

文章编号 1004-924X(2023)14-2135-12

联合全局与局部特征的深度压缩感知图像重构

仲元红^{1*}, 徐乾锋¹, 周宇杰¹, 王姗姗²

(1. 重庆大学 微电子与通信工程学院, 重庆 400044;

2. 安徽大学 物质科学与信息技术研究院, 安徽 合肥 230039)

摘要: 从极少量的测量值中有效且高概率高质量恢复出原始信号是压缩感知图像重建研究的核心问题, 学者们相继提出了传统和基于深度学习的压缩感知图像重建算法, 传统算法通常基于优化模型迭代求解, 重建质量和重建速度都无法保证; 基于深度学习的算法重建质量相对较高, 但缺乏物理可解释性。受滤波流的启发, 本文提出了联合全局与局部的深度压缩感知图像重建模型(G2LNet), 其以卷积层执行压缩采样以及初始重建过程, 利用快速傅里叶卷积与滤波流, 同时考虑了图像全局上下文信息和图像像素局部邻域信息, 联合学习优化测量矩阵与滤波流, 建立了完整的端到端可训练的深度学习压缩感知重建网络。经实验验证, 在压缩感知图像重建领域常用的 Set5, Set11, BSD68 测试集上取得了良好的重建效果, 在采样率为 20% 的情况下, G2LNet 的图像重建质量相比于经典的传统算法 MH 与基于深度学习的算法 CS-Net 的平均 PSNR 分别提高了 2.29 dB, 0.51 dB, 有效提升了重建图像质量。

关键词: 压缩感知; 图像重建; 快速傅里叶卷积; 滤波流; 深度神经网络

中图分类号: TP394.1; TH691.9 **文献标识码:** A **doi:** 10.37188/OPE.20233114.2135

Image reconstruction based on deep compressive sensing combined with global and local features

ZHONG Yuanhong^{1*}, XU Qianfeng¹, ZHOU Yujie¹, WANG Shanshan²

(1. School of Microelectronics and Communication Engineering, Chongqing University,
Chongqing 400044, China;

2. Institute of Physical Science and Information Technology, Anhui University, Hefei 230039, China)

* Corresponding author, Email: zhongyh@cqu.edu.cn

Abstract: Effectively restoring the original signal with high probability and high quality from a very small number of measured values is the core issue of compressive sensing for image reconstruction. Researchers have successively proposed traditional and deep learning-based compressive sensing image reconstruction algorithms. The traditional algorithms are based on mathematical derivation. Although they are comprehensible, their reconstruction quality is relatively poor. On the contrary, deep learning-based algorithms have relatively high reconstruction quality, but they cannot guarantee intelligibility. Inspired by filter flow, this study proposes a global-to-local compressive sensing image reconstruction model called G2LNet, which performs compressed sampling and initial reconstruction processes with convolutional layers using

收稿日期: 2022-12-06; 修订日期: 2023-01-05.

基金项目: 国家自然科学基金资助项目 (No. 61501069); 重庆市技术创新与应用发展面上项目资助 (No. cstc2019jscx-msxmX0167)

fast Fourier convolution and convolutional filter flow, taking into account the global contextual information of the image and local neighborhood information of the image pixel simultaneously. It learns to jointly optimize the measurement matrix and convolution filter flow and establishes a complete end-to-end trainable deep image reconstruction network. Verification experiments were performed on the Set5, Set11, and BSD68 test datasets commonly used in the field of compressive sensing image reconstruction at a 20% sampling rate. The image reconstruction quality of G2LNet was compared with that of the traditional algorithm MH and algorithm based on deep learning; the average peak signal-to-noise ratio of CSNet increased by 2.29 dB and 0.51 dB, respectively, effectively improving the quality of the reconstructed image.

Key words: compressive sensing; image reconstruction; fast Fourier convolution; filter flow; deep neural network

1 引言

在传统信号处理中,信号采样遵循奈奎斯特香农采样定理^[1],随着信号处理领域中信息量的不断增多,信号的带宽越来越宽。如果依据奈奎斯特采样定理要求:采样过程中采样频率不低于信号带宽两倍,会使得硬件系统面临很大的压力。在信号压缩编码过程中,为了降低存储、处理和传输的成本,大量的采样数据被丢弃,对资源造成极大浪费。针对以上情况,压缩感知(Compressive Sensing, CS)理论^[2-4]应运而生,其指出只要信号在某一域中是稀疏的,即可将采样与压缩过程有机结合,以线性的方式获取较少量的测量值,有效避免了信号的高速采样,然后再通过非线性的重建算法恢复原始信号。这种方式可以更加关注信号信息的结构与内容。目前压缩感知理论已广泛应用于图像、视频处理^[5]、雷达^[6-7]、核磁共振成像^[8]和遥感等领域,相关研究也得到高度关注。其中压缩感知图像重建的研究内容主要有信号稀疏表示、测量矩阵的设计和重建算法的设计三个挑战性问题,其中重建算法的研究是压缩感知图像重建中的重点,重建算法的好坏决定了最终恢复信号的质量。传统算法通常基于优化模型迭代求解,重建质量和重建速度都无法保证;基于深度学习的算法重建质量相对较高,但缺乏物理可解释性;基于深度展开的算法精度较高,但算法复杂度高。

在本文中,为改善基于深度学习的重建算法中存在的缺乏可理解性的问题,提出了一种新颖的利用滤波流的压缩感知图像重建框架,并结合快速傅里叶卷积,建立了一种联合全局与局部特征的深度压缩感知图像重构模型(G2LNet)。

G2LNet 包含一个采样网络和一个重建网络,两者联合优化学习。采样网络能够自适应地从训练图像中学习测量矩阵,这种方法在 CSNet^[9]中最先提出,使得 CS 测量值保留了更多的图像信号的结构信息与内容,其重建网络中由一个线性的初始重建网络和一个增强的重建网络级联而成。其中增强网络由基于快速傅里叶卷积的全局分支网络和基于滤波流的局部增强网络构成。

本文的主要贡献如下:

(1)提出一种联合全局与局部的深度压缩感知图像重构模型(G2LNet),兼顾了图像的全局信息与图像像素局部邻域信息,实现了图像的有效重建;

(2)G2LNet 联合优化学习测量矩阵与重建网络,相比于现有的基于深度学习的压缩感知图像重建算法具有更好的性能与可理解性;

(3)在大量的数据集上进行了实验,并与相关算法进行比较,取得了有竞争力的结果,证明了方法的有效性。

2 相关工作

目前压缩感知图像重建算法的研究主要分为三类,分别是传统算法^[10-17],基于深度学习的算法^[9,18-21]和基于深度展开的算法^[20-21,24]。Chen 等人^[22]提出的多假设预测算法(MH)利用距离加权的 Tikhonov 正则约束能够很好的恢复出图像纹理结构,这类传统算法中,大多从图像先验着手添加额外的优化信息,其计算复杂度较高,图像重建质量不理想。在基于深度学习的算法中,Kulkarni 等人^[23]提出的 ReconNet 利用线性映射

来模拟图像块的压缩采样过程,并利用全连接层和重塑操作获得初始重建图像块,再利用卷积神经网络获得进一步的重建图像块再拼成重建图像,最后采用BM3D去噪器提升图像质量,整个网络框架是端到端可学习的,但其重建图像存在严重的块效应。Shi等人^[9]提出的CSNet首次利用卷积层进行压缩采样与初始重建,其将块测量矩阵作为卷积核来学习,联合优化测量矩阵与重建图像,并利用图像块内信息与块间相关性消除了块效应,达到了很好的恢复效果。但是深度学习的方法是一个“黑匣子”,缺乏良好的可理解性。在基于深度展开的算法中,Zhang等人^[24]提出的ISTA-Net将传统的迭代收缩阈值算法在深度学习框架下展开,取得了较好的重建效果,但其迭代的思想使得算法的计算复杂度较高。

在基于深度学习的压缩感知图像重建算法中,卷积神经网络^[25]是深度学习的核心,而现代设计的卷积神经网络中大多采用的是具有小感受野的卷积层,例如ResNet^[26]中卷积层通常采用 3×3 大小的卷积核。这种局部操作在层数较少的情况下不能同时提取两个距离较远区域的特征,只能通过堆叠卷积层来线性或者指数级地增加感受野的大小,或通过使用空洞卷积来增加感受野。前者需要构建较大的网络参数,后者“空洞”的大小受限于图中不同物体的大小,难以进行适配多种情况。

快速傅里叶卷积^[27]是近期提出的一种新型

的卷积模块,其优势是具有全局的感受野,且在卷积单元内跨尺度特征融合。根据傅里叶理论中的频域卷积定理,改变频域中的一个点即可影响空间域里的全局特征。快速傅里叶卷积通过对频域的特征进行处理,使得对频域局部特征的操作能够覆盖整个图像,甚至可以在图像重建阶段的一些早期卷积层中使用的。它将输入图像的局部邻域中的像素进行线性组合,最终重建输出图像中对应位置的像素。与普通的卷积不同之处在于:滤波器的权重是随空间位置而变化的,本文对给定的输入图像估计回归滤波器的权重。虽然滤波流基于卷积神经网络,但却不同于其他基于深度学习的压缩感知重建算法:它可以展示出从输入图像到输出重建图像的显式表述,其如何变换直观透明且可以理解。

3 全局到局部的模型设计

本文基于信号本身的性质进行设计一种联合全局与局部特征的深度压缩感知图像重构模型(G2LNet)。该网络通过快速傅里叶卷积提取到图像全局特征信息,同时利用滤波流从图像像素的局部邻域获取信息。最后结合两者的特征信息并充分利用信号的稀疏性和信号自身的结构信息,达到有效提升压缩感知图像重建的效果。该网络整体结构如图1所示,下面将分别介绍网络的各个组成部分。




图1 全局到局部压缩感知图像重建模型结构

Fig. 1 Global-to-Local Compressive Sensing Image Reconstruction Model Structure

3.1 采样网络

将测量矩阵 A_s 的每一行设置为卷积核, 用一个无偏差的卷积层模拟块压缩采样过程。那么则有当采样率为 M/N 时, 每个大小为 $S \times S \times k$ 的卷积核, 因为图像块 I_i 大小也是 $S \times S \times k$, 那么测量矩阵中有 n_s 行, 其中 $n_s = MkS^2/N$, 即可以从一个图像块中测量出 n_s 个测量值。压缩采样过程可以表示为:

$$\mathbf{y} = S(I) = \mathbf{W}_s * I, \quad (1)$$

其中: $S(\cdot)$ 表示压缩采样操作, $\mathbf{y}$ 表示压缩感知测量值, $\mathbf{W}_s$ 为卷积核, 其大小为 $S \times S \times k$ 且共有 n_s 个, $*$ 表示卷积操作, I 为输入的原始图像。

3.2 初始重建网络

初始重建网络输入为采样网络的输出: 压缩采样后的测量值 $\mathbf{y}$ 。与采样网络类似, 首先采用一层卷积层提取测量信息, 并变换为图像信息: 我们首先将 A_s^T 设置为卷积层的卷积核, 其大小为 $1 \times 1 \times n_s$, 且共有 kS^2 个滤波器。因为测量值 $\mathbf{y}$ 大小也为 $1 \times 1 \times n_s$, 每个图像块中含有 kS^2 个元素, 输出为 $1 \times 1 \times kS^2$ 大小的张量, 此输出即为每个初始重建图像块的向量表示。然后, 通过像素洗牌^[29]操作将 $1 \times 1 \times kS^2$ 的张量输出重塑为 $S \times S \times k$, 共有 n_s 个图像块。这保证了初始重建的图像与原始图像大小保持一致。初始重建过程可以表示为:

$$\hat{I}_0 = R_0(\mathbf{y}) = \text{PixelShuffle}(\mathbf{W}_{\text{initial}} * \mathbf{y}), \quad (2)$$

其中: $\hat{I}_0$ 为初始重建图像, $R_0(\cdot)$ 表示初始重建操作, $\text{PixelShuffle}(\cdot)$ 表示像素洗牌操作, $\mathbf{W}_{\text{initial}}$ 为 kS^2 个 $1 \times 1 \times n_s$ 大小的卷积核。

3.3 增强深度重建网络

增强重建网络包含快速傅里叶卷积残差网络与滤波流网络。快速傅里叶卷积残差网络由 1 层快速傅里叶卷积、5 个快速傅里叶卷积残差模块以及一层 1×1 的卷积层构成。该网络在深度重建网络的浅层设置一层傅里叶卷积以提取全局上下文信息。此层傅里叶卷积的参数设置为 $\alpha_{\text{in}} = 0$, $\alpha_{\text{out}} = 0.5$, 卷积核大小为 $3 \times 3 \times 64$ 。通过 5 个快速傅里叶卷积残差模块扩展感受野到输入特征图的全部区域, 最后将特征图输入一层 1×1 的标准卷积生成图像信息。快速傅里叶卷积残差网络可以表示为:

$$\hat{I}_1 = R_F(\hat{I}_0) + \hat{I}_0, \quad (3)$$

其中: $\hat{I}_1$ 为快速傅里叶卷积残差网络的重建图像, 同时作为整体快速傅里叶滤波流与滤波流网络的退化图像, $R_F(\cdot)$ 为快速傅里叶卷积残差网络, $\hat{I}_0$ 为初始重建图像, 作为残差连接防止网络训练时出现梯度消散, 让整体网络框架学习到“恒等映射+扰动”。

学习到了更优的退化图像后, 就具备了学习像素级滤波器的条件。为让后续的学习过程不止注重局部的信息, 引入了全局上下文结构。受到快速傅里叶卷积网络的启发, 设计了具有全局和局部分支的滤波流网络。其中全局路径为基于 Resnet18 的深度卷积神经网络, 具有较大的感受野, 能够提取上下文信息估计像素滤波器; 局部路径为全分辨率但相对较浅的卷积网络, 通过保持图像的分辨率以减少空间信息的损失。最后合并两条路径的信息并通过 3 层卷积神经网络以及 Softmax 映射得到最终的滤波器。滤波流过程可以描述为:

$$\hat{I}_2 = R_c(\hat{I}_1), \quad (4)$$

$$\hat{I}_3 = \hat{I}_2 \cdot \hat{I}_1, \quad (5)$$

其中: $R_c(\cdot)$ 为滤波流网络; $\hat{I}_2$ 为滤波流, 是滤波流网络的输出; $\hat{I}_3$ 为最终的重建图像, 由 $\hat{I}_2$ 与 $\hat{I}_1$ 元素相乘后生成。

3.4 损失函数

采用平均绝对误差(MAE)作为代价函数。因为希望初始重建图像 $\hat{I}_0$ 以及最终重建图像 $\hat{I}_2$ 都尽可能的逼近原始图像 I , 所以在网络训练过程中对初始重建图像以及重建图像都施加约束。具体来说, 框架整体的损失函数的数学表达式为:

$$\text{loss}(w) = \frac{1}{2N} \sum_{i=1}^N \|I^i - \hat{I}_2^i\|_1 + \frac{1}{2N} \sum_{i=1}^N \|I^i - \hat{I}_0^i\|_1. \quad (6)$$

4 实验结论

4.1 实验参数设置

采用数据集 91image^[30] 作为训练集, 以 57 个像素为步长, 在每张训练图像上进行裁剪, 最终得到 36 184 张图像块作为训练集, 其中图像块大小为 64×64 。测试集包括 Set5^[31], Set11^[32],

BSD68^[33]等常用的标准数据集。在训练过程中采用 Adam 优化算法,训练次数为 200 批次(epochs),批处理大小为 32(batch size),学习率为 10^{-4} ,滤波流中每个像素级滤波器大小设置为 17,则 G2LNet 在每个图像的像素位置输出大小为 $17 \times 17 = 289$ 个权值。本章节所有实验均在 Ubuntu18.04.6 LTS 操作系统上完成,其中配置信息为: Intel Core i3-10100 CPU, 3.6 GHz CPU 处理器, NVIDIA GeForce GTX 1080 Ti 显卡,运行平台为 Pycharm。评价标准为主观的视觉效果展示以及客观的图像质量评价指标: 峰值信噪比 (PSNR) 和结构相似性 (SSIM)^[34]。

4.2 对比实验结果

为了验证提出的 G2LNet 模型的性能,与主流的压缩感知图像重建算法的进行对比,比较算法为: MH^[22] 算法, ReconNet^[23], CSNet^[9], ISTA-Net+^[24], 其中 MH 算法为传统重建算法, ReconNet, CSNet 为基于深度学习的重建算法, ISTA-Net+ 为基于深度展开的算法。MH 算法基于图像块的非局部自相似性,能有效利用原始图像的结构化信息; ReconNet 是首次将深度学习与压缩感知相结合的算法; CSNet 联合训练测量矩阵并利用块内和块间信息很好地解决了块效应问题;

ISTA-Net+ 将深度学习与传统的收缩迭代阈值算法结合,既含有传统算法的数学意义,又兼顾了深度学习对算法计算速度和效率的提升。这些方法源代码均从原作者上传的 Github 网站上下载运行,其中 MH 算法在 MATLAB2016b 上运行,其他算法均在 Pycharm 编译器 Pytorch 框架下运行,在参数的设置上与原论文保持一致。

首先在如图 2 所示的 8 张 set11^[32] 测试图像上,以 10%, 20%, 30% 的采样率对上述的五种算法进行测试,测试结果如表 1 所示,表现最优结果用粗体标出。从表中可以看出,在 Barbara 图像的测试数据中, MH 算法在三种采样率下表现最优, PSNR 值最高,其原因为 Barbara 图像中头巾上具有丰富的条纹纹理信息, MH 算法采用的非局部自相似性先验能更多地利用图像的自身结构化信息,因此效果较好。但 MH 算法在其他图片中的表现差于 CSNet, ISTA-Net+ 和 G2LNet,这体现了一些先验知识的局限性。综合来看,除 Barbara 图像以外的其他测试图像在 10%, 20%, 30% 三种采样率下, G2LNet 重建质量最优, ReconNet 在几种算法中重建质量最差, ISTA-Net+ 在采样率较高的情况下 (20% 采样率、30% 采样率) 重建质量较好, CSNet 在




图 2 8 张来自 Set11^[32] 测试图像

Fig. 2 8 test images from Set11^[32]

表 1 8 张图中不同算法的重建图像的 PSNR

Tab. 1 PSNR of reconstructed images of different algorithms in 8 pictures

(dB)

采样率	算法	Monarch	House	Barbara	Lena	Parrots	Peppers	Boats	C. man
10%	MH ^[22]	23.19	30.30	26.73	26.12	25.35	26.00	26.11	22.12
	ReconNet ^[23]	21.51	26.69	22.50	24.47	23.23	22.67	24.15	21.66
	CSNet ^[9]	26.73	31.68	24.24	28.57	27.40	26.66	28.80	24.92
	ISTA-Net ^{+[24]}	25.72	30.49	23.52	27.50	26.37	27.13	27.41	23.76
	G2LNet	28.07	32.00	25.23	28.86	28.88	27.61	28.95	25.46
20%	MH ^[22]	27.10	33.84	30.81	29.81	29.21	29.78	29.91	25.87
	ReconNet ^[23]	22.89	27.95	22.87	25.39	24.56	24.04	25.98	22.64
	CSNet ^[9]	29.57	33.42	24.98	30.75	29.77	28.42	30.97	26.79
	ISTA-Net ^{+[24]}	31.01	34.99	26.78	31.14	29.96	30.45	31.91	27.65
	G2LNet	31.61	35.16	27.27	31.71	31.12	31.38	32.44	28.30
30%	MH ^[22]	29.20	35.69	32.99	31.99	31.00	31.35	32.25	28.08
	ReconNet ^[23]	29.21	33.61	25.65	33.74	26.88	29.77	30.20	26.90
	CSNet ^[9]	32.58	36.47	28.38	33.35	32.87	30.75	33.21	28.64
	ISTA-Net ^{+[24]}	34.80	37.07	30.13	33.45	32.91	35.54	35.22	30.35
	G2LNet	35.27	37.56	30.87	34.26	33.58	35.81	35.87	31.28

采样率较低的情况下(10% 采样率)重建质量较好。

如表 1 和表 2 所示,在 Set11 和 BSD68 数据集下,G2LNet 的平均 PSNR 和平均 SSIM 表现最优,在 Set5 数据集下 CSNet 的平均 PSNR 和平均 SSIM 表现最优,这由于 CSNet 较好得利用了块内信息和对块效应的具有较好处理。从表 2 可以看出,在 Set11 数据集下,G2LNet 相比于 MH 算法、ReconNet,CSNet,ISTANet+ 的平均 PSNR

在 10% 采样率下分别提升 2.13, 5.50, 0.58, 1.46 dB,在 20% 采样率下分别提升 2.28, 6.67, 1.88, 0.41 dB,在 30% 采样率下分别提升 2.16, 7.97, 2.73, 0.01 dB。

在 BSD68 数据集下,G2LNet 相比于 MH 算法,ReconNet,CSNet,ISTANet+ 的平均 PSNR 在 10% 采样率下分别提升 2.69, 3.04, 0.54, 1.36 dB,在 20% 采样率下分别提升 2.61, 4.47, 0.08, 0.56 dB,在 30% 采样率下分别提升 2.50,

表 2 多个数据集下不同算法的重建图像的 PSNR 对比结果

Tab. 2 PSNR of reconstructed images of different algorithms in multiple datasets

(dB)

采样率	数据集	MH ^[22]	ReconNet ^[23]	CSNet ^[9]	ISTA-Net ^{+[24]}	G2LNet
10%	Set5	28.56	24.31	31.54	28.61	30.56
	Set11	25.82	22.45	27.37	26.49	27.95
	BSD68	23.97	23.62	26.12	25.30	26.66
	Avg.	26.12	23.46	28.34	26.80	28.39
	Set5	26.12	23.46	28.34	26.80	28.39
20%	Set11	28.93	24.44	29.33	30.80	31.21
	BSD68	26.98	25.12	29.51	29.03	29.59
	Avg.	27.34	24.34	29.06	28.88	29.73
	Set5	34.09	27.78	36.69	35.45	36.03
30%	Set11	31.55	25.74	30.98	33.70	33.71
	BSD68	28.79	26.27	31.01	30.35	31.29
	Avg.	31.48	26.60	32.89	33.17	33.68

5.02,0.28,0.94 dB。

从表 3 可以看出,在 Set11 数据集下,G2LNet 相比于 MH 算法,ReconNet,CSNet,ISTANet+ 的平均 SSIM 在 10% 采样率下分别提升 0.086 5,0.244 2,0.027 5,0.065 1,在 20% 采样率下分别提升 0.050 4,0.190 1,0.021 3,0.009 4,在 30% 采样率下分别提升 0.043 7,0.141 5,0.058 8,0.011 8。在 BSD68 数据集下,G2LNet 相比于 MH 算法,ReconNet,CSNet,ISTANet+ 的平均 SSIM 在 10% 采样率下分别提升 0.133 7,0.141 4,0.017 2,0.089 5,在 20% 采样率下分别提升 0.112 7,0.176 8,0.006 3,0.017 8,在 30% 采样率下分别提升 0.091 0,0.134 4,0.035 2,0.040 4。G2LNet 在三个数据集下的平均 PSNR 和平均 SSIM 均是最优,重建图像质量较其他方法更好。


表 3 不同算法的重建图像的 SSIM 的对比结果

Tab. 3 Comparison results of SSIM of reconstructed images with different algorithms

采样率	数据集	MH ^[22]	ReconNet ^[23]	CSNet ^[9]	ISTA-Net ^{+[24]}	G2LNet
10%	Set5	0.835 0	0.734 1	0.901 0	0.839 8	0.898 6
	Set11	0.782 2	0.624 5	0.841 2	0.803 6	0.868 7
	BSD68	0.655 9	0.648 2	0.772 4	0.700 1	0.789 6
	Avg.	0.757 7	0.668 9	0.838 2	0.781 2	0.852 3
20%	Set5	0.888 1	0.794 0	0.950 1	0.902 1	0.943 6
	Set11	0.872 1	0.732 4	0.901 2	0.913 1	0.922 5
	BSD68	0.769 3	0.705 2	0.875 7	0.864 2	0.882 0
	Avg.	0.843 2	0.743 9	0.909 0	0.893 1	0.916 0
30%	Set5	0.918 5	0.823 3	0.963 3	0.934 1	0.959 3
	Set11	0.906 3	0.804 6	0.891 2	0.938 2	0.950 0
	BSD68	0.827 6	0.784 2	0.882 4	0.878 2	0.918 6
	Avg.	0.884 1	0.804 0	0.912 3	0.916 8	0.942 6

可视化对比:在图 3 中展示了在采样率为 10% 情况下图像 House 各个算法的重建图像对比,在图 4 中展示了在采样率为 20% 情况下图像 Monarch 各个算法的重建图像对比。从图中可以看出,ReconNet 恢复出的重建图像比较模糊,整体图像看不出纹理特征,MH 算法恢复出的重建

图像次之,ISTA-Net+ 恢复出的重建图像在低采样率下的块效应比较明显,CSNet 恢复出的重建图像细节部分略逊于 ISTA-Net+ 和 G2LNet。G2LNet 可以明显看到能够恢复出更多的纹理细节,图像质量更清晰,这是基于其同时考虑到了图像全局信息和像素局部邻域信息所带来的。






图3 采样率为10%,各个算法在图像House上的重建图像对比

Fig. 3 Sampling rate is 10%, and the reconstruction images of each algorithm on the image House are compared




图4 采样率为20%,各个算法在图像Monarch上的重建图像对比

Fig. 4 Sampling rate is 20%, and the reconstruction image comparison of each algorithm on the image Monarch

表5展示采样率为10%时,各个算法在Set11下平均运行时间。其中MH使用CPU计算,其余均使用GPU计算。我们的网络中使用了堆叠的快速傅里叶卷积模块,该卷积层中较普通卷积多了一次快速傅里叶变换与反变换,因此较其他基于深度的算法运算时间较长。

4.3 滤波流对比实验

为了验证利用滤波流的压缩感知图像重建框架的有效性,我们设计并训练了与G2LNet具有相同网络结构,但不含滤波流网络的FFCNet进行比较测试。FFCNet是基于卷积神经网络的端到端框架,其是图像到图像的重建方式。

表 4 和给出了 G2LNet 和 FFCNet 在采样率为 10%,20%,30% 共三种采样率下的比较结果,其比较数据集为:Set5,Set11 和 BSD68,比较指标为:平均 PSNR 和平均 SSIM。可以看出 G2LNet 的平均 PSNR 和平均 SSIM 均高于 FFCNet。由于卷积神经网络的框架难以学习像素级的小目标的变换,因此对于基于滤波流设计的框架,卷积神经网络难以直接生成较好质量的重建图像。同时证明了滤波流能够有效处理压缩感知图像重建的问题。

表 4 与不含滤波流的相同结构模型比较结果

Tab. 4 Comparing results with the same structured model without convolutional filter flow

数据集	算法模型	采样率					
		10%		20%		30%	
		PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
Set5	FFCNet	22. 16	0. 788 9	22. 82	0. 825 6	23. 20	0. 842 6
	G2LNet	30. 56	0. 898 6	34. 11	0. 943 6	36. 03	0. 959 3
Set11	FFCNet	23. 98	0. 825 3	24. 29	0. 869 7	26. 72	0. 904 6
	G2LNet	27. 95	0. 868 7	31. 21	0. 922 5	33. 71	0. 950 0
BSD68	FFCNet	22. 67	0. 734 6	23. 64	0. 813 4	25. 11	0. 854 1
	G2LNet	28. 39	0. 789 6	29. 59	0. 882 0	31. 29	0. 918 6

表 5 采样率为 10%,不同算法在 Set11 下的平均运行时间对比结果

Tab. 5 Sampling rate is 10%, Comparison of the average running time of different algorithms in Set11 (s)

算法名称	平均运行时间(CPU/GPU)
MH ^[22]	22. 703 468 91/—
ReconNet ^[23]	—/0. 052 174 221
CSNet ^[9]	—/0. 049 654 527
ISTA-Net+ ^[24]	—/0. 009 718 182
G2LNet	—/0. 123 254 545

4. 4 滤波流可视化

图 5 给出了在 20% 采样率下的损失函数的值随迭代次数的变化曲线,从图中可以看出随训练迭代次数的增加,损失函数的值逐渐降低并逐渐达到收敛,即表现出良好的稳定性。

由于生成的滤波流为高维数据,无法直接观测。我们先利用 K 分类将滤波流进行分组(K=60),然后利用 2D t-SNE 将 60 个滤波流降维为可视化的图像,结果如图 6 中左图所示(彩图见期刊电子版):每个蓝色框代表着一个滤波流,其中亮点表示对应位置有较大取值,与图形卷积时对应位置像素将被赋予较高的权重。2D t-SNE 处理时,我们为每个滤波流中的权值最大点中分配了颜色,其颜色分布如左上角颜色分布图所(如:红

色代表对应滤波流权值最大点位于右坐标轴上)。




图 5 20% 采样率下 loss 随训练迭代次数(epochs)的变化曲线

Fig. 5 Change curve of loss with the number of training iterations (epochs) at 20% sampling rate

图 6 中间图为 G2LNet 生成的最终重构图像。图 6 右图为使用滤波流对图像进行再次重构时,图像中各像素使用的滤波分布情况:其中颜色表示对应位置像素使用的滤波流,图中颜色分明的区域集中在图像凸出的边缘和纹理区域,且颜色分布不均匀。说明滤波流主要补充重建图像的高频细节,但不偏重于某一方向的信息。这



图6 30%采样率下G2LNet重建图像与滤波流可视化

Fig. 6 G2LNet reconstruction image and filter flow visualization at 30% sampling rate

与我们的预期相符:经过初始重建网络和快速傅里叶卷积网络,重建图像已经具有了较好的轮廓(低频信息),因此滤波流主要集中对图像的细节(高频信息)进行补充细化。

5 结 论

提出了一种基于深度学习的全局到局部的压缩感知图像重建网络模型(G2LNet)。该模型利用卷积层执行压缩采样过程和初始重建过程,

联合优化测量矩阵与滤波流,不仅利用快速傅里叶卷积扩大了感受野,有效利用了图像全局信息,还通过滤波流来学习像素局部邻域的局部信息。实验结果表明,G2LNet的图像重建质量相比于经典的传统算法MH与基于深度学习的算法CSNet的平均PSNR分别提高了2.29 dB和0.51 dB,有效提升了重建图像质量;相比于对比的其他主流的代表性算法具有更好的视觉效果和可理解性。

参考文献:

- [1] SHANNON C E. Communication in the presence of noise[J]. *Proceedings of the IRE*, 1949, 37(1): 10-21.
- [2] CANDÈS E J, WAKIN M B, BOYD S P. Enhancing sparsity by reweighted ℓ_1 [J]. *Journal of Fourier Analysis and Applications*, 2008, 14(5): 877-905.
- [3] DONOHO D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306.
- [4] BARANIUK R, CANDÈS E, NOWAK R, et al. Compressive sampling[J]. *IEEE Signal Processing Magazine*, 2008, 25(2): 12-13.
- [5] SHI W Z, LIU S H, JIANG F, et al. Video compressed sensing using a convolutional neural network[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021, 31(2): 425-438.
- [6] ROGERS C A, POPESCU D C. Compressed sensing MIMO radar system for extended target detection[J]. *IEEE Systems Journal*, 2021, 15(1): 1381-1389.
- [7] 黄博,周劫,江舸. 稳健型双层叠组LASSO逆合成孔径雷达高分辨成像算法[J]. *电子与信息学报*, 2021, 43(3): 674-682.
- HUANG B, ZHOU J, JIANG G. High resolution ISAR imaging algorithm based on robust two-tier group LASSO alternating direction method of multipliers[J]. *Journal of Electronics & Information Technology*, 2021, 43(3): 674-682. (in Chinese)
- [8] KUMAR P A, GUNASUNDARI R, AARTHI R. Systematic analysis and review of magnetic resonance imaging (MRI) reconstruction techniques[J]. *Current Medical Imaging Formerly Current Medical Imaging Reviews*, 2021, 17(8): 943-955.
- [9] SHI W Z, JIANG F, LIU S H, et al. Image compressed sensing using convolutional neural network[J]. *IEEE Transactions on Image Processing*,

- 2020, 29: 375-388.
- [10] MALLAT S G, ZHANG Z F. Matching pursuits with time-frequency dictionaries [J]. *IEEE Transactions on Signal Processing*, 1993, 41(12): 3397-3415.
- [11] 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.
- [12] FORNASIER M, RAUHUT H. Iterative thresholding algorithms [J]. *Applied and Computational Harmonic Analysis*, 2008, 25(2): 187-208.
- [13] BECK A, TEBOULLE M. A fast iterative shrinkage-thresholding algorithm for linear inverse problems [J]. *SIAM Journal on Imaging Sciences*, 2009, 2(1): 183-202.
- [14] WRIGHT S J, NOWAK R D, FIGUEIREDO M A T. Sparse reconstruction by separable approximation [J]. *IEEE Transactions on Signal Processing*, 2009, 57(7): 2479-2493.
- [15] FIGUEIREDO M A T, NOWAK R D, WRIGHT S J. Gradient projection for sparse reconstruction: application to compressed sensing and other inverse problems [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2007, 1(4): 586-597.
- [16] MUN S, FOWLER J E. Block Compressed Sensing of Images Using Directional Transforms [C]. 2010 *Data Compression Conference*. 24-26, 2010, *Snowbird, UT, USA*. IEEE, 2010: 547.
- [17] 景宁, 姚鼎一, 王志斌, 等. 等效时间采样压缩感知高频信号重建 [J]. *光学精密工程*, 2022, 30(10): 1240-1245.
- JING N, YAO D Y, WANG Z B, *et al.* High frequency signal reconstruction based on compressive sensing and equivalent-time sampling [J]. *Opt. Precision Eng.*, 2022, 30(10): 1240-1245. (in Chinese)
- [18] 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)*. 27-30, 2016, *Las Vegas, NV, USA*. IEEE, 2016: 449-458.
- [19] SHI W Z, JIANG F, ZHANG S P, *et al.* Deep Networks for Compressed Image Sensing [C]. 2017 *IEEE International Conference on Multimedia and Expo (ICME)*. 10-14, 2017, *Hong Kong, China*. IEEE, 2017: 877-882.
- [20] SHI W Z, JIANG F, LIU S H, *et al.* Scalable Convolutional Neural Network for Image Compressed Sensing [C]. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 15-20, 2019, *Long Beach, CA, USA*. IEEE, 2020: 12282-12291.
- [21] YANG Y, SUN J, LI H B, *et al.* ADMM-CS-Net: a deep learning approach for image compressive sensing [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(3): 521-538.
- [22] ZHANG J, ZHAO C, GAO W. Optimization-inspired compact deep compressive sensing [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2020, 14(4): 765-774.
- [23] CHEN C, TRAMEL E W, FOWLER J E. Compressed-Sensing Recovery of Images and Video Using Multihypothesis Predictions [C]. 2011 *Conference Record of the Forty Fifth Asilomar Conference on Signals, Systems and Computers (ASILOMAR)*. 6-9, 2011, *Pacific Grove, CA, USA*. IEEE, 2012: 1193-1198.
- [24] 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*. 18-23, 2018, *Salt Lake City, UT, USA*. IEEE, 2018: 1828-1837.
- [25] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [26] 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)*. 27-30, 2016, *Las Vegas, NV, USA*. IEEE, 2016: 770-778.
- [27] CHI L, JIANG B, MU Y. Fast fourier convolution [J]. *Advances in Neural Information Processing Systems*, 2020, 33: 4479-4488.
- [28] SEITZ S M, BAKER S. Filter Flow [C]. 2009 *IEEE 12th International Conference on Computer Vision*. September 29 - October 2, 2009, *Kyoto, Japan*. IEEE, 2010: 143-150.
- [29] SHI W Z, CABALLERO J, HUSZÁR 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)*. 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 1874-1883.
- [30] YANG J C, WRIGHT J, HUANG T S, *et al.* Image super-resolution via sparse representation [J]. *IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society*, 2010, 19(11): 2861-2873.
- [31] BEVILACQUA M, ROUMY A, GUILLEMOT C, *et al.* Low-Complexity Single-Image Super-Resolution Based on Nonnegative Neighbor Embedding [C]. *Proceedings of the British Machine Vision Conference 2012. Surrey. British Machine Vision Association*, 2012.
- [32] BO L, LU H C, LU Y J, *et al.* FompNet: Compressive Sensing Reconstruction with Deep Learning over Wireless Fading Channels [C]. 2017 *9th International Conference on Wireless Communications and Signal Processing (WCSP)*. 11-13, 2017, Nanjing, China. IEEE, 2017: 1-6.
- [33] 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*. 7-14, 2001, Vancouver, BC, Canada. IEEE, 2002: 416-423.
- [34] WANG Z, BOVIK A C, SHEIKH H R, *et al.* Image quality assessment: from error visibility to structural similarity [J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600-612.

作者简介:



仲元红(1981—),男,重庆合川人,2006年于重庆大学获得硕士学位,2011年于重庆大学获得通信与信息系统专业工学博士学位。长期从事计算机视觉,智能信息处理,智能硬件等方面的研究。E-mail: zhongyh@cqu.edu.cn



徐乾锋(1997—),男,湖北咸丰人,硕士研究生,2020年于重庆大学获得学士学位,主要从事计算机视觉,图像处理方面的研究。E-mail: qianfeng_xu@cqu.edu.cn