

DOI:10.19651/j.cnki.emt.2209298

基于多通道采样和注意力重构的图像压缩感知^{*}

侯保军 田金鹏 杨洁 邓江峰 曾凤珍

(上海大学通信与信息工程学院 上海 200444)

摘要: 近年来用于图像压缩感知的深度学习网络得到广泛关注,深度学习网络可以实现图像的压缩采样,并从采样数据重构出原始图像。但现有的压缩感知算法在信息分布不均匀的图像场景中,无法有效提取原始图像信息,导致重构精度较低。针对上述问题,本文提出了基于多通道采样和注意力重构的图像压缩感知算法。该算法包含了多个不同采样率的采样通道,能够根据视觉显著性对图像不同区域应用不同的采样率,使得采样数据中能够包含更多原始图像信息。重构采用了残差通道注意力结构,自适应调整通道特征来提高网络的表示能力。通过对比实验表明,本文提出的基于多通道采样和注意力重构的图像压缩感知算法能够取得更好的重构质量与视觉观感。

关键词: 压缩感知;多通道采样;残差通道注意力;重构

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 520.60

Image compressive sensing based on multi-channel sampling and attention reconstruction

Hou Baojun Tian Jinpeng Yang Jie Deng Jiangfeng Zeng Fengzhen

(School of Communication and Information Engineering, Shanghai University, Shanghai 200444, China)

Abstract: Recently, deep learning networks for image compressive sensing have received a great deal of attention. Deep learning networks can achieve compressed sampling of images and reconstruct the original image from the sampled data. However, the existing compressive sensing algorithms cannot effectively extract original image information in image scenes with uneven information distribution, resulting in low reconstruction accuracy. To address the above problem, this paper proposes an image compressive sensing algorithm based on multi-channel sampling and attention reconstruction. The algorithm includes multiple sampling channels that can apply different sampling rates to different regions of the image according to visual saliency, so that the sampling data can contain more original image information. The reconstruction adopts the residual channel attention structure, which can adaptively adjust the channel features to improve the representation ability of the network. The comparative experiments show that the image compressive sensing algorithm based on multi-channel sampling and attention reconstruction proposed in this paper can achieve better reconstruction quality and visual perception.

Keywords: compressive sensing; multichannel sampling; residual channel attention; reconstitution

0 引言

图像采集系统一般基于 Nyquist 采样定律^[1],采样速率必须高于信号最高频率两倍才能完成对信号的重构。这种采样方式没有考虑图像的先验特征,使得采样数据中含有较多的冗余信息。而压缩感知(compressive sensing, CS)^[2-3]的提出打破了 Nyquist 采样定律的限制,能够同时对图像进行采样和压缩,实现了用更少的采样数据得到高精度的图像重构。由于 CS 一方面能够降低采样率,使得

采样总时间变短,另一方面也可以减少传递的信息量,从而降低了在通信的带宽限制。CS 理论引起了计算机视觉,编码论和无线传输等领域的大量关注,并广泛应用在单像素相机^[4]、遥感成像^[5]、核磁共振成像^[6]、图像/视频源编码^[7-8]等。

近年来,随着 GPU 的矩阵计算能力提高,深度学习在计算机视觉领域得到了迅速发展,展示了其强大的处理能力。深度学习以数据驱动方式学习图像的特征信息,并通过梯度下降自适应更新参数,能够更好的提高 CS 的重构

收稿日期:2022-03-16

*基金项目:国家自然科学基金(61871261)、上海市科委重点项目(19DZ1205802)资助

精度和速度。但是现有的基于深度学习的图像压缩感知网络,需要针对每个不同的采样率训练不同的网络,而且整张图像应用同一个采样率进行压缩采样时,在信息分布不均匀的图像场景中,采样数据不能有效地保存原始图像的有用信息,影响重构性能。

例如,Mousavi等^[9]受到深度学习技术在计算机视觉的优越性能的启发,首次采用了一种结构化信号恢复的深度学习方法用于CS重建,但是网络采用全连接网络,其计算复杂度比较高,而且也容易导致过拟合。Kulkarni等^[10]提出了一个用卷积重建的ReconNet算法,该算法是用随机高斯采样矩阵对图像块进行测量,并用卷积实现非迭代的图像压缩感知重构,但是重建的精度相对不高。DR2-Net^[11]在ReconNet算法基础上改进,通过线性映射和残差结构来进一步提高重建的质量,但依然是对图像分块处理,容易受到块效应的影响。ISTA-Net^[12]将迭代收缩阈值(ISTA)^[13]算法转化为深度网络模型,进一步提高了算法的准确性和重建速度。CSNet^[14]和TIP-CSNet^[15]使用了卷积层进行采样和重建,卷积层的参数能够自适应的学习数据中的特征信息,使得CS测量保留更多的图像结构信息。然而这几种方法都是以固定大小的采样矩阵对图像不同区域采样,无法对图像信息丰富的区域关注,使得图像重构的精度相对较低。

本文提出了一种基于多通道采样和注意力重构的图像压缩感知算法(MC-RCANet)。该算法包含多个不同采样率的采样通道,通过多通道采样能够充分采样原始图像的信息,并利用残差通道注意力网络对通道特征自适应调整,提高网络的重构精度。多通道采样是对原始图像进行分块并计算各部分的视觉显著性,根据视觉显著性对不同区域应用不同的采样率,这种方式得到的采样数据能够更有效地保存图像的有用信息。重构网络引入了通道注意力机制^[16-19],能够通过训练来有效增强网络中的有用特征并抑制无用的特征,加强不同层和通道之间的长期依赖关系,进而提高重构网络的学习以及表示性能。实验结果表明,MC-RCANet可以使图像的重构精度更高,网络计算量更低。

1 图像多通道采样基础

1.1 CS理论

CS理论假设 $x \in R^{N \times 1}$ 为原始图像的一维信号,如果信号 x 在变换域 $\Psi \in R^{N \times N}$ 中是稀疏的,即稀疏向量 α 中有 k 个非零系数($k \ll N$),可以利用CS理论对原始图像进行压缩采样。过程如式(1)所示。

$$y = \Phi x, \text{ s. t. } x = \Psi \alpha \quad (1)$$

其中,测量矩阵为 $\Phi \in R^{M \times N}$ ($M \ll N$), $y \in R^{M \times 1}$ 为测量值, α 为稀疏向量。从测量值 y 重建出原始图像 x 是一个非线性的恢复过程,过程可以由式(2)表示:

$$\min_{\alpha} \| \alpha \|_1, \text{ s. t. } y = \Phi \Psi \alpha \quad (2)$$

式(2)是一个典型的NP-Hard问题,常用 L_1 范数来代

替 L_0 范数转换为凸优化问题进行求解。

1.2 图像的视觉显著性算法

图像的感知质量很大程度上受到人类的视觉注意力影响,人类的视觉系统会更加关注图像的显著区域,忽视图像的其余部分。文献[16]将视觉显著性描述为视觉空间中的统计相关性,应用DCT变换可以捕捉图像像素间的二阶相关性的性质,通过归一化图像DCT变换的系数来设计图像的视觉显著性算法,算法如式(3)所示。

$$\begin{cases} P = \text{sign}(C(X)) \\ F = \text{abs}(C^{-1}(P)) \\ X_s = G * F^2 \end{cases} \quad (3)$$

其中, X 表示图像, C 和 C^{-1} 分别表示DCT变换和DCT反变换, $\text{sign}(\cdot)$ 表示符号函数, $\text{abs}(\cdot)$ 表示绝对值函数, G 表示高斯低通滤波器, X_s 表示图像 X 的视觉显著性特征图。 $\text{sign}(\cdot)$ 函数可以对DCT系数进行二值归一化处理,抑制高度相关的分量,从而实现了图像DCT域的显著性计算。应用该算法得到的图像的视觉显著性特征图,可以用于图像的采样率自适应分配中,将更多的采样资源分配给视觉显著区域。

1.3 图像多通道采样分配机制

图像在进行压缩采样时,一般需要对图像划分为不重叠的图像块进行分块处理,然后每个图像块进行压缩采样与重构。文献[20]提出应用显著性检测算法来估计图像的视觉显著特性,然后确定图像块的不同采样率。文献[21]表示利用视频相邻帧的相关性推算当前帧的视觉显著特性,从而更容易地实现采样率的分配。

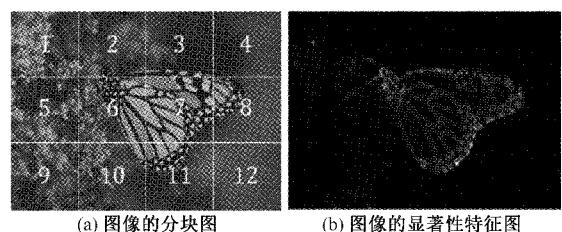


图1 分块图像和显著性特征

为实现对图像中不同的图像块应用不同的采样率进行采样,使得采样数据中包含更多原始图像的信息,本文将多通道采样来实现图像采样率自适应分配。如图1所示,对图像分块并计算其图像的显著性特征图,从而得到图像的信息分布区域和视觉显著性特征值的关系。图像多通道采样分配机制就是利用图像的视觉显著性信息,对图像的视觉显著区域分配较高的采样率,而对视觉不显著的区域分配较低的采样率。更重要的是,该多通道采样分配机制可以与不同的重构网络相结合,构成一种适应不同采样率的图像压缩感知重构网络,提高网络的灵活性。

2 MC-RCANet模型

MC-RCANet分为多通道采样重构子网络和深度重建

的残差通道注意力子网络。多通道采样重构子网络应用多个通道对图像中不同的图像块进行自适应压缩采样和重构初始图像,然后将重构的初始图像输入到残差通道注意力

子网络中进行深度重构。MC-RCANet 能够采样更有效的原始图像的信息,关注图像的高频细节特征,从而得到高精度的重构图像。如图 2 所示。

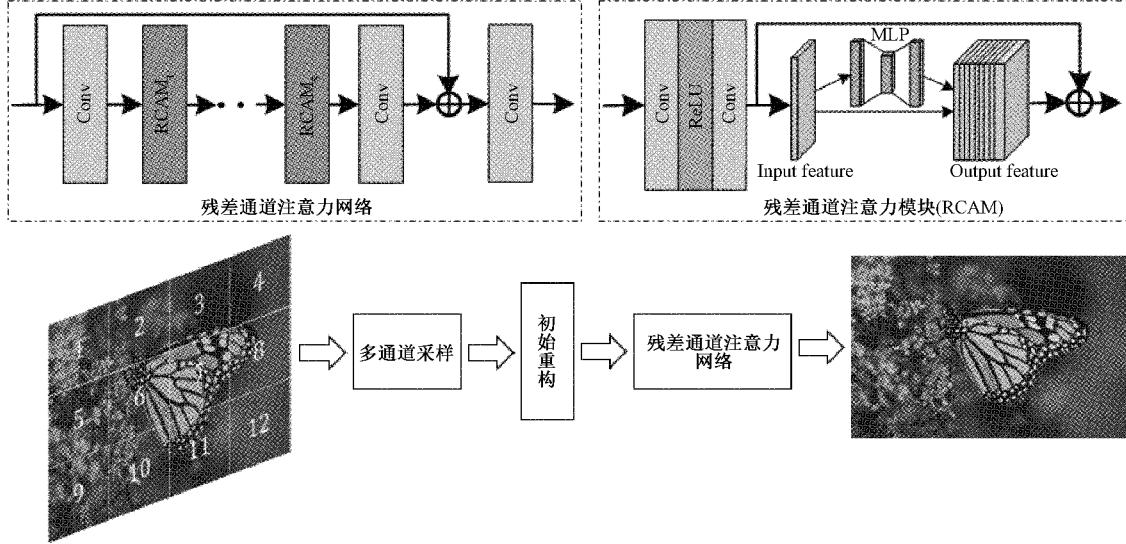


图 2 MC-RCANet 模型

2.1 多通道采样重构子网络

如图 3 所示,多通道采样重构子网络包含 k 个采样通

道,每个采样通道对应不同的采样率实现对图像的压缩采样和重构。

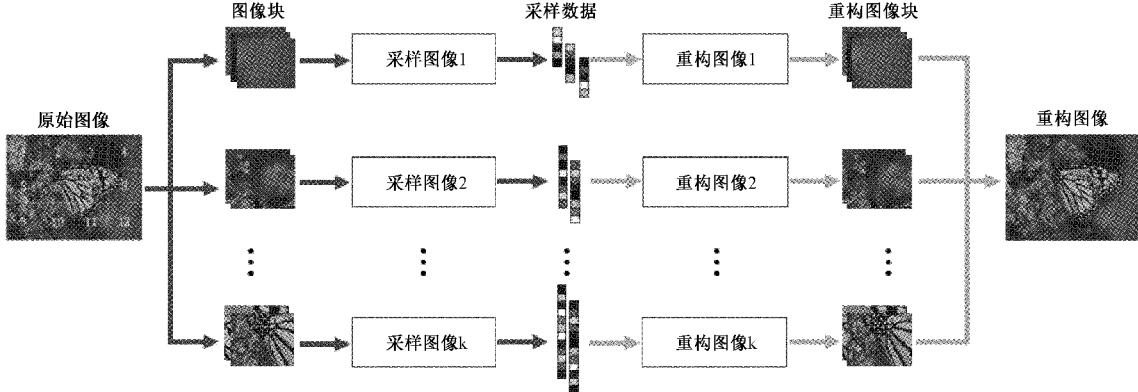


图 3 多通道采样重构网络

首先通过视觉显著性算法得到采样率的自适应分配,假设 ξ 表示整张图像 X 中所包含的显著性信息数量,可以表示为对应显著性特征图的平均值,如式(4)所示。

$$\xi = \frac{1}{N} \sum_{j \in X_s} l_j \quad (4)$$

其中, N 表示图像中像素的数量, l_j 表示显著性特征图 X_s 中位置 j 的数值。对整张图像 X 分割为不重叠的图像块,设第 i 个图像块 x_i 的显著性为 ξ_i , $p_i = \xi_i / \xi$ 表示图像块 x_i 的显著性占整张图像 X 显著性的比例。同时本文设置采样率的最大值和最小值,在固定的采样率区间内分配采样率,保证采样资源相对偏重于显著性区域而不会严重失衡。

当图像块由多通道采样得到采样数据后,使用相对应的重构通道得到初始重构图像。多通道采样重构子网络

能够在同样大小的采样数据中包含更多原始图像的信息,提高重构的精度。

2.2 残差通道注意力子网络

如图 2 所示,残差通道注意力子网络分为特征提取层、残差通道注意力模块和输出层。该子网络使用多个残差通道注意力模块对网络中的通道特征加权,凸显重要的通道特征,进而提高子网络的深度重构性能。

特征提取层: 使用一层卷积层来从初始重构图像中提取图像的特征信息。

残差通道注意力模块: 由两个卷积层和一个通道注意力层组合而成,并且残差通道注意力模块包含长连接和短连接结构。残差结构^[22]和长短连接结构能够很好的解决梯度爆炸或梯度消失的问题,保证输入的特征信息在传递

的过程不易损失,而通道注意力层能够有选择性的增强有用特征信息并抑制无用特征信息,使网络关注更多的高频细节,提升重构质量。

假设初始重构图像 $X_{IR} \in R^{H \times W}$ 经过特征提取层得到特征图 $F \in R^{H \times W \times C}$, 并使用池化 ($MaxPool$) 操作对各通道的特征进行处理, 形成对应的通道描述符。然后使用多层次感知器 (MLP) 来对通道描述符进行学习, 并使用含 sigmoid 函数的简单门控机制生成每个特征通道的权重, 具体过程如下。

$$CD = \sigma(MLP(MaxPool(F_i))) \quad (5)$$

其中, CD 为各通道特征的权重, $\sigma(\cdot)$ 为 sigmod 函数, F_i 为输入的特征图。将得到的 CD 对输入通道特征 F_i 加权, 得到输出的特征图 F_{out} 。

$$F_{out} = F_i \cdot CD \quad (6)$$

输出层: 使用一层卷积来对特征进行融合, 得到一张深度重构图像, 并与初始重构图像相加, 最终得到高精度的重构图像。

3 实验

3.1 训练细节

本文使用 BSD500 数据集^[23] 中的 200 幅训练集图像和 200 幅验证集图像共 400 幅图像作为训练集, 并使用数据增强技术对训练集进行增强, 包括水平翻转、旋转 90°, 旋转 270° 等。然后对这些图像进一步裁剪为 96×96 的子图像, 裁剪的步长为 57, 最终得到 89 600 张子图像对网络进行训练。每张子图像 X 会进一步划分为 9 张 32×32 的图像块 $\{x_i\}_{i=1}^9$, 使用视觉显著性估计算法对这些图像块进行自适应采样率分配。最终的训练数据为 89 600 组图像及其标签: $\{\mathbf{X}, \{p_i\}_{i=1}^9\}$, 其中 p_i 为图像块 x_i 对应的显著性信息占整张子图像 \mathbf{X} 的比例。

在多通道采样重构子网络结构中, 设置通道数量 $k = 7$, 每个通道对应的采样率分别为 0.01, 0.03, 0.05, 0.1, 0.2,

0.3, 0.4。在对网络进行训练时, 进一步对训练集中的每组数据 $\{\mathbf{X}, \{p_i\}_{i=1}^9\}$ 进行处理, 找到每个图像块所对应的采样通道。具体操作如下: 设置固定的采样率 $SR = 0.1$, 与每个图像块 x_i 的显著性比例 p_i 相乘, 得到图像块的采样率 $s_i = SR \times p_i$, 然后判断 s_i 落入哪个采样率区间, 则输入对应的采样通道进行采样。比如当 $0.1 \leq s_i < 0.2$ 时, 则输入 0.1 采样率对应的采样通道。由于训练集图像足够多, 所以每个采样通道都能得到较好的训练。在测试网络时, 对于设定的采样率, 同样按照上述方式进行处理, 为了防止采样率严重失衡, 设置采样率的上下限为相邻的采样率, 比如对于 $SR = 0.1$, 上下限分别为 0.2 和 0.05, 对于 $SR = 0.25$, 上下限分别为 0.3 和 0.2。

所有网络均在 Nvidia GTX 3090 GPU 上进行训练, 应用 L_1 范数作为损失函数, 初始学习率设置为 10^{-4} , 应用 ADAM 优化器对模型进行训练, 优化器的参数 $\beta_1 = 0.9$, $\beta_2 = 0.999$, $\epsilon = 10^{-8}$ 。应用典型网络 CSNet^[14] 与 TIP-CSNet^[15] 以及本文提出的残差通道注意力子网络结构进行对比实验。首先对网络应用原来的单通道采样结构在不同采样率下进行训练, 然后将提出的多通道网络结构分别与这几个网络的深度重构网络相结合, 记作 MC-CSNet、MC-TIP-CSNet 和 MC-RCANet 进行单次训练, 上述网络训练完毕后在不同采样率下测试图像的重构性能。对于 MC-CSNet 和 MC-TIP-CSNet, 网络参数与原论文保持一致, 分别训练 100 个周期, 每个周期迭代 1 400 次, 每个训练批次输入 64 张图像。学习率每 20 个周期减半。对于 MC-RCANet, 训练 50 个周期, 每个周期迭代 5 600 次, 每个训练批次输入 16 张图像。学习率每 10 个周期减半。

3.2 重构性能对比

表 1~3 分别在 0.04、0.10、0.25 三种采样率下, CSNet、MC-CSNet、TIP-CSNet、MC-TIP-CSNet、RCANet、MC-RCANet 共 6 个网络在 Set5^[24]、Set11^[10]、Set14^[25]、BSD100^[26] 四个数据集上重构的 PSNR 和 SSIM 对比。

表 1 0.04 采样率下各网络的重构性能对比

算法	数据集	Set5	Set11	Set14	BSD100	Avg
CSNet	PSNR	28.43	24.70	26.05	26.15	26.33
	SSIM	0.817 6	0.751 7	0.711 7	0.680 3	0.740 3
MC-CSNet	PSNR	28.44	24.59	26.02	26.14	26.30
	SSIM	0.809 4	0.742 9	0.706 2	0.675 7	0.733 6
TIP-CSNet	PSNR	28.74	24.83	26.16	26.26	26.50
	SSIM	0.829 2	0.760 7	0.717 9	0.686 3	0.748 5
MC-TIP-CSNet	PSNR	28.97	25.06	26.40	26.38	26.70
	SSIM	0.832 6	0.768 4	0.722 4	0.687 4	0.752 7
RCANet	PSNR	29.26	25.73	26.66	26.42	27.02
	SSIM	0.848 1	0.796 6	0.734 3	0.692 7	0.767 9
MC-RCANet	PSNR	29.77	25.70	26.91	26.72	27.28
	SSIM	0.857 7	0.795 6	0.741 3	0.702 8	0.774 4

表 2 0.10 采样率下各网络的重构性能对比

算法	数据集	Set5	Set11	Set14	BSD100	Avg
CSNet	PSNR	32.21	28.02	28.87	28.37	29.37
	SSIM	0.909 7	0.862 7	0.827 5	0.796 2	0.849 0
MC-CSNet	PSNR	32.44	28.16	29.31	28.85	29.69
	SSIM	0.900 1	0.855 0	0.818 1	0.792 3	0.841 4
TIP-CSNet	PSNR	32.28	28.06	28.91	28.39	29.41
	SSIM	0.909 7	0.682 9	0.828 1	0.797 5	0.804 6
MC-TIP-CSNet	PSNR	33.03	28.68	29.77	29.15	30.16
	SSIM	0.912 7	0.869 2	0.829 1	0.801 3	0.853 1
RCANet	PSNR	33.07	29.11	29.45	28.53	30.04
	SSIM	0.920 8	0.881 3	0.834 8	0.796 7	0.858 4
MC-RCANet	PSNR	34.02	29.68	30.42	29.59	30.93
	SSIM	0.925 3	0.886 2	0.842 0	0.813 3	0.866 7

表 3 0.25 采样率下各网络的重构性能对比

算法	数据集	Set5	Set11	Set14	BSD100	Avg
CSNet	PSNR	34.35	30.46	31.04	30.33	31.55
	SSIM	0.930 4	0.901 8	0.882 4	0.864 4	0.894 8
MC-CSNet	PSNR	36.40	32.52	32.86	31.89	33.42
	SSIM	0.955 9	0.96 5	0.915 7	0.899 1	0.933 9
TIP-CSNet	PSNR	36.24	32.30	32.34	30.98	32.97
	SSIM	0.953 2	0.929 5	0.902 1	0.877 1	0.915 5
MC-TIP-CSNet	PSNR	36.99	33.03	33.21	32.13	33.84
	SSIM	0.959 6	0.940 7	0.918 9	0.902 6	0.930 5
RCANet	PSNR	36.50	32.43	32.76	31.68	33.31
	SSIM	0.957 2	0.934 5	0.917 7	0.901 0	0.927 6
MC-RCANet	PSNR	37.50	33.90	33.63	32.53	34.39
	SSIM	0.962 7	0.947 2	0.923 1	0.908 1	0.935 3

从上述 3 个表中可以看出,对于相同的深度重构网络来说,应用多通道采样网络结构可以较好地提升图像的重构质量。特别是在较高的采样率下性能提升明显,比如在采样率为 0.25 时,MC-CSNet、MC-TIP-CSNet 和 MC-RCANet 与对应的单通道采样重构网络相比,在四个测试集上重构的平均 PSNR 分别提升 1.87 dB、0.87 dB、1.08 dB,SSIM 分别提升 0.039 1、0.015 0、0.007 7 dB。

本文提出在多通道采样情况下 MC-RCANet 能够在 0.04、0.10、0.25 三种采样率下的 Set5、Set11、Set14 和 BSD100 四个数据集上均取得了最高的重构性能,与 MC-TIP-CSNet 相比在 4 种采样率下,4 个数据集上的平均 PSNR 分别高 0.58 dB、0.77 dB、0.55 dB,SSIM 分别高 0.021 7、0.013 6、0.004 8。这是因为训练同一个网络实现对不同采样率下的图像重构具有较高的挑战性,RCANet 的网络结构更深,在训练时能够得到更好的收敛。

图 4~6 分别是在 0.04、0.10、0.25 三种采样率下,CSNet、MC-CSNet、TIP-CSNet、MC-TIP-CSNet、RCANet、

MC-RCANet 共 6 个网络在典型的测试图像 Monarch、Baby 和 Parrots 上的重构结果,并标示了每个重构图像的 PSNR 值和 SSIM 值。通过对比可以直观地观察多通道采样结构对图像重构性能提升的影响。

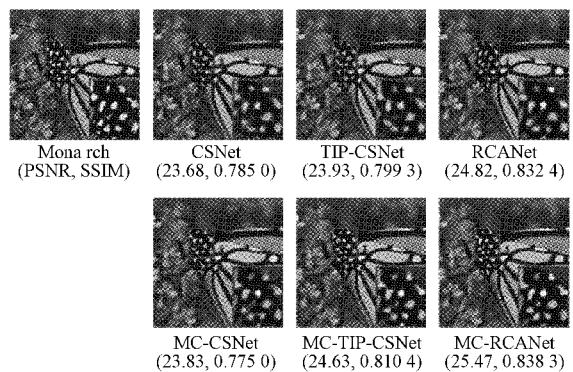


图 4 0.04 采样率下 Monarch 图像重构效果对比

观察图 4,在 0.04 采样率下,基于多通道采样的 MC-

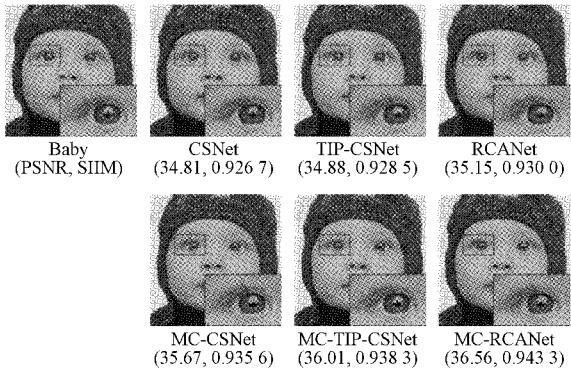


图 5 0.10 采样率下 Baby 图像重构效果对比

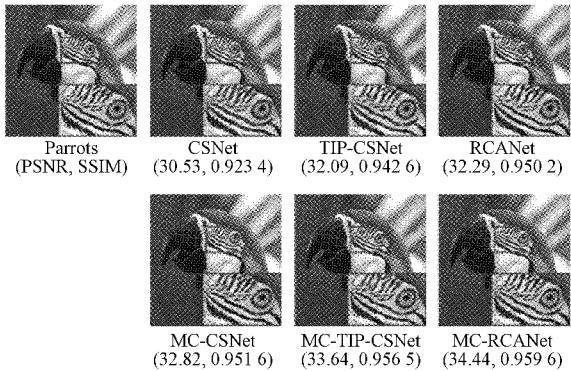


图 6 0.25 采样率下 Parrots 图像重构效果对比

CSNet、MC-TIP-CSNet 和 MC-RCANet 的重构图像与单通道采样的 CSNet、TIP-CSNet、RCANet 相比,蝴蝶头部的斑点区域更加清晰。从图 5 中观察在 0.1 采样率下,基于单通道的网络在图像的细节处如眼部区域比较模糊,而基于多通道采样的网络重构的图像能够恢复更多的细节信息,眼睛睫毛处相比更加清晰。从图 6 中观察 0.25 采样率下,基于多通道采样的网络与单通道采样网络相比,重构的图像中鹦鹉眼周的花纹更加清晰。通过直观对比可以发现,基于多通道采样结构的图像压缩感知重构网络能够恢复图像更多的细节信息,取得更好的视觉观感。

4 结 论

本文提出了一种新的基于多通道采样和注意力重构的图像压缩感知网络 MC-RCANet,该网络由多通道采样重构子网络和残差通道注意力子网络组成。多通道采样重构子网络能够将更多的采样资源分配给图像中的视觉显著区域,使得采样数据包含更多原始图像的信息。残差通道注意力子网络引入通道注意力机制,有选择性的增强有用的通道特征信息并抑制无用通道特征信息,提升了网络捕获关键信息的能力,从而更好的学习图像的高频细节特征,使得重构的图像纹理细节更加清晰。在未来研究中,我们将考虑将多通道采样以及注意力机制扩展到视频压缩感知等。

参考文献

- [1] KUAN H, ZIHAO W, XIANG H, et al. Computational multifocal microscopy[J]. Biomedical Optics Express, 2018, 9(12): 6177-6196, DOI: 10.1364/BOE.9.006477.
- [2] DONOHO D L. Compressed sensing [J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.
- [3] CANDÈS E J. Compressive sampling[J]. Proceedings of the International Congress of Mathematicians, 2006, 17(2): 1433-1452.
- [4] DUARTE M F, DAVENPORT M A, TAKHAR D, et al. Single-pixel imaging via compressive sampling[J]. IEEE Signal Processing Magazine, 2008, 25(2): 83-91.
- [5] WANG L, LU K, LIU P. Compressed sensing of a remote sensing image based on the priors of the reference image [J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(4): 736-740.
- [6] LIU Y, SHAN W, HUANG X, et al. Hybrid CS-DMRI: Periodic time-variant subsampling and omnidirectional total variation based reconstruction[J]. IEEE Transactions on Medical Imaging, 2017, 36(10): 2148-2159.
- [7] MUN S, FOWLER J E. DPCM for quantized block-based compressed sensing of images [C]. Signal Processing Conference, IEEE, 2012.
- [8] GAO X, JIAN Z, CHE W, et al. Block-based compressive sensing coding of natural images by local structural measurement matrix [C]. 2015 Data Compression Conference. Snowbird: IEEE, 2015: 133-142.
- [9] MOUSAVI A, PATEL A B, BARANIUK R G. A deep learning approach to structured signal recovery[C]. 2015 53rd Annual Allerton Conference on Communication, Control, and Computing IEEE, 2016.
- [10] KULKARNI K, LOHIT S, TURAGA P, et al. Reconnet: Non-iterative reconstruction of images from compressively sensed measurements[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 449-458.
- [11] YAO H, DAI F, ZHANG S, et al. DR2-Net: Deep residual reconstruction network for image compressive sensing [J]. Neurocomputing, 2019, 359 (24): 483-493.
- [12] ZHANG J, 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, 2017: 449-458.

- Recognition, Salt Lake City: IEEE Xplore, 2018: 1828-1837.
- [13] BECK A, TEBOULLE M. A fast iterative shrinkage-thresholding algorithm for linear inverse problems[J]. Siam J Imaging Sciences, 2009, 2(1):183-202.
- [14] SHI W, JIANG F, Zhang S, et al. Deep Networks for Compressed Image Sensing [C]. IEEE Computer Society. IEEE Computer Society, 2017: 877-882. DOI: 10.1109/ICME.2017.8019428.
- [15] SHI W, JIANG F, LIU S, et al. Image Compressed Sensing Using Convolutional Neural Network [J]. IEEE Transactions on Image Processing, 2020, 29: 375-388. DOI: 10.1109/TIP.2019.2928136.
- [16] JIE H, LI S, GANG S, et al. Squeeze-and-Excitation Networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 7132-7141. DOI: 10.1109/TPAMI.2019.2913372.
- [17] 张波, 兰艳亭, 鲜浩, 方炜. 基于通道注意力机制的人脸表情识别机器人交互研究[J]. 电子测量技术, 2021, 44(11):169-174.
- [18] 徐健, 陆珍, 刘秀平, 张立昌, 闫焕营. 注意力机制优化 RetinaNet 的密集工件检测方法研究[J]. 电子测量与仪器学报, 2022, 36(1):227-235.
- [19] 杨梅, 贾旭, 殷浩东, 孙福明. 基于联合注意力孪生网络目标跟踪算法[J]. 仪器仪表学报, 2021, 42(1): 127-136.
- [20] YING Y, WANG B, Zhang L. Saliency-Based Compressive Sampling for Image Signals[J]. IEEE Signal Processing Letters, 2010, 17(11): 973-976. DOI: 10.1109/LSP.2010.2080673.
- [21] BARANIUK R G, GOLDSTEIN T, SANKARANARAYANAN A C, et al. Compressive Video Sensing: Algorithms, architectures, and applications[J]. IEEE Signal Processing Magazine, 2017, 34(1):52-66. DOI: 10.1109/MSP.2016.2602099.
- [22] 王延年, 刘航宇, 刘宏涛, 刘妍妍. 基于小波深度残差网络的图像超分辨率重建[J]. 国外电子测量技术, 2021, 40(9):160-164.
- [23] ARBELAEZ P, MAIRE M, FOWLKES C, et al. Contour Detection and Hierarchical Image Segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(5): 898-916. DOI: 10.1109/TPAMI.2010.161.
- [24] BEVILACQUA M, ROUMY A, GUILLEMOT C, et al. Low-Complexity Single Image Super-Resolution Based on Nonnegative Neighbor Embedding[C]. British Machine Vision Conference. BMVA Press, 2012. <https://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=0F8B4C3FF17B3735A050115CC6CD8860?doi=10.1.1.297.1474&rep=rep1&type=pdf>.
- [25] ZEYDE R, ELAD M, PROTTER M. On Single Image Scale-Up Using Sparse-Representations [J]. International Conference on Curves and Surfaces, 2010: 711-730. https://link.springer.com/chapter/10.1007/978-3-642-27413-8_47.
- [26] 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]. IEEE International Conference on Computer Vision, IEEE, 2001, 2: 416-423. DOI: 10.1109/ICCV.2001.937655.

作者简介

侯保军,硕士生,主要研究方向为图像/视频压缩与恢复领域研究。

田金鹏,博士,副教授,主要研究方向为信号处理与模式识别领域研究。

E-mail: adaline@163.com

杨洁,硕士,主要研究方向为图像处理、压缩感知领域研究。

邓江峰,硕士生,主要研究方向为图像重建、优化和深度学习领域研究。

曾凤珍,硕士生,主要研究方向为图像处理领域研究。