像进行泊松降噪时, 所设计的

非视域仿真模型制作的泊松噪声数据集训练的网络具有较好的降噪结果,相比于使用高斯噪声训练的网络,不仅能够更好地去除成像目标“光”范围之外的泊松噪声,还能够更好地保留光子计数图像特征信息。

4.4 不同降噪方法对泊松降噪的结果对比

实验中对比的降噪算法是传统的 PURE、VST 算法、自主设计的 AEF-Net,使用这些算法分别对利用 5×10^6 、 1×10^7 和 1×10^8 个光子进行非视域仿真得到的泊松噪声数据集进行降噪,实验结果如图 7 所示。

分析图 7 可知:在非视域场景下,所提 AEF-Net 的降噪效果优于其他两种传统泊松图像降噪算法 PURE 算法和 VST 算法;在光子数为 5×10^6 时,由于有效光子数量较少,非视域场景中的有效光子的信噪比也相对较低,重建图片质量较差,网络不能很好地对泊松噪声进行学习,但随着光子数的增多,有效光子的信噪比也越来越高,图像边缘的特征信息也越来越多,所提 AEF-Net 的重建结果也明显优于 PURE 算法和 VST 算法。

为了验证所提 AEF-Net 对实际的非视域重建结果的降噪性能,使用基于单光子的非视域成像的硬件

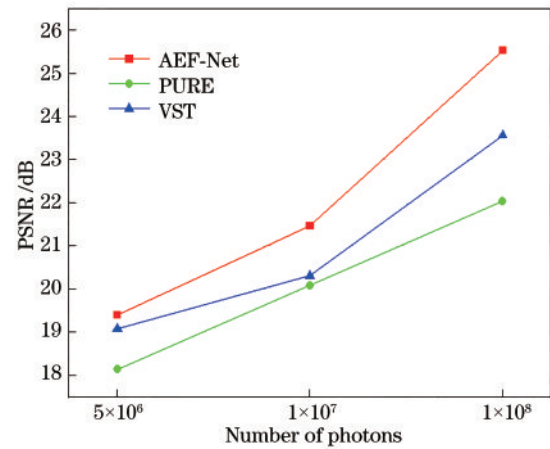


图 7 不同降噪算法的平均 PSNR 值比较

Fig. 7 Comparison of average PSNR for different noise suppression algorithms

实验系统。固定激光频率为 4 MHz。以瓷砖为中介面,亚克力板材质的“光”字为非视域目标,使用 512 s、1024 s、2048 s 时间进行扫描,并使用 AEF-Net、PURE 和 VST 算法对实际非视域重建结果进行降噪处理,实验结果如图 8 所示。




图 8 不同算法的降噪结果。(a) 扫描时间为 512 s; (b) 扫描时间为 1024 s; (c) 扫描时间为 2048 s

Fig. 8 Noise suppression results of different algorithms. (a) Scan time of 512 s; (b) scan time of 1024 s; (c) scan time of 2048 s

分析图 8 可知:分别使用三种不同的算法对实际非视域重建图像进行泊松降噪时,所提 AEF-Net 能够对成像目标“光”字范围之外的泊松噪声进行去除,而传统算法 PURE 和 VST 的降噪结果在成像范围之外仍残留有大量噪声。故所提 AEF-Net 的降噪效果都

优于传统的泊松图像降噪算法 PURE 和 VST。

5 结 论

搭建了基于单光子的非视域成像系统,建立了基于双向散射分布函数的非视域成像系统的仿真模型,

通过改变光子数量和距离,对设计的仿真模型的正确性进行了验证。设计了一种专门用于非视域成像的深度学习泊松图像降噪网络 AEF-Net,对其与传统的 PURE 和 VST 泊松图像降噪算法进行对比,证明本次设计的 AEF-Net 具有更好的泊松噪声抑制效果。在此基础上,通过对比不同噪声模型训练的网络,验证了仿真模型制作的数据集训练的网络 AEF-Net 能够较好地抑制非视域场景下的泊松噪声的结论。

参 考 文 献

- [1] Faccio D, Velten A, Wetzstein G. Non-line-of-sight imaging[J]. *Nature Reviews Physics*, 2020, 2(6): 318-327.
- [2] Kirmani A, Hutchison T, Davis J, et al. Looking around the corner using ultrafast transient imaging[J]. *International Journal of Computer Vision*, 2011, 95(1): 13-28.
- [3] Renna M, Nam J H, Buttafava M, et al. Fast-gated 16×1 SPAD array for non-line-of-sight imaging applications[J]. *Instruments*, 2020, 4(2): 14.
- [4] Batarseh M, Sukhov S, Shen Z, et al. Passive sensing around the corner using spatial coherence[J]. *Nature Communications*, 2018, 9: 3629.
- [5] Klein J, Laurenzis M, Hullin M. Transient imaging for real-time tracking around a corner[J]. *Proceedings of SPIE*, 2016, 9988: 998802.
- [6] Tsai C Y, Kutulakos K N, Narasimhan S G, et al. The geometry of first-returning photons for non-line-of-sight imaging[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2336-2344.
- [7] Li Y Z, Xue Y J, Tian L. Deep speckle correlation: a deep learning approach toward scalable imaging through scattering media[J]. *Optica*, 2018, 5(10): 1181-1190.
- [8] 于亭义, 乔木, 刘红林, 等. 基于深度学习的非视域成像[J]. *光学学报*, 2019, 39(7): 0711002.
Yu T Y, Qiao M, Liu H L, et al. Non-line-of-sight imaging through deep learning[J]. *Acta Optica Sinica*, 2019, 39(7): 0711002.
- [9] Kirmani A, Hutchison T, Davis J, et al. Looking around the corner using transient imaging[C]//2009 IEEE 12th International Conference on Computer Vision, September 29-October 2, 2009, Kyoto, Japan. New York: IEEE Press, 2010: 159-166.
- [10] 许凯达, 金伟其, 刘敬, 等. 基于激光距离选通成像的非视域成像应用[J]. *红外与激光工程*, 2012, 41(8): 2073-2078.
- Xu K D, Jin W Q, Liu J, et al. Non-line-of-sight imaging based on laser range-gated imaging technology [J]. *Infrared and Laser Engineering*, 2012, 41(8): 2073-2078.
- [11] Velten A, Willwacher T, Gupta O, et al. Recovering three-dimensional shape around a corner using ultrafast time-of-flight imaging[J]. *Nature Communications*, 2012, 3: 745.
- [12] Buttafava M, Zeman J, Tosi A, et al. Non-line-of-sight imaging using a time-gated single photon avalanche diode [J]. *Optics Express*, 2015, 23(16): 20997-21011.
- [13] Jin C F, Song Z T, Zhang S Q, et al. Recovering three-dimensional shape through a small hole using three laser scatterings[J]. *Optics Letters*, 2015, 40(1): 52-55.
- [14] 邹京耀, 苏秀琴, 谭京京, 等. 基于单光子阵列探测器的隐藏目标瞬时成像理论研究(英文)[J]. *红外与激光工程*, 2018, 47(S1): S122001.
Wu J Y, Su X Q, Tan J J. Study of theory for transient imaging of hidden object using single-photon array detector[J]. *Infrared and Laser Engineering*, 2018, 47(S1): S122001.
- [15] Wu C, Liu J J, Huang X, et al. Non-line-of-sight imaging over 1.43 km[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2021, 118(10): 2024468118.
- [16] Luisier F, Blu T, Unser M. Image denoising in mixed Poisson-Gaussian noise[J]. *IEEE Transactions on Image Processing*, 2011, 20(3): 696-708.
- [17] Azzari L, Foi A. Variance stabilization for noisy estimate combination in iterative Poisson denoising[J]. *IEEE Signal Processing Letters*, 2016, 23(8): 1086-1090.
- [18] Jo Y, Chun S Y, Choi J. Rethinking deep image prior for denoising[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2022: 5067-5076.
- [19] Zha Z Y, Wen B H, Yuan X, et al. Simultaneous nonlocal low-rank and deep priors for Poisson denoising [C]//2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), May 23-27, 2022, Singapore, Singapore. New York: IEEE Press, 2022: 2320-2324.
- [20] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018. Lecture notes in computer science*. Cham: Springer, 2018, 11211: 3-19.