

基于卷积神经网络的压缩感知重构算法优化



刘玉红 刘树英 付福祥

兰州交通大学电子与信息工程学院 兰州 730070

摘要 压缩感知理论因其编码复杂度低、节省资源、抗干扰能力强等特点,被广泛应用于图像和视频信号处理。然而,传统的压缩感知技术也面临着重构时间长、算法复杂度高、迭代次数多、计算量大等问题。针对图像重构时间和重构质量的问题,文中提出一种新的卷积神经网络结构 Combine Network (CombNet),它将压缩感知的测量值作为卷积神经网络的输入,连接一个全连接层,然后通过 CombNet 获得最终输出。实验结果表明,CombNet 具有较低的复杂度及较好的恢复性能,在相同的采样率下,CombNet 的峰值信噪比(PSNR)较 TVAL3 提高了 7.2%~13.95%,较 D-AMP 提高了 7.72%~174.84%。CombNet 重构的耗时比传统重构算法提高了 3 个数量级,实现了实时重构。在采样率极低(采样率为 0.01 时)的情况下,CombNet 的平均 PSNR 较 D-AMP 高出 11.982 dB,因此所提算法具有更好的视觉吸引力。

关键词: 压缩感知;卷积神经网络;峰值信噪比;实时重构

中图分类号 TP389.1

Optimization of Compressed Sensing Reconstruction Algorithms Based on Convolutional Neural Network

LIU Yu-hong, LIU Shu-ying and FU Fu-xiang

School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China

Abstract Compressed sensing theory is widely used in image and video signal processing because of its low coding complexity, resource saving and strong anti-jamming ability. However, the traditional compressed sensing technology also faces such problems as long reconstruction time, high algorithm complexity, multiple iterations and large amount of computation. Aiming at the time and quality of image reconstruction, a new convolutional neural network structure named Combine Network (CombNet) was proposed. It takes the measured values of compressed sensing as the input of convolutional neural network, connects a full connection layer, and then obtains the final output through CombNet. Experiment results show that CombNet has lower complexity and better recovery performance. At the same sampling rate, the peak signal-to-noise ratio (PSNR) of CombNet is 7.2%~13.95% higher than that of TVAL3, and 7.72%~174.84% higher than that of D-AMP. The reconstruction time of CombNet is three orders of magnitude higher than that of traditional reconstruction algorithm. When the sampling rate is very low (the sampling rate is 0.01), the average PSNR of CombNet is 11.982 dB higher than D-AMP, therefore the proposed algorithm has better visual attraction.

Keywords Compressed sensing, Convolutional neural networks, PSNR, Real time reconstruction

1 引言

2006年,Candes等提出由部分傅里叶变换系数可精确重构出原始信号^[1]。接着,Donoho提出了压缩感知理论(Compressed Sensing, CS)的概念^[2]。该理论指明,人们可以获得少量的测量值,这些测量值是稀疏信号的随机投影,通过求解逆问题可以完美重建整个信号。CS是将采样和压缩集成到由前端硬件执行的单个步骤的信号采集范例。在满足特定的前提下,通过采集少量信息CS可以高精度地恢复出原始信号。CS理论编码简单,大大降低了编码复杂度,减少了

信号处理中的冗余信息,并在采样的同时对数据进行压缩,节省了资源消耗。

虽然传统的压缩感知重构算法解决了从CS测量值中重建图像的优化问题。但是,最优化问题解的迭代性质使得算法的计算成本昂贵,其中一些算法甚至需要十几分钟来恢复一个图像,使得实时重建无法实现。目前,这些算法虽然能够以高采样率提供高质量的重建,但是重构耗时久,并且随着采样率的降低,它们的性能明显下降,重构效果非常差。迭代重建算法在压缩感知图像重构中已经形成了应用瓶颈。

近年来,深度学习在计算机视觉和图像处理的任务(如语

收稿日期:2019-01-24 返修日期:2019-07-06 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61661025,61661026)

This work was supported by Nation Science Foundation of China(61661025,61661026).

通信作者:刘玉红(89996807@qq.com)

义分割、深度估计、图像超分辨率和图像去噪等^[12-15]中显示出了良好的性能。因此,一些学者将深度学习引入到图像和视频重建中,具体方法包括将叠加式去噪自动编码器(SDA)^[16]和卷积神经网络(CNN)^[17]应用到压缩感知的图像重建中。由于CNN能够利用自然图像中存在的空间相关性,而且每个卷积层具有比全连接层少得多的可学习参数,因此CNN特别有吸引力,并且更强大。

2 相关理论

2.1 压缩感知理论

CS理论主要包括3方面的内容:1)稀疏性,即信号中的大部分元素是0,或者绝对值非常小;2)测量矩阵,如何设计测量矩阵使其在采样过程中保留信号的有效信息是一个很重要的问题;3)重构算法,即设计快速的重构算法,从少量的观测值中恢复信号^[3]。

CS的重构算法相当于传统信号处理中的解码器,但是其复杂度高。为了从CS测量值中重建原始信号,早期的重构算法假定原始图像信号具有 l_p 范数($0 \leq p \leq 1$)稀疏性。基于这一假设,许多研究者提出了一些迭代算法,例如,匹配追踪算法^[5]、正交匹配追踪算法^[6]、迭代硬阈值算法^[7]、梯度投影算法^[8]等。同时,从稀疏方面改进的算法有:非局部稀疏度^[9]、块稀疏度^[10]、小波树稀疏度^[11]等。然而这些重构算法大多面临着算法复杂度高、低采样率时重构精度不高、不能实时重构等问题。

为了降低重构算法的计算复杂度,提高重构质量,实现实时重构,本文将CNN应用于CS的重构算法。CNN具有较强的自适应能力和优异的自学能力,还可以自动提取特征,因此将卷积神经网络与压缩感知相结合,可以有效避免传统方法计算量大的缺点,并取得良好的重建效果。

2.2 CNN理论

典型的卷积神经网络主要由输入层、卷积层、池化层(下采样层)、全连接层以及输出层组成^[18]。卷积层是对输入图像应用若干个卷积核进行内积的过程,其对输入图像进行特征提取,同时得到相同数目的特征图。卷积神经网络的第 i 层用 H_i 表示,那么 H_i 的产生过程可表示为:

$$H_i = f(H_{i-1} \otimes W_i + b_i) \quad (1)$$

其中, W_i 表示第 i 层卷积核的权值向量,运算符号 \otimes 表示卷积核与第 $i-1$ 层图像或者特征图进行内积。将输出与第 i 层的偏移向量 b_i 相加,最后通过非线性激励函数 $f(x)$ 得到第 i 层的特征图 H_i 。

池化层又称下采样层,用于压缩从卷积层输出的图像的数据量和参数的数量。池化层可以减少过拟合现象,并且对图像进行特征降维,去掉冗余信息,保留最重要的特征,使得图像中的特征不变。CNN经过多个卷积层和池化层,最后连接全连接层,通过全连接层对提取的特征进行分类,得到基于输入的概率分布 Y ,如式(1)所示。CNN的本质是使原始数据经过多次的数据变换或降维,映射到一个新的特征表达(Y)的数学模型。

$$Y(i) = P(L = l_i | H_0; (W, b)) \quad (1)$$

文献^[18]指出,CNN的工作原理分为3个部分:网络模

型的定义、网络训练以及网络预测。

3 CombNet网络结构

文献^[16]使用SDA来恢复欠采样测量的信号。SDA由全连接层组成,这意味着随着信号规模的增大,网络规模越来越大,这就需要大量的计算,算法复杂性增加,可能会导致过度拟合。文献^[4]利用卷积神经网络层,可任意测量信号,这意味着它可以重建整个图像,但随着信号尺寸的增大,测量成本也会增加。

从传统算法中可以看出,若要用CS技术重建出质量较好的图像,就需要将图像进行分块处理,这样可以实现对复杂信息块的特殊处理,并且可以在降低重建的复杂度的同时提高重建精确度。文献^[17]提出的ReconNet也运用了这种构想,该网络由1个全连接层和6个卷积层组成,其中前3层和后3层是相同的。这些层的功能描述如下:全连接层将CS测量作为输入,并输出尺寸为 33×33 的特征图;除了最后一个卷积层外,所有卷积层后面都跟着ReLU层。只有CNN的输入有结构信息时,CNN才可以工作。

虽然ReconNet是一个典型的将CNN应用于压缩感知重构部分的算法,能做到实时重构,但是ReconNet的网络层次较少,卷积核太大,增加了计算的复杂度,并且重构精度不高,图像边缘较模糊,因此重构质量没有达到较好的效果。

本文在ReconNet的基础上,将全卷积网络的层数加深,设计了更深的网络结构,扩展了全卷积网络的规模,并将较大的卷积核换成了较小的卷积核,因为多个小的卷积核叠加使用比一个大的卷积核单独使用的效果要好得多。在连通性不变的情况下,本文方法大大降低了参数个数和计算复杂度。

本文贡献如下:

(1)提出了一种新的图像压缩传感重构网络CombNet,由一个全连接层和一个全卷积网络组成,其性能优于现有的网络。对于该网络,在测量速率低于0.1时,其信噪比较传统算法更高,且信噪比减小得更缓慢,鲁棒性更强。

(2)全连接层以更快的速度和更低的计算成本生成较好的初步重建图像,起到初步恢复图像的作用。全连接层非常适用于计算资源和网络带宽有限的情况下的图像重建任务。

(3)全卷积网络进一步提高了网络的重构质量,恢复了图像的像素信息,能获得更好的视觉效果。

3.1 CombNet的网络模型

本文提出的卷积神经网络称为CombNet,其网络模型如图1所示。CombNet可以直接将CS测量值映射到图像块。网络的输入是将一幅图像压缩为 M 维向量作为卷积神经网络的输入,记为 ΦX 。 Φ 是大小为 $M \times N$ 维的观测矩阵, M 是测量数据, X 是量化的输入图像块。本文将图像分成 32×32 的块对图像进行重构,因此 $N=1024$ 。

CombNet由1个全连接层和10个卷积层组成。全连接层采用CS测量作为输入,并输出尺寸为 32×32 的特征图。全连接层与1024个神经元完全连接。本文利用随机梯度下降(SGD)训练算法,在所有训练样本上都能得到映射矩阵。

全卷积网络由10个卷积层组成。全连接层起到了从CS测量值中恢复一些结构信息的作用;卷积层跟在全连接层之

后,以提高图像的重构精度,获得一个高分辨率的输出。这些层的描述如下:第一层和第二层都使用 1×1 大小的卷积核,分别生成 128 个和 64 个特征图;第三层使用 9×9 大小的卷积核,生成 64 个特征图;第四层使用 7×7 大小的卷积核,生成 32 个特征图;第五层和第六层都生成了 16 个特征图,分别使用 3×3 和 1×1 大小的卷积核;第七、八、九层都生成了 1 个特征图,分别使用 $3 \times 3, 5 \times 5, 3 \times 3$ 大小的卷积核;最后一层通过 3×3 大小的卷积核,输出中间重建图像。然后,通过




图 1 CombNet 网络模型

Fig. 1 Network model of CombNet

损失函数是所有训练图像块的平均重建误差。本文选择 MSE 作为损失函数, MSE 是真实值与预测值的差值的平方和平均。给定一组高分辨率图像 $\{x_i\}$ 及其相应的低分辨率图像 $\{y_i\}$, 则 MSE 的计算公式为 $y = \frac{1}{m} \sum_i (y_i - x_i)^2$ 。其中, m 是训练集中的图像块总数, x_i 是第 i 个补丁, y_i 是第 i 个补丁的网络输出。

3.2 训练 CNN 网络

重构网络的训练是基于文献[15]中的 91 幅图像集, 从该图像集中均匀提取大小为 32×32 的图像块, 步幅为 14, 得到 21760 个图像块。这些图像块的亮度分量构成了训练集的标签。训练集的输入是图像块的相应 CS 测量值。




图 2 不同采样率下的图像重构视觉效果

Fig. 2 Visual effects of image reconstruction at different sampling rates

一个 BM3D 滤波器去除中间重建图像因分块量化的量化误差而产生的块效应, 最后输出图像。本文的网络结构保证了所有图层中特征图的大小不变。图 1 中, 输入图像被分成不重叠的块, 通过测量矩阵分别获得每个块的 CS 测量值, 将这些测量值作为 CombNet 的输入, 因此需要从每个图像块的压缩测量中重建每个图像块, 然后重建的块形成了低分辨率的重建图像, 并通过去噪器去除块状伪影, 输出最终的高分辨率重建图像。

实验结果表明, 该训练集足以训练深层网络。所有的训练都是基于 Caffe 平台^[19-20]进行了为期 3 天的训练。

网络训练过程如下: 首先构建一个测量矩阵 Φ , 随机生成一个适当大小的高斯矩阵, 然后对其行进行正交化。根据 $y = \Phi X$ 来获得 CS 的测量数据集, 并用该测量数据集对卷积神经网络进行训练, 训练的输入标签对可以表示为 $(\Phi X; X)$ 。本文在 4 种不同的采样率 (0.25, 0.10, 0.04 和 0.01) 下进行训练网络实验, 由于每块的总像素数 $N = 1024$, 因此测量次数分别为 256, 100, 40 和 10。4 种不同采样率下的图像重建效果如图 2 所示。从图 2 可以清楚地看到人类的脸、大树、蘑菇以及鸟。在采样率为 0.4 时, 重构出的图像仍然含有丰富的语义内容, 保留了图像中人们感兴趣的场景属性。

4 实验

4.1 实验条件以及环境

本文实验所使用的电脑为 X 64 兼容台式电脑, 电脑的操作系统是 Windows 7 64 位, 电脑处理器为英特尔 Core i7-7700K @4.20GHz 四核, 电脑的内存为 16GB, 主硬盘为三星 MZNLN128HCGR-000L1, 显卡为 NVIDIA GeForce GTX 1060 6GB。

本文使用 Caffe 实验平台, 并使用 MATLAB 运行程序进行实验。Caffe 是一个用 C++ 编写的深度学习框架, 支持命令行、Python 以及 MATLAB 接口。本文实验是在 MATLAB 程序中定义好网络结构, 然后在 Caffe 平台中进行训练, 最后通过 MATLAB 程序得出最终的重构图像。

4.2 实验及分析

本节将 CombNet 与 ReconNet, 以及两个迭代 CS 图像重建算法 TVAL3^[21] 和 D-AMP^[22] 进行比较。这些算法的参数 (包括迭代次数) 被设置为默认值。由于重建会产生块效应, 因此本文使用 BM3D^[23] 去噪器来减少这些块状伪影, 因为它在时间复杂度和重建质量之间进行了很好的折中。本文实验使用了 10 幅伯克利图像库中的标准测试图, 如图 3 所示。本

文分别在 0.25, 0.1, 0.04 和 0.01 的采样率下进行了无噪声和有噪声的块 CS 图像重建实验, 并对信噪比进行对比, 仿真结

果如表 1 和表 2 所列。其中, 4 种算法处理后图像的主观重建质量如表 1 所列, 平均信噪比和平均重构耗时如表 2 所列。

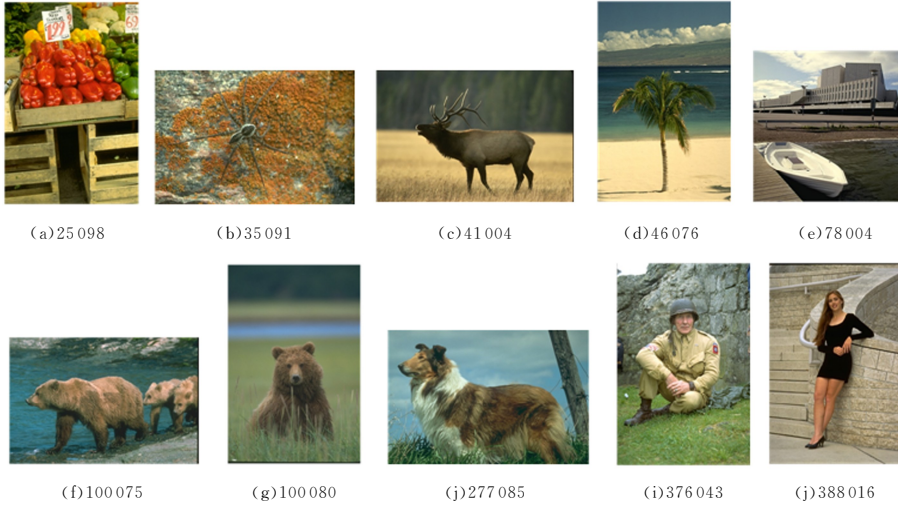


图 3 伯克利图像库中的 10 幅图像

Fig. 3 Ten images in Berkeley image library

表 1 不同测量速率下不同算法对于 10 幅图像的 PSNR 值

Table 1 PSNR values of different algorithms obtained at different measurement rates for 10 images

(单位: dB)

原图	算法	采样率为 0.25		采样率为 0.10		采样率为 0.04		采样率为 0.01	
		无滤波器	有滤波器	无滤波器	有滤波器	无滤波器	有滤波器	无滤波器	有滤波器
25 098	TVAL3	20.46	20.51	19.40	19.45	17.61	17.68	15.31	15.27
	D-AMP	20.61	20.88	16.42	16.56	10.83	11.02	6.48	6.67
	ReconNet	21.15	21.20	20.13	20.23	18.05	18.21	15.42	15.58
	CombNet	21.43	21.60	20.32	20.51	18.48	18.68	15.86	16.03
35 091	TVAL3	20.55	20.63	19.48	19.54	18.71	18.79	15.31	15.37
	D-AMP	21.07	21.22	18.26	18.49	14.31	14.49	7.16	7.32
	ReconNet	21.25	21.30	20.00	20.12	18.57	18.71	17.36	17.46
	CombNet	21.98	22.29	20.36	20.56	18.75	18.91	17.60	17.72
41 004	TVAL3	24.46	24.49	23.12	23.17	20.03	20.06	19.40	19.48
	D-AMP	27.20	27.31	25.29	25.45	16.07	16.22	6.41	6.65
	ReconNet	23.97	24.05	23.09	23.20	21.67	21.84	18.73	18.86
	CombNet	24.56	24.97	23.11	23.43	21.80	22.03	19.65	19.85
46 076	TVAL3	24.29	24.36	23.32	23.40	19.55	19.61	17.87	17.94
	D-AMP	25.09	25.32	23.81	24.03	13.97	14.11	5.47	5.62
	ReconNet	22.01	22.06	21.52	21.61	20.61	20.72	19.08	19.19
	CombNet	22.32	22.81	21.65	21.96	20.84	20.95	19.31	19.41
78 004	TVAL3	18.52	18.67	17.04	17.12	15.42	15.54	14.69	14.73
	D-AMP	19.79	20.03	17.87	18.02	11.76	11.97	6.52	6.73
	ReconNet	20.89	20.98	19.54	19.69	18.03	18.24	15.48	15.62
	CombNet	20.81	21.19	19.85	20.10	18.56	18.76	16.56	16.73
100 075	TVAL3	24.39	24.48	23.16	23.27	20.53	20.60	17.36	17.45
	D-AMP	24.27	24.45	21.61	21.83	14.11	14.26	8.83	9.00
	ReconNet	24.61	24.66	23.66	23.79	22.34	22.48	19.89	20.04
	CombNet	24.80	25.10	23.53	23.82	22.43	22.61	20.00	20.18
100 080	TVAL3	21.41	21.50	20.14	20.19	19.93	20.01	16.51	16.55
	D-AMP	24.07	24.26	20.64	20.89	10.49	10.68	7.51	7.70
	ReconNet	26.88	26.91	26.41	26.48	25.24	25.36	24.03	24.18
	CombNet	26.94	27.15	26.76	27.02	25.66	25.95	24.08	24.22
247 085	TVAL3	25.27	25.33	23.61	23.69	20.38	20.42	18.04	18.12
	D-AMP	26.65	26.87	20.14	20.37	10.01	10.25	6.74	6.91
	ReconNet	23.91	23.97	22.99	23.10	21.66	21.83	19.91	20.07
	CombNet	24.03	24.17	23.04	23.19	21.87	22.03	19.98	20.15
376 043	TVAL3	19.34	19.41	18.32	18.40	17.33	17.38	16.11	16.19
	D-AMP	20.88	20.92	18.71	18.86	11.62	11.75	6.41	6.48
	ReconNet	20.89	20.96	19.79	19.94	18.46	18.62	16.90	17.04
	CombNet	21.22	21.52	19.97	20.23	18.70	18.90	17.20	17.37
388 016	TVAL3	16.64	16.59	15.28	15.32	14.72	14.83	14.15	14.19
	D-AMP	25.12	25.30	20.07	20.21	10.06	10.21	5.37	5.45
	ReconNet	20.45	20.49	19.46	19.54	18.04	18.18	15.88	15.90
	CombNet	20.59	20.67	19.50	19.71	18.32	18.49	16.55	16.69

表2 各种算法重建单幅图像的平均信噪比和耗时

Table 2 Average PSNR and consuming time of various algorithms reconstructing a single image

算法	采样率=0.25		采样率=0.1		采样率=0.04		0.01 采样率	
	平均 PSNR/dB	平均重构耗时/s	平均 PSNR/dB	平均重构耗时/s	平均 PSNR/dB	平均重构耗时/s	平均 PSNR/dB	平均重构耗时/s
TVAL3	21.591	3.9892	20.355	4.6754	18.514	5.1439	16.529	5.3431
D-AMP	23.657	200.1694	20.473	240.5660	12.496	272.1407	6.853	325.9651
ReconNet	22.658	0.7325	21.770	0.8876	20.419	0.9926	18.394	1.0487
CombNet	23.147	0.8203	22.053	0.9615	20.731	1.0940	18.835	1.1514

对于给定的测试图像,为了模拟无噪声的CS测量,本文首先将图像划分为 32×32 大小的非重叠块,然后计算每个块的CS测量值。对于每个采样率,本文使用的测量矩阵是各采样率对应的随机高斯测量矩阵。从表1可以看出,与其他3种算法重构出的图像峰值信噪比相比,CombNet的信噪比有了明显的提高。信噪比的改善代表平滑性更好,失真度减小。通过仿真数据和重建质量的对比可以看出,CombNet有效提高了图像处理质量,图像的细节损失明显减少,重构出的图像更加清晰,效果更好,而且在低采样率时,CombNet的信噪比更高,从高采样率到低采样率,PSNR下降得更缓慢。由此证明,本文算法能适应低采样率的环境,鲁棒性较好。除了重建质量好、重建精度高外,优化后的算法实现了实时计算,计算速度比传统的重建算法至少快3个数量级。为此,本文比较了各种算法在不同测量速率下从无噪声CS测量中重构

测试图像所需的平均时间,如表2所列。

根据采样率的不同,CombNet重建图像所需的时间比TVAL3快4~5倍,比D-AMP快244~283倍。值得注意的是,本文优化后的算法能够实现实时性是因为与传统的CS算法不同,传统的CS算法是迭代的,耗时长;而基于CNN的算法是一种非迭代算法,并且通过简单的卷积操作,就可重构出图像,因此可以实现快速重构。由于传统的重构算法是迭代的,采样率越高,其重构精度就越高,而本文提出的算法是非迭代的,因此在采样率高于0.1时,其PSNR有时会低于传统的重构算法;在采样率高于0.1时,其PSNR高于传统的重构算法。

图4给出了3幅标准图像,在采样率为0.1时各种算法的最终重建效果。从重建的图像中可以看到,本文优化后的算法能够保留图像更精细的特征,而其他算法均无法做到这一点。

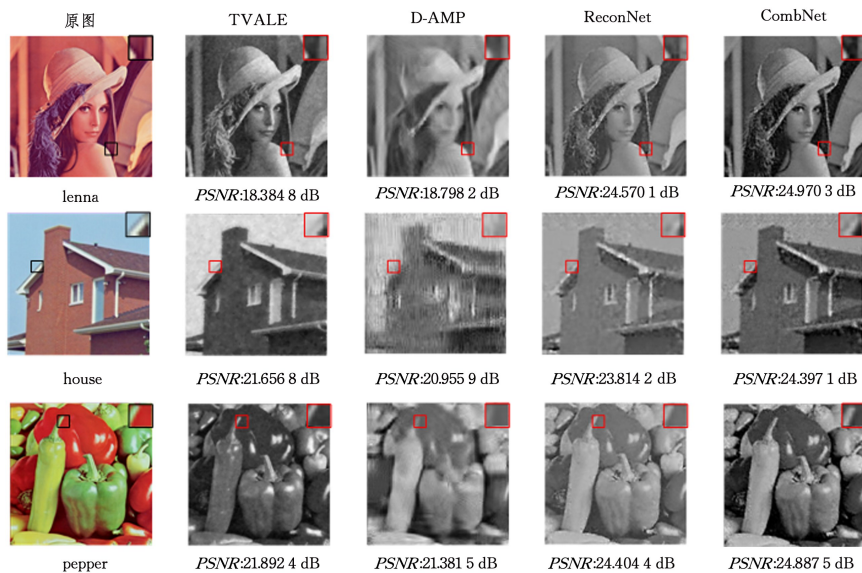


图4 4种算法在采样率为0.1时无噪声条件下的信噪比和重建后的视觉效果比较

Fig. 4 Comparison of signal-to-noise ratio and reconstructed visual effects with 0.1 sampling rate and no noise for 4 algorithms

结束语 随着图像和视频信息处理的不断发展,压缩感知已广泛应用于图像处理。压缩感知技术由于只需要采集少量的信息就能够恢复出原始信号,降低了编码复杂度和资源消耗,因此成为图像处理领域的热点。传统的压缩感知重构算法中,迭代的算法的算法复杂度和时间复杂度较高,且重构效果不佳。为了适应现今社会生活中图像和视频信号处理的需求,提高图像处理的速度和质量,有效解决分块处理过程中的块效应,本文提出了一种新的卷积神经网络CombNet,用于压缩感知图像重构。它易于实现,并且重构时间比传统的迭代算法快3个数量级,能实现实时重建,并且在采样率较高

时提供了极好的重建质量,保留了丰富的图像信息,在采样率较低时也能保留关键的图像信息。但是本文所提出的算法仍有不足之处,即图像在进行压缩感知时被分成块,因此在重构时也会破坏图像的结构信息。这也将是我们的下一个研究方向。

参考文献

- [1] CANDÉS 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.
- [2] DONOHO D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4):1289-1306.
- [3] WANG H L, WANG S, LIU W Y. An Overview of Compressed Sensing Implementation and Application[J]. *Journal of Detection & Control*, 2014, 36(4).
- [4] MOUSAVI A, BARANIUK R G. Learning to Invert; Signal Recovery Via Deep Convolutional Networks[C]// 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2017.
- [5] MALLAT S G, ZHANG Z. Matching pursuits with time-frequency dictionaries[J]. *IEEE Trans on Signal Processing*, 1993, 41(12):3397-3415.
- [6] 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.
- [7] BLUMENSATH T, DAVIES M E. Iterative hard thresholding for compressed sensing[J]. *Applied & Computational Harmonic Analysis*, 2009, 27(3):265-274.
- [8] 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*, 2008, 1(4):586-597.
- [9] MAIRAL J, BACH F, PONCE J, et al. Non-local sparse models for image restoration[C]// IEEE International Conference on Computer Vision. 2010.
- [10] EL DAR Y C, KUPPINGER P, BÖLCSKEI H. Block-Sparse Signals; Uncertainty Relations and Efficient Recovery[J]. *IEEE Transactions on Signal Processing*, 2010, 58(6):3042-3054.
- [11] BARANIUK R G, CEVHER V, DUARTE M F, et al. Model-Based Compressive Sensing[J]. *IEEE Transactions on Information Theory*, 2010, 56(4):1982-2001.
- [12] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2014, 39(4):640-651.
- [13] EIGEN D, PUHRSCHE C, FERGUS R. Depth Map Prediction from a Single Image using a Multi-Scale Deep Network [J]. arXiv:1406.2283v1.
- [14] CHAO D, HE K, CHEN C L, et al. Learning a Deep Convolutional Network for Image Super-Resolution[C]// European Conference on Computer Vision. Cham: Springer, 2014.
- [15] XIE J Y, XU L L, CHEN E H. Image denoising and inpainting with deep neural networks [C]// International Conference on Neural Information Processing Systems. 2012:341-349.
- [16] 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 (Allerton). IEEE, 2015:1336-1343.
- [17] 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). IEEE Computer Society, Las Vegas, NV, 2016.
- [18] LI Y D, HAO Z B, LEI H. Survey of convolutional neural network[J]. *Journal of Computer Application*, 2016, 36(9):2508-2515.
- [19] TAQI A M, AL-AZZO F, MARIOFANNA M, et al. Classification and discrimination of focal and non-focal EEG signals based on deep neural network[C]// International Conference on Current Research in Computer Science & Information Technology. 2017:8692.
- [20] JIA Y Q, SHELHAMER E, DONAHUE J, et al. Caffe; Convolutional Architecture for Fast Feature Embedding [C]// ACM International Conference on Multimedia. 2014.
- [21] 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.
- [22] METZLER C A, MALEKI A, BARANIUK R G. From Denoising to Compressed Sensing[J]. *IEEE Transactions on Information Theory*, 2016, 62(9):5117-5144.
- [23] DABOV K, FOI A, KATKOVNIK V, et al. Image Denoising by Sparse 3-D Transform-Domain Collaborative Filtering[J]. *IEEE Transactions on Image Processing*, 2007, 16(8):2080-2095.



LIU Yu-hong, born in 1975, master, associate professor. Her main research interests include wireless communication, compressed sensing and image processing.