

用于光子计数单像素成像的去块状采样网络

熊乙宁, 鄢秋荣*, 祝志太, 蔡源鹏, 杨耀铭

(南昌大学信息工程学院, 江西南昌 330031)

摘要: 将光子计数技术和单像素成像结合, 能实现高灵敏、低成本的光子计数成像, 但存在采样时间和重建时间长的问题。基于深度学习的压缩采样和重建网络, 将去除偏置和激活函数的全连接层作为测量矩阵, 通过从数据中学得高效的测量矩阵和避免传统迭代算法带来的巨大计算量, 实现了更快、更高质量的图像重建。但利用全连接层进行高分辨图像的分块压缩感知时, 重建图像会产生块状效应。针对该问题提出了重叠分块采样网络 (Os_net)、嵌套采样网络 (Ns_net)、卷积采样网络 (Cs_net) 等三种方法以取代全连接层采样。在重建网络的设计中, 使用线性映射网络对图像进行重建, 设计实验结果表明 Cs_net 的去块状化效果最好。将 Cs_net 二值化后应用于光子计数单像素成像系统, 实验结果表明 Cs_net 除块状化明显优于传统算法 TVAL3, 且 Cs_net 在重建质量上也同样取得了较好的效果。

关键词: 分块压缩感知; 块效应; 光子计数技术; 单光子压缩成像; 深度学习

中图分类号: O438 文献标志码: A DOI: 10.3788/IRLA20210724

Deblocking sampling network for photon counting single-pixel imaging

Xiong Yining, Yan Qiurong*, Zhu Zhitai, Cai Yuanpeng, Yang Yaoming

(School of Information Engineering, Nanchang University, Nanchang 330031, China)

Abstract: Combining photon counting technology with single-pixel imaging can achieve highly sensitive and low cost photon counting imaging, but there are problems of long sampling time and long reconstruction time. The compressed sampling and reconstruction network, which is based on deep learning, uses the fully connected layer without the offset and activation function as the measurement matrix, achieves faster and higher quality image reconstruction by learning efficient measurement matrices from the data and avoids the huge amount of calculation caused by traditional iterative algorithms. However, when the fully connected layer is used for block compression sensing of high-resolution images, the reconstructed image will produce block artifact. In response to this problem, overlapping block sampling network (Os_net), nested sampling network (Ns_net), and convolution sampling network (Cs_net) were proposed: to replace fully connected layer sampling. In the design of the reconstructed network, the images were reconstructed by using a linear mapping network. The design experiment shows that Cs_net has the best deblocking effect. After Cs_net binarization is applied to a photon counting single-pixel imaging system, the experiment results show that Cs_net de-blocking effect is significantly better than the traditional algorithm TVAL3, and Cs_net has also achieved good results on the reconstruction quality.

Key words: block-compressed sensing; block artifact; photon counting technology; single-photon compression imaging; deep learning

收稿日期: 2021-09-30; 修订日期: 2021-11-12

基金项目: 国家自然科学基金 (61865010)

作者简介: 熊乙宁, 女, 硕士生, 主要从事计算单像素成像方面的研究。

导师(通讯作者)简介: 鄢秋荣, 男, 副教授, 硕士生导师, 博士, 主要从事单像素成像、单光子成像、光电精密仪器方面的研究。

0 引言

单像素成像 (Single Pixel Imaging, SPI) 是利用点探测器实现物体成像的技术, 基于压缩感知理论的单像素成像方法由 Takhar D 等人首次提出^[1], 在数字微镜 (Digital Micromirror Device, DMD) 上加载一系列掩膜对光学图像进行调制, 调制后的光强由无空间分辨的点探测器进行探测, 然后利用所测光强和掩膜对应的测量矩阵重建图像。若采用单光子探测器作为点探测器, 则可以将单像素成像与光子计数技术相结合, 实现光子计数单像素成像^[2-4]。该方法有两个主要优点: 一是仅使用点探测器就可以实现二维光子计数成像, 与阵列探测器相比成本较低、分辨率高, 特别是在红外、太赫兹^[5]等特殊波段; 二是单像素计数压缩成像系统中的点探测器可以同时收集多个像素的光强, 成像灵敏度超过所采用的探测器本身的灵敏度的极限^[6]。因此光子计数单像素成像在生物医学诊断、天文、光谱测量等超弱光成像检测中具有广泛的应用前景^[7-9]。

目前的单像素成像系统的采样和重建主要有三种方法: 一是先利用随机测量矩阵或正交固定矩阵进行欠采样, 然后再利用迭代算法进行图像重建。常用测量矩阵有高斯测量矩阵^[10]、伯努利测量矩阵^[11]、拓普利兹矩阵^[12]、哈达玛矩阵和部分的随机傅里叶矩阵^[13], 重建算法有正交匹配追踪 (Orthogonal Matching Pursuit, OMP)^[14]、正规化正交匹配追踪 (Regularized Orthogonal Matching Pursuit, ROMP)^[15] 和全变分增广拉格朗日交替方向算法 (Total variation Augmented Lagrangian Alternating Direction Algorithm, TVAL3)^[16] 等。由于测量次数远小于图像像素数时要通过优化求解不确定性问题来重建图像, 需要耗费大量的时间进行迭代运算。二是同样使用高斯随机测量矩阵或正交固定矩阵进行欠采样, 利用基于深度学习的压缩重建网络进行图像重建。训练后权重固定的重建网络从低维采样值拟合映射到高维的图像, 可避免上述传统迭代算法带来的大量计算, 从而实现快速重建。深度学习压缩重建网络有 SDA^[17]、RconNet^[18]、DR2_net^[19]、ISTA-Net^[20] 等。2018 年, C. F. Higham 等率先将卷积自编码网络用于经过线性采集的图像

的重构, 该方法具有比压缩感知 (Compressed Sensing, CS) 理论常用重构算法更短的重建时间, 并且能够在超低采样率的情况下实现更清晰的重构图像^[21]。2019 年, 中国科学院上海光学精密机械研究所的司徒国海等提出了一种应用于鬼成像的端对端的深度学习方法, 该方法将图像与处理过的掩膜相乘得到仿真数据用于神经网络的训练^[22]。2020 年, 笔者课题组的李冰提出了 Bsr2-Net 网络进行图片重建, 并与传统算法 TVAL3 进行对比, 研究表明, 使用深度学习方法测量重建的方法无论在成像质量上还是重建时间上都表现的更好^[23]。三是使用采样和重建集成的深度神经网络。2020 年, 笔者课题组的管焰秋提出了一种采样和重建集成的残差编解码网络 SRIED_Net 用于光子计数单像素成像, 网络由采样子网络、初步重建网络和深度重建网络组成, 采样子网络为网络的第一层, 是一个二值化全连接层, 并将其训练成二进制的测量矩阵直接加载到数字微镜阵列上以实现高效压缩采样, 除第一层外的其余网络用于快速重建, 获得了更好的重建性能^[24]。

虽然采样和重建集成网络获得了更好的效果, 但在进行高分辨图像成像时, 由于高维度下的全连接层测量矩阵参数量成指数性增长, 巨大的参数量会使得训练时的迭代极为困难且容易使模型过拟合。基于分块压缩感知理论, 可以将一张高分辨率图像切割成若干张维度较小的子图, 再分别独立采样重建, 最后拼合恢复成原始大图, 从而大大缩短了重建时间和节约了重建成本。事实上, 大多数对图像的压缩感知算法都是这样做的, 如 ReconNet^[18]、DR2_net^[19] 等算法。但是, 基于分块压缩感知理论的分块处理方法在处理图像时也存在一些问题。由于对高分辨率图像切割时破坏了原始图片的连续线性, 同时各子块独立重建时存在不同程度的失真。因此在最后拼合的重建图片上, 子图与子图之间会存在明显的分界线, 即产生块状化效应, 并且块状化效应在越低的测量率下越明显。块状化效应不会体现在一些经典的图像质量评估的指标上, 如 PSNR 和 SSIM, 但却十分影响观感体验。一些去噪算法 (如 BM3D) 可以适当地减少块状化效应产生的影响, 对子图边缘的高频分量进行衰减, 但同时可能去除一些重要的信息和引入一些冗余的信息。

针对该问题,文中提出了三种去块状化的采样子网络:一是针对重构图像在块与块交界位置处产生像素的不规则跳变提出了重叠分块采样网络(Overlapping sampling network, Os_net);二是受子像素卷积启发提出了嵌套采样网络(Nested sampling network, Ns_net);三是利用卷积的权值共享特性提出了卷积采样网络(Convolutional sampling network, Cs_net)。设计实验对三种采样网络进行了比较,并在光子计数单像素成像系统上进行了验证。

1 光子计数单像素成像系统

搭建的光子计数单像素成像系统示意图如图 1 所示。LED(CREE Q5)发出的散射光经过平行光管后变成平行光。平行光透过衰减片(LOPF-25 C-405)和光阑(APID25-1)后,成为单光子水平的极微弱的平行光束。物体被微弱平行光照射后,经成像透镜汇聚于数字微镜器件(Digital Micromirror Device, DMD)上。DMD(T1:0.7 XGA12°DDR DMD)是一种电寻址空间光调制器件,其镜面由1 024×768个可单独控制偏转的微镜组成,每个微镜的大小均为13.78 μm×13.78 μm。为了实现“开”和“关”的空间光调制,微镜分别对应控制翻转+12°和-12°。微镜翻转+12°时经过调制的空间光信号反射至聚焦透镜(OLBQ25.4-050)。汇聚了多

个像素的光强透过光电倍增管(Photomultiplier Tube, PMT)输出一个个离散脉冲至接收器。工作在光子计数模式下单光子点探测器PMT(H10682-110)可以实现调制光强的量化,光子脉冲的计数代表光强。微镜翻转-12°时将照射在其上的光反射至系统光路外。笔者设计了现场可编程门阵列(Field Programmable Gate Array, FPGA)的同步控制电路,可将二值矩阵加载至DMD,并同步记录光电倍增管PMT输出的离散脉冲个数。通过USB将FPGA记录的光子计数值发送到计算机重建目标图像。

2 去块状化重建网络

2.1 分块重叠采样网络(Os_net)

DR2_net是把整副高分辨率大图分块成同尺寸的无重叠的子图像,对每个同等规模的子图像使用一致尺寸的观测矩阵进行采样和重构^[19],造成了对含有更多信息量图片的欠采样和信息量少图片的过采样,使重构图像在块与块交界位置处产生像素的不规则跳变。针对该算法的缺陷,笔者提出了Os_net进行重叠分块采样。在Os_net中要对于输入的第*i*个原始图片 $X_i \in R^{N \times N}$ 进行重叠分割。

如图 2 所示,需要按照步长*S*来对原始图片进行移动切割成多个*n*×*n*大小的图像块,为了确保原始图片信息全部保留,在切割之前需调整图片的尺寸,调整方式见公式(1)和公式(2)。然后对调整完成的图像进行重叠切割,记子图像的个数为*R*,见公式(3)。

$$pad_h = S - [(N - n) \% S] \quad (1)$$

$$H = N + pad_h \quad (2)$$

$$R = \left(\frac{H - n}{S} + 1 \right)^2 \quad (3)$$

式中:*N*为原始图片大小;*pad_h*为原始图片需填充的长度;*S*表示切割移动的步长, $\frac{n}{2} \leq S < n$; *H*为调整后图像块的大小。

将处理好的分割后的图像块作为重叠采样网络(Os-net)的输入,并将其拉伸成维度为1×*m*的列向量。拉伸后的图像 $x_i \in R^{1 \times m}$ 经过第一层全连接层进行采样,得到采样值 $y_i^r \in R^{1 \times r}$:

$$y_i^r = x_i W_1 \quad (4)$$

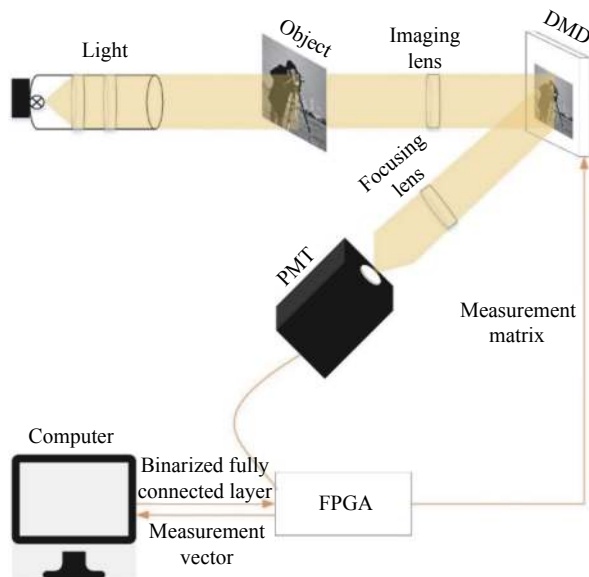


图 1 光子计数单像素成像系统原理图

Fig.1 Schematic diagram of photon counting single pixel imaging system




图 2 重叠切割过程

Fig.2 Process of overlapping cutting

式中: $W_1 \in R^{m \times r}$ 为权值矩阵; y_i^r 即为采样值; r 为采样次数。

网络中的第二层全连接层为图像重建网络, 采样值经第二层全连接层可得到重构图像 $x_i^r \in R^{1 \times m}$:

$$x_i^r = y_i^r W_2 \quad (5)$$

式中: $y_i^r \sim x_i^r$ 的映射为线性映射; $W_2 \in R^{r \times m}$ 为权值矩阵, 此处令 $m = 1024$ 。

该网络通过两个全连接层分别构成了编码 (encode) 和解码 (decode) 两个部分, 编码部分完成图像的重叠采样, 解码部分完成图像的重建。为了获得最终输出高分辨率图像, 先将子图像按切割顺序依次拼接, 其次对拼接后的图像行和列重叠的部分求取平均值。Os_net 在重叠区域进行重复采样, 增加了采样次数, 故对于整副大图而言, 其整体采样率与输入网络中的小块图像采样率不同, 二者之间的数量关系如下:

$$mr = \frac{r}{n^2} \quad (6)$$

$$MR = \frac{R \times r}{N^2} \quad (7)$$

联立公式 (1)、(2)、(3)、(6) 可得:

$$MR = \frac{\{N - n + 2S - [(N - n) \% S]\}^2 \times n^2 \times mr}{S^2 \times N^2} \quad (8)$$

式中: mr 为子图像的采样率; MR 为整张图片的采样率。

2.2 嵌套采样网络 (Ns_net)

2016 年, Shi Wenzhe 提出了子像素卷积, 实现了

从低分辨率到高分辨率的映射过程^[25], 与需要填补 0 来扩展信息的反卷积相比, 子像素卷积充分利用了图像的先验信息。受子像素卷积启发, 笔者提出了 Ns_net 网络。该网络是先通过嵌套切割, 从高分辨率的原始图片中提取四个均含有部分原始图片信息的子图像, 即将大小为 $N \times N$ 的原始图片等分为 $\frac{N^2}{4}$ 个 2×2 的像素块, 然后依次提取每个像素块的左上角、右上角、左下角、右下角的像素点排列组合成 4 个 $\frac{N}{2} \times \frac{N}{2}$ 的图像块, 如图 3 所示。这里令 $N = 64$, 经过嵌套切割后得到 4 个 32×32 的子图像。将这些子图像拉伸成 $1 \times m$ 大小的图像 $x_i \in R^{1 \times m}$ 输入全连接层, 完成压缩采样得到采样值 $y_i^r \in R^{1 \times r}$, 随后再将采样值输入全连接层进行图像重构, 并输出重建图像块 $x_i^r \in R^{1 \times m}$ 。将 x_i^r 尺寸复原为 32×32 后, 按照分割顺序将 4 张输出图像的像素点挨个放回原始高分辨率图片的位置得到最终图片。




图 3 嵌套切割过程

Fig.3 Process of nested cutting

2.3 卷积采样网络 (Cs_net)

2018 年, Thuong Nguyen Canh 等提出了 MS-DCSNet, 采用卷积层完成 Down-sampling 的过程, 该网络使用了基于多尺度的小波变换转换图像信号, 对四个频带的小波系数进行卷积采样^[26]。卷积采样使卷积核在不同的位置之间共享权重, 实现了平移不变性, 并且能减少网络中的参数, 完全可以替换全连接层采样。图 4 为笔者提出能运用在单像素压缩成像系统中的卷积采样网络示意图。Cs_net 包含两个子

网络: 卷积下采样子网络和卷积上采样子网络。在卷积下采样子网络中, 先用卷积核对输入的第 i 个图像 $x_i \in R^{n \times n}$ 进行卷积采样, 公式如下:

$$y_i = X_i * W_\alpha \quad (9)$$

式中: W_α 为 m 个 $32 \times 32 \times 1$ 的卷积核; y_i 为第 i 个原始图像经压缩采样后得到的采样值, 维度为 $2 \times 2 \times m$ 。其中, m 的值与 MR 存在密不可分的联系, 数量关系如下:

$$MR = \frac{4 \times m}{64 \times 64} \times 100\% \quad (10)$$

上述网络大大减少了权重的数量, 降低了计算的复杂度。在采样率为 0.2 时, Cs_net 的权重数量为 $32^2 \times 205 = 209\,920$, 而全连接采样的权重数量为 $64^2 \times 820 = 3\,358\,720$, 笔者提出的网络减少了超过 90% 的权重。

在卷积上采样子网络中, 将采样值 y_i 输入网络进行图像重建, 公式如下:

$$Z_i = y_i * W_\beta \quad (11)$$

式中: W_β 为 1024 个 $2 \times 2 \times m$ 的卷积核; Z_i 为重建后的图像, 维度为 $1 \times 1 \times 4\,096$ 。为了恢复至原始信号的维度, 将 Z_i 维度转换成 64×64 。




图 4 用 Cs_net 采样和初步重建的过程

Fig.4 Process of sampling and initial reconstruction with Cs_net

3 网络训练

使用与 $DR2_net$ ^[19] 一致的 91 张自然图片来生成 Os_net 、 Ns_net 和 Cs_net 的训练集。在训练 Cs_net 时使用步幅 14 对这些图片进行切割, 得到 7851 张大小为 64×64 的图像块作为训练集。在训练 Os_net 和 Ns_net 时, 为了保证实验的公平性, 需要保持训练集的数量一致, 因此从上述每一张 64×64 的图像中均匀地抽取一张 32×32 的图像块, 最终得到 7 851 张小图

作为训练集。保留提取的图像块的亮度分量作为网络的输入 x_i 。最大迭代周期、Batch size 和学习率分别设置为 1000、128 和 0.0001, 采用 Adam 优化器进行迭代优化。损失函数采用均方差, 公式如下:

$$Loss = \frac{1}{N} \sum_{i=1}^N \|x'_i - x_i\|^2 \quad (12)$$

为了使经过训练的矩阵加载在 DMD 上, 需要对神经网络 Os_net 、 Ns_net 和 Cs_net 的第一层的浮点型权重进行二值化。文中使用的二值化方法是基于符号函数 $Sign$ 的确定性方法:

$$W^b = Sign(W_1) = \begin{cases} +1 & W_1 \geq 0 \\ -1 & otherwise \end{cases} \quad (13)$$

式中: W_1 表示浮点型权重; W^b 表示经过二值化的权重。

然而符号函数的导数在非零时为 0, 在跳跃间断点零时不可导, 显然不可进行反向传播运算, 故在反向传播时用 $Htanh$ 函数替代符号函数来进行导数修正, 具体如下:

$$Htanh(x) = Clip(x, -1, 1) = \max[-1, \min(1, x)] \quad (14)$$

4 实验结果与讨论

4.1 不同采样算法的成像质量评估

此节设计了对照实验来评估上述提出的三种采样网络、双全连接层网络 (Fc_net) 和目前最先进的压缩感知图像重建算法 $TVAL3$ 的去块状化效果。为了确保对比实验的公平性, 在 $TVAL3$ 算法重建时用经过训练的浮点全连接层代替高斯矩阵。根据公式 (8) 所示, Os_net 的采样率计算方法与其他神经网络算法采样率不一样, 其采样率随着步长 S 的增大而有所提升, 当步长为 31 时其采样率与其他神经网络算法逼近, 为了确保公平, 选取步长为 31。从数据集 Set 0 中提取了五张 256×256 的图片用于测试, 以评估网络的性能。由于峰值信噪比 (PSNR) 与均方误差 (MSE) 只是基于对应像素点的误差评价, 无法表现“虚假边界”, 实验结果分析过程中需同时结合视觉来衡量去块状化效果, 在此从图像“Cameraman”中选择一个 64×64 的小块图像来评估不同算法去块状化的效果。

由表 1 可知: Os_net 的客观评价结果相比传统迭代算法 $TVAL3$ 有 1.03 ~ 2.36 dB 的提升, 与基于深度学习的 Fc_net 、 Ns_net 和 Cs_net 相比在重建质量上分别有 0.072 ~ 0.11 dB、1.939 ~ 3.846 dB 和 0.073 ~

0.466 dB的提升。这是因为即使 Os_net 步长设置为 31 以逼近其他重建算法的采样率,其采样率仍会大于其他算法,实际采样率对应为 0.019、0.05、0.13 和 0.25,这种采样率上的差异导致了 Os_net 在重建质量上的提升。在采样率低至 0.015 时, Ns_net 相比 TVAL3 能产生更高质量的重建图片,但在其他采样率下 Ns_net 的重建效果逊于 TVAL3 的重建效果。与

此同时,在所有采样率下 Ns_net 的重建结果均弱于其他神经网络算法的重建结果,这是因为 Ns_net 打乱了输入图片的空间规律,打断了数据集的信息连续性,数据集的调整降低了模型训练的质量。Cs_net 与 Fc_net 在低采样率时 PSNR 基本相同,在高采样率时有 0.2 ~ 0.4 dB 的差距,这可能是因为 Fc_net 网络输入子图像尺寸更小,能对每小块图像进行更精确的重建。

表 1 不同算法在不同采样率下的重建结果对比 (PSNR/dB)

Tab.1 Reconstruction results of different algorithms at different sampling rates (PSNR/dB)

Images	Methods	MR=0.015	MR=0.04	MR=0.1	MR=0.2
Bird	Tval3	13.177	13.236	14.745	13.622
	Fc_net	15.269	15.612	15.784	15.858
	Os_net	15.311	15.629	15.784	15.859
	Ns_net	14.624	15.097	15.402	15.565
	Cs_net	15.274	15.599	15.780	15.841
Cameraman	Tval3	17.437	21.698	24.492	25.927
	Fc_net	20.468	22.222	24.330	26.544
	Os_net	20.686	22.386	24.471	26.650
	Ns_net	18.363	19.781	21.114	21.899
	Cs_net	20.486	22.243	24.184	26.102
Head	Tval3	17.675	17.556	17.591	17.610
	Fc_net	20.010	20.229	20.495	20.607
	Os_net	20.010	20.239	20.491	20.606
	Ns_net	19.525	19.878	20.120	20.240
	Cs_net	20.037	20.267	20.398	20.562
Monarch	Tval3	18.228	21.353	25.283	23.860
	Fc_net	18.989	22.070	25.264	28.052
	Os_net	19.186	22.282	25.414	28.24
	Ns_net	15.996	17.907	19.867	21.162
	Cs_net	19.048	22.010	24.907	27.218
Peppers	Tval3	18.085	20.855	25.278	30.891
	Fc_net	21.115	23.599	26.334	28.890
	Os_net	21.207	23.672	26.404	28.965
	Ns_net	18.197	20.066	21.412	22.224
	Cs_net	21.189	23.56	25.955	28.269
Mean	Tval3	16.920	18.940	21.478	22.382
	Fc_net	19.170	20.746	22.441	23.990
	Os_net	19.280	20.842	22.513	24.064
	Ns_net	17.341	18.546	19.583	20.218
	Cs_net	19.207	20.736	22.245	23.598

图 5 为五种重建算法重建图,从视觉效果评测五种算法的去块状化能力。从图中可以直观地出, Cs_net 的重建图像完全没有“虚假边界”,在极低采样率下图片轮廓也清晰可见。而 TVAL3 作为先进的

CS 迭代算法,在低采样率下存在明显的十字形块状化,随着采样率的提升,在图像重建质量升高的同时,十字形块状化也逐渐变弱,但依旧无法消除。在采样率为 0.015 和 0.04 时, Fc_net 重建图像块与块之间存




图 5 使用不同重建方法的重建结果, 图片大小为 64×64 pixel

Fig.5 Reconstruction results using different methods, the size of pictures is 64×64 pixel

在很明显的像素跳变,这是由于 Fc_net 使用相同的观测矩阵固定观测,会在图片光滑处过采样,纹理区欠采样。Os_net 在重复采样区域存在块状化,随着采样率的提高,块状化程度比 Fc_net 更轻,Os_net 的重建质量之所以优于 Fc_net,是因为 Os_net 独特的采样方式带来了其在采样率计算上的优势,使得其重建质量更优,但其小图之间依旧存在十分明显的“虚假边界”。Ns_net 对输入图片的像素进行重排,小图之间的棋盘效应消失,但却在每个像素之间出现了像素跳变现象。故此得出 Cs_net 相较于其他四种重建算法

具有更好的去块状化效果。Cs_net 在重建质量上明显优于 TVAL3 与 Ns_net,与 Fc_net 的重建质量基本相同,但 Cs_net 具有十分显著的去块状化效果。

4.2 算法二值化后的成像质量评估

上述结果证明,五种算法中 Cs_net 对去块状化有明显优势,设计了对照实验组以验证 Cs_net 在实际系统实验中的表现。由于实际实验中 DMD 只能加载二值采样矩阵,则将 Cs_net 第一层卷积层进行二值化。为了实验公平,同时将 TVAL3 中随机高斯矩阵替换为训练过的二值矩阵,确保与 Cs_net 的采样矩阵相同。

表 2 为 TVAL3 和 Cs_net 的仿真结果。与表 1 中的结果对比可以看出, Cs_net 二值化后的重构效果明显逊于未二值化的重构效果。这是因为-1 和 1 的二值化矩阵与浮点矩阵相比, 其对特征的表达能力和拟合能力更弱, 所以二值化后的矩阵在采样时降低了网络整体的学习能力。从表 2 中可以得出: Cs_net 在所有的采样率下均优于 TVAL3 算法; 且在极低采样率

下, Cs_net 的优势更加明显, 二者之间的差值高达 2.07 dB。同时, Cs_net 相比于 TVAL3 能更稳定地重建出图像, 随着采样率从 0.2 降低至 0.015, Cs_net 重建出来的图像平均 PSNR 差别仅为 2.102 dB, 而 TVAL3 平均 PSNR 降低了 3.805 dB, 这是因为通过训练所得的 Cs_net 相比于传统的 TVAL3 算法具有更好的鲁棒性, 在低采样率下也能稳定地重建图像。

表 2 不同采样率下 TVAL3 与 Cs_net 的重建结果对比 (PSNR/dB)

Tab.2 Reconstruction result of TVAL3 and Cs_net at different sampling rates (PSNR/dB)

Images	Methods	MR=0.015	MR=0.04	MR=0.1	MR=0.2
Bird	TVAL3	13.173	13.515	13.561	13.644
	Cs_net	15.239	15.466	15.648	15.668
Cameraman	TVAL3	17.062	21.876	24.072	21.924
	Cs_net	20.111	21.113	22.447	22.575
Head	TVAL3	17.745	17.716	18.064	19.414
	Cs_net	19.764	19.89	20.189	20.247
Monarch	TVAL3	16.638	21.395	22.844	20.957
	Cs_net	18.753	20.539	22.799	23.174
Peppers	TVAL3	19.695	19.908	21.930	27.399
	Cs_net	20.802	21.958	23.735	23.514
Mean	TVAL3	16.863	18.882	20.094	20.668
	Cs_net	18.934	19.793	20.964	21.036

4.3 光子计数成像系统实验

用光子计数成像系统来评估 Cs_net 的消除块状化的能力。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掩模板作为成像目标, 该掩模板为“组合图案”, 如图 6 所示。在实际实验中采用微镜组合方案^[3], 设置整个 DMD 镜的成像分辨

率为 64×64 pixel, 将整个 DMD 镜面分成 2×2 部分, 对分辨板实现卷积采样。在实验中将 DMD 的翻转频率设置为两次/s, 在对比实验中所设置的采样率分别为 0.015、0.04、0.1 和 0.2, 对应不同采样率下的采样时间为 32 s、82 s、206 s 和 420 s。选择 TVAL3 进行对照实验。由于难以获得 DMD 上的原始图像, 故选




图 6 传统算法与所提出的方法在光子计数成像系统中的结果对比

Fig.6 Comparison of the results of the traditional algorithm and the proposed method in the photon counting imaging system

择无参考评测指标对其性能进行评测。

由图 6 可知, 在所有采样率时, 使用 TVAL3 重构都存在十字形块状化, 而 Cs_net 即使在低采样率下也不存在“虚假边界”且重建图像的边缘分辨率更高。从上述对照组实验中可以得出, Cs_net 相比于 TVAL3 具有十分显著的去块状化效果。

5 结 论

针对基于深度学习的压缩采样和重建网络利用全连接层进行高分辨图像的分块压缩感知时, 重建图像会产生块状效应的问题, 提出了 Os_net、Ns_net 和 Cs_net 等三种方法用以取代传统的全连接层采样。在重建网络的设计中, 使用线性映射网络对图像进行重建。第一步, 设计实验对比了 Fc_net、Os_net、Ns_net 和 Cs_net 四种采样网络, 实验结果表明, Cs_net 相较于其他三种采样网络具更好的去块状化效果。第二步, 将 Cs_net 进行二值化, 模拟实验表明, 在相同的实验条件下二值化的 Cs_net 重建质量比传统重建算法提升了 0.368 ~ 2.071 dB, 紧接着将其应用于光子计数单像素成像系统进行实际实验, 结果表明, Cs_net 除块状化明显优于 TVAL3, 且 Cs_net 在重建质量上也同样取得了较好的效果。

参考文献:

- [1] Takhar D, Laska J N, Wakin M B, et al. A new compressive imaging camera architecture using optical-domain compression [C]//Conference on Computational Imaging IV, 2006: 20060116-18.
- [2] Yu W K, Liu X F, Yao X R, et al. Single photon counting imaging system via compressive sensing[J]. *arXiv*, 2012: 1202.5866.
- [3] Wang H, Yan Q, Li B, et al. Sampling time adaptive single photon compressive imaging [J]. *IEEE Photonics Journal*, 2019, PP(99): 1-1.
- [4] Liu Y, Shi J, Zeng G. Single-photon-counting polarization ghost imaging[J]. *Appl Opt*, 2016, 55(36): 10347-10351.
- [5] 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): S293.
- [6] Yu Wenkai. Application of compressed sensing in ultra-sensitive time-resolved imaging spectroscopy[D]. Beijing: University of Chinese Academy of Sciences, 2015. (in Chinese)
- [7] Taguchi K, Iwanczyk J S. Vision 20/20: Single photon counting X - ray detectors in medical imaging[J]. *Medical Physics*, 2013, 40(10): 4820371.
- [8] Shigetomo S, Hiromi S, Yoshiyuki T, et al. Astronomical observation with a Nb-Al-AIOX-Al-Nb STJ single photon detector for optical wavelengths [J]. *Publications of the Astronomical Society of Japan*, 2004, 56(4): L19-L23.
- [9] Liu X, Yu W, Yao X. Measurement dimensions compressed spectral imaging with a single point detector [J]. *Optics Communications*, 2016, 365: 173-179.
- [10] Davenport M, Baraniuk R, Devore R, et al. The Johnson-Lindenstrauss lemma meets compressed sensing [DB/OL]. [2021-11-12]. <http://mdav.ece.gatech.edu/talk/princeton-2006.pdf>.
- [11] Baraniuk R, Davenport M, Devore R, et al. A simple proof of the restricted isometry property for random matrices [J]. *Constructive Approximation*, 2008, 28(3): 253-263.
- [12] Bajwa W U, Haupt J D, Raz G M, et al. Toeplitz-structured compressed sensing matrices [C]//2007 IEEE/SP 14th Workshop on Statistical Signal Processing, 2007: 294-298.
- [13] Candes E, Tao T. Near optimal signal recovery from random projections: Universal encoding strategies [J]. *IEEE Transactions on Information Theory*, 2004, 52(12): 5406-5425.
- [14] Tropp J A, Gilbert A C. Signal recovery from random measurements via orthogonal matching pursuit [J]. *IEEE Transactions on Information Theory*, 2007, 53(12): 4655-4666.
- [15] Needell D, Vershynin R. Signal recovery from inaccurate and incomplete measurements via regularized orthogonal matching pursuit[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2010, 4: 310-316.
- [16] Li C. An efficient algorithm for total variation regularization with applications to the single pixel camera and compressive sensing[D]. Houston: Rice University, 2010.
- [17] Mousavi A, Patel A B, Baraniuk R G. A deep learning approach to structured signal recovery [C]//IEEE, 2016.
- [18] Kulkarni K, Lohit S, Turaga P, et al. ReconNet: Non-iterative reconstruction of images from compressively sensed measurements [C]//Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2016.
- [19] Yao H, Dai F, Zhang D, et al. Dr2-net: Deep residual reconstruction network for image compressive sensing [J]. *Neurocomputing*, 2019, 359: 483-493.
- [20] Zhang Jian, Ghanem B. ISTA-Net: Interpretable optimization-inspired deep network for image compressive sensing [C]//Proceedings of the IEEE Conference on Computer Vision

- and Pattern Recognition. 2018: 1828-1837.
- [21] Higham C F, Murray-smith R, Padgett M J, et al. Deep learning for real-time single-pixel video [J]. *Sci Rep*, 2018, 8(1): 2369.
- [22] 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.
- [23] Li B, Yan Qiurong, Wang Y F, et al. A binary sampling Res2 net reconstruction network for single-pixel imaging [J]. *Review of Scientific Instruments*, 2020, 91(3): 033709.
- [24] Guan Yanqiu, Yan Qiurong, Yang Shengtao, et al. Single-photon compression imaging based on residual coding and decoding network[J]. *Acta Optica Sinica*, 2020, 40(1): 0111022. (in Chinese)
- [25] Shi W, Caballero J, Huszar F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 1874-1883.
- [26] Canh T N, Jeon B. Difference of convolution for deep compressive sensing[C]//2019 IEEE International Conference on Image Processing (ICIP), 2019.