

基于多尺度残差网络的压缩感知重构算法

练秋生^{1,2} 富利鹏^{1,2} 陈书贞^{1,2} 石保顺^{1,2}

摘要 目前压缩感知系统利用少量测量值使用迭代优化算法重构图像. 在重构过程中, 迭代重构算法需要进行复杂的迭代运算和较长的重构时间. 本文提出了多尺度残差网络结构, 利用测量值通过网络重构出图像. 网络中引入多尺度扩张卷积层用来提取图像中不同尺度的特征, 利用这些特征信息重构高质量图像. 最后, 将网络的输出与测量值进行优化, 使得重构图像在测量矩阵上的投影与测量值更加接近. 实验结果表明, 本文算法在重构质量和重构时间上均有明显优势.

关键词 压缩感知, 卷积神经网络, 多尺度卷积, 扩张卷积

引用格式 练秋生, 富利鹏, 陈书贞, 石保顺. 基于多尺度残差网络的压缩感知重构算法. 自动化学报, 2019, 45(11): 2082–2091

DOI 10.16383/j.aas.c170546

A Compressed Sensing Algorithm Based on Multi-scale Residual Reconstruction Network

LIAN Qiu-Sheng^{1,2} FU Li-Peng^{1,2} CHEN Shu-Zhen^{1,2} SHI Bao-Shun^{1,2}

Abstract In recent years, a small number of measurements and iterative optimization algorithms were exploited in compressed sensing to reconstruct images. In the process of reconstruction, most algorithms based on iteration for compressed sensing image reconstruction suffer from the complicatedly iterative computation and time-consuming. In this paper, we propose a novel multi-scale residual reconstruction network (MSRNet), and exploit the measurements to reconstruct images through the network. The multi-scale dilate convolution layer is introduced in the network to extract the feature of different scales in the image, and the feature information could improve the quality of reconstructed image. Finally, we exploit the output of the network and measurements to optimize our algorithm, so as to make the projection of the reconstructed image closer to the measurements. The experimental results show that the MSRNet requires less running time and has better performance in reconstruction quality than other compressed sensing algorithms.

Key words Compressive sensing, convolution neural network, multi-scale convolution, dilate convolution

Citation Lian Qiu-Sheng, Fu Li-Peng, Chen Shu-Zhen, Shi Bao-Shun. A compressed sensing algorithm based on multi-scale residual reconstruction network. *Acta Automatica Sinica*, 2019, 45(11): 2082–2091

传统的奈奎斯特采样速率必须达到信号带宽的两倍以上才能精确重构出原始信号. 然而随着科技的不断进步, 所处理信号的带宽也在不断地增加, 这对传统的采样系统提出了挑战. 近年来, 由 Donoho 和 Candes 等提出的压缩感知理论^[1–4], 突破了这一限制, 其主要思想是利用随机测量矩阵

$\Phi \in \mathbf{R}^{m \times n}$ 对信号 $\mathbf{x} \in \mathbf{R}^{n \times 1}$ 进行采样, 将 \mathbf{x} 投影到 m 维的低维空间, 并证明这样随机投影的测量值 $\mathbf{y} \in \mathbf{R}^{m \times 1}$ ($\mathbf{y} = \Phi \mathbf{x}$) 中包含了重构信号的足够信息, 通过求解一个稀疏优化问题, 利用投影在低维空间的测量信号可重构出原始信号.

在图像压缩感知问题中, 测量值 \mathbf{y} 的维度 m 远小于原始信号 \mathbf{x} 的维度 n , 图像压缩感知重构本质上是求解一个欠定方程, 如何从这个欠定方程中寻找出最优解是重构的关键. 近年来众多学者提出了基于图像在某种变换域具有稀疏性的图像重构算法, 该类算法利用 l_p ($0 \leq p \leq 1$) 范数衡量稀疏系数的稀疏性, 通常使用正交匹配追踪 (Orthogonal matching pursuit, OMP) 算法^[5], 迭代硬阈值 (Iterative hard-thresholding) 算法^[6] 等求解对应的稀疏编码问题. 还有学者提出利用梯度稀疏性^[7]、非局部稀疏性^[8] 和块稀疏性^[9] 作为先验知识对原始信号进行重构, 基于混合基稀疏图像表示^[10], 基于非局部相似性^[11] 的压缩感知图像重构

收稿日期 2017-09-26 录用日期 2018-01-29
Manuscript received September 26, 2017; accepted January 29, 2018

国家自然科学基金 (61471313), 河北省自然科学基金 (F2019203318) 资助

Supported by National Natural Science Foundation of China (61471313) and Natural Science Foundation of Hebei Province (F2019203318)

本文责任编辑 胡清华

Recommended by Associate Editor HU Qing-Hua

1. 燕山大学信息科学与工程学院 秦皇岛 066004 2. 河北省信息传输与信号处理重点实验室 秦皇岛 066004

1. School of Information Science and Engineering, Yanshan University, Qinhuangdao 066004 2. Hebei Key Laboratory of Information Transmission and Signal Processing, Qinhuangdao 066004

算法也被提出. 然而这些重构算法都需要进行复杂的迭代运算, 重构时间较长, 并且在较低的采样率下, 重构图像质量较差.

深度学习自提出以来, 在计算机视觉和图像处理方面, 受到广泛关注, 如, 图像超分辨率重建^[12]、图像语义分割^[13]、图像去噪^[14]等, 并且在这些方面都呈现出较好的效果. 最近, 有学者将深度学习应用在压缩感知上, 利用堆降噪自编码模型^[15] (Stacked denoiseing auto-encoders, SDA) 和卷积神经网络 (Convolutional neural network, CNN)^[16] 学习一个端到端的映射, 利用测量值, 通过网络直接重构图像. 在文献 [15] 中, Mousavi 等利用 SDA 训练得到测量值与重构图像的映射, 使用该映射利用测量值进行图像重构. Kulkarni 等在文献 [16] 中提出的 ReconNet 网络将两个 SRCNN (11-1-7) 模型^[12] 堆叠, 在卷积网络前级联一个全连接层, 实现了非迭代图像压缩感知重构, 但重构质量相对较差. Yao 等将 ReconNet 网络与残差网络^[17] 结构相结合提出了 DR²-Net^[18], 网络由全连接层和四个残差块 (12 层卷积层) 组成. DR²-Net 相对于 ReconNet 网络提高了重构质量, 但是由于含有较多的卷积层需要花费较长的重构时间.

本文在 ReconNet 和 DR²-Net 的基础上提出多尺度残差重构网络, 使用不同尺寸的卷积核组合成多种感受野, 捕捉图像中不同尺度的特征, 进而重构出高质量的图像. 在重构网络中, 引入扩张卷积 (Dilate convolution)^[19], 仅使用 7 层卷积层, 重构图像的质量优于 DR²-Net, 且重构时间比其短.

1 图像压缩感知重构

图像压缩感知重构主要是对图像进行随机投影采样, 并利用图像在某种变换域的稀疏性作为先验知识, 从少量测量数据中重构出原始图像. 对于 $n = W \times H$ 的图像, 将其向量化为 $\mathbf{x} \in \mathbf{R}^{n \times 1}$, 取 $m \times n$ 维的测量矩阵 Φ 对原始图像 \mathbf{x} 进行采样得:

$$\mathbf{y} = \Phi \mathbf{x} \quad (1)$$

当 $m \ll n$ 时, 式 (1) 是一个病态问题, 存在无穷多个解. 利用图像在变换域具有稀疏性的先验知识:

$$\mathbf{y} = \Phi \Psi \mathbf{s} \quad (2)$$

其中, Ψ 中的每一列是变换域的一个基向量, \mathbf{s} 是 \mathbf{x} 在变换域 Ψ 的稀疏系数组成的向量. 对于式 (2) 可以通过求解下式的非凸优化问题:

$$\min_{\mathbf{x}} \|\Psi^T \mathbf{x}\|_0, \text{ s.t. } \mathbf{y} = \Phi \mathbf{x} \quad (3)$$

式 (3) 是一个典型的 NP-Hard 问题, 一般常用 l_1 范数代替 l_0 范数转化为凸优化问题即式 (4):

$$\min_{\mathbf{x}} \|\Psi^T \mathbf{x}\|_1, \text{ s.t. } \mathbf{y} = \Phi \mathbf{x} \quad (4)$$

求解该问题时需要多次迭代运算, 因此重构速度较慢.

传统的优化方法基本不能实现实时重构, 如果用 $m \times n$ 的测量矩阵 Φ 对图像 $n = H \times W$ 进行采样时计算量和存储量比较大, 影响重构速度. 为了减少存储量, 提高采样速度, 对图像进行分块采样^[20] 重构. 将图像分成 $B \times B$ 的小块, 用相同的采样矩阵 Φ_B 对图像块进行采样. 则每个小块 $\mathbf{x}_i \in \mathbf{R}^{B^2 \times 1}$ 对应的测量信号表示为 $\mathbf{y}_i = \Phi_B \mathbf{x}_i$, 其中 Φ_B 是一个 $n_B \times B^2$ 的行正交高斯矩阵.

2 重构网络

2.1 网络结构

如图 1 所示, 受文献 [18] 的启发, 本文首先使用线性重构网络即一个全连接层对图像进行重构, 得到原始图像 $\mathbf{x}_i \in \mathbf{R}^{n \times 1}$ 的近似解 $\hat{\mathbf{x}}_i$, 再通过多尺度残差网络学习 $\hat{\mathbf{x}}_i$ 与原始图像 \mathbf{x}_i 的残差 \mathbf{d}_i , 最终得到高质量的重构图像.

$$\mathbf{d}_i = \mathbf{x}_i - \hat{\mathbf{x}}_i \quad (5)$$

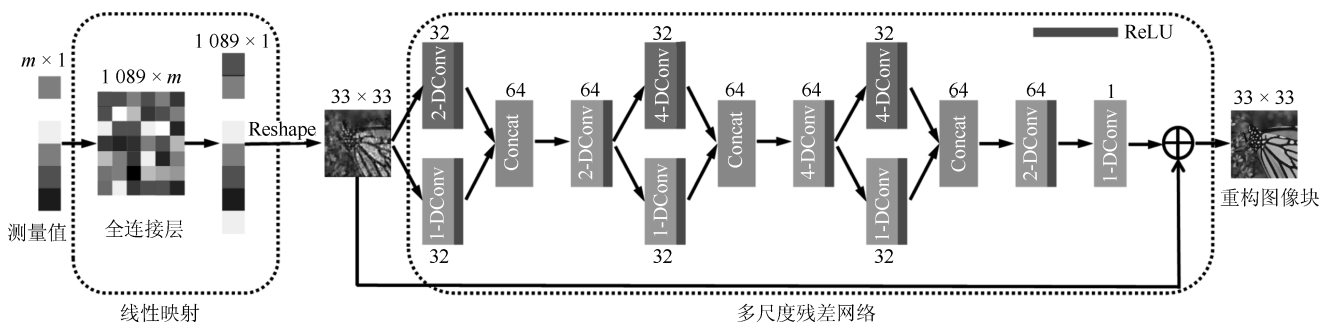


图 1 多尺度残差重构网络 (MSRNet), s-Dconv 表示扩张卷积, $s = 1, 2, 4$

Fig. 1 Mult-scale residue reconstruction network, s-Dconv denotes s-dilate convolution, here $s = 1, 2$ and 4

2.2 线性生成网络

在文献 [18] 中, 使用一层全连接层对图像进行初等的重构. 本文在图像重构过程中也引入这一结构. 训练集包含 N 个训练样本即 $\{(\mathbf{y}_1, \mathbf{x}_1), (\mathbf{y}_2, \mathbf{x}_2), \dots, (\mathbf{y}_N, \mathbf{x}_N)\}$, $\mathbf{y}_i \in \mathbf{R}^{m \times 1}$ 为测量值, $\mathbf{y}_i = A\mathbf{x}_i$, $A \in \mathbf{R}^{m \times n}$ 为随机行正交的高斯矩阵, $\mathbf{x}_i \in \mathbf{R}^{n \times 1}$ 为对应的图像块, 损失函数使用均方误差函数如式 (6) 所示:

$$L(\{W^f\}) = \frac{1}{N} \sum_{i=1}^N \|\mathbf{x}_i - F^f(\mathbf{y}_i, W^f)\|_2^2 \quad (6)$$

使用 Adam (Adaptive moment estimation)^[21] 方法进行训练, 优化得到 $W^f \in \mathbf{R}^{1089 \times m}$, 使得式 (6) 最小. $F^f(\cdot)$ 表示由一个全连接层组成的线性映射, 网络 $F^f(\cdot)$ 包含 1089 个神经元, 训练完成后利用测量值 \mathbf{y}_i 通过式 (7) 重构得到 \mathbf{x}_i 的近似解 $\hat{\mathbf{x}}_i$.

$$\hat{\mathbf{x}}_i = F^f(\mathbf{y}_i, W^f) \quad (7)$$

2.3 多尺度残差网络

线性映射网络 $F^f(\cdot)$ 重构出的图像, 图像质量较差, 为了提高重构图像的质量, 引入多尺度残差网络 $F^{msr}(\cdot)$.

如图 1 所示, 线性网络的输出作为多尺度残差网络 $F^{msr}(\cdot)$ 的输入, 通过网络输出大小为 33×33 的图像块. 多尺度残差网络有 7 层卷积核大小为 3×3 的卷积层, 除最后一层其他所有卷积层的激活函数为 ReLU (Rectified linear units)^[22], 第 1 层到第 6 层输出 64 个特征图, 第 7 层输出一个特征图. 网络中有 3 层多尺度层, 分别是第 1 层、第 3 层和第 5 层, 每一个多尺度层由两种不同扩张因子的扩张卷积组成, 第 1 层扩张因子 s 为 1 和 2, 第 3、5 层的扩张因子 s 为 1 和 4, 每一种扩张卷积输出 32 个特征图, 然后将每一层输出的特征图级联, 输出 64 个特征图. 为了增大网络的感受野, 剩下的卷积层也使用扩张卷积, 第 2、4、6、7 层的扩张因子 s 分别为 2、4、2、1.

测量值 \mathbf{y}_i 作为网络的输入, 首先由线性映射层 $F^f(\cdot)$ 重构出一幅中间图像 $\hat{\mathbf{x}}_i$, 再通过多尺度残差网络 $F^{msr}(\cdot)$ 估计出残差 \mathbf{d}_i , 最后由式 (8) 得到重构图像 \mathbf{x}_i^* .

$$\mathbf{x}_i^* = \hat{\mathbf{x}}_i + \mathbf{d}_i \quad (8)$$

将式 (8) 中的 $\hat{\mathbf{x}}_i$ 和 \mathbf{d}_i 用 $F^f(\cdot)$ 和 $F^{msr}(\cdot)$ 代替, \mathbf{x}_i^* 可由式 (9) 表示.

$$\mathbf{x}_i^* = F^f(\mathbf{y}_i, W^f) + F^{msr}(F^f(\mathbf{y}_i, W^f), W^{msr}) \quad (9)$$

将式 (6) 求解所得的 W^f 作为式 (9) 中 W^f 的初始值, 使用 Adam 算法更新 MSRNet 中的参数 W^f 和 W^{msr} . 所使用的损失函数为均方误差 (Mean squared error, MSE) 损失函数, 即式 (10):

$$L(\{W^f, W^{msr}\}) = \frac{1}{N} \sum_{i=1}^N \|\mathbf{x}_i - \mathbf{x}_i^*\|_2^2 \quad (10)$$

其中, N 表示训练集中样本的数目, \mathbf{y}_i 为压缩感知测量值, \mathbf{x}_i 为 \mathbf{y}_i 对应的图像块标签, \mathbf{x}_i^* 为网络的输出即重构图像块.

2.4 多尺度卷积层

卷积神经网络中的卷积核常常用来提取图像中的特征, 但是相同尺寸的卷积核只能提取同一尺度特征, MSRNet 在同一层使用两种不同尺寸的卷积核提取图像中不同尺度的特征, 通过级联操作 (Concat) 将多尺度层的特征信息融合作为下一层的输入. 本算法分别在网络的第 1 层、第 3 层和第 5 层使用多尺度层, 组合成多种感受野, 捕获图像中不同尺度的特征, 提高图像的重构质量. 多尺度层如图 2 所示, 由一个卷积层和一个级联层组成. s_1 和 s_2 为不同值的扩张因子, 将 3×3 的卷积核扩张为不同尺寸大小的卷积核, 组成多尺度卷积层. 每一个卷积核输出 32 个特征图, 再通过级联层将不同尺度的特征融合为 64 个特征图, 作为下一层的输入.




图 2 多尺度卷积层

Fig. 2 Multi-scale convolution layer

2.5 使用扩张卷积增大网络感受野

图像重构过程中, 感受野是非常重要的, 大的感受野可以捕捉更多的图像信息, 提高图像重构质量. 在卷积神经网络中, 一般使用大尺寸的卷积核、增加卷积层的层数和引入池化层 (Pooling layer), 来增加网络的感受野. 但是随着卷积核的增大和网络层数的增加, 网络的计算复杂度也会增加, 使得图像重构时间变长. 池化虽然没有增加网络的计算复杂度, 但是丢失了许多的信息, 导致重构图像质量较差. 本文引入文献 [19] 中的扩张卷积来增大网络的感受野. 扩张卷积增大了网络的感受野, 但不增加网络的参数, 使得图像重构速度较快. 例如, 使用扩张因子 $s = 2$ 对 3×3 的卷积核进行扩张, 得到 $(2s + 1) \times (2s + 1)$ 即 5×5 的卷积核, 该卷积核有

9 个位置不为零, 其余位置都为零, 感受野从原来的 3×3 变为 5×5 , 如图 3 所示, 左边为普通的卷积, 右边为 $s = 2$ 的扩张卷积.

在 MSRNet 网络中引入多尺度卷积核用来提取图像中不同尺度的特征, 提高重构图像的质量. 本文在第 1 层、第 3 层和第 5 层分别加入多尺度卷积核, 使得 MSRNet 有多种感受野, 其尺寸分别为 25×25 、 27×27 、 31×31 、 33×33 、 37×37 和 39×39 . 网络中不同大小的感受野可以捕获图像中不同尺度的特征, 从而提高重构图像的质量.




图 3 扩张卷积

Fig. 3 Dilate convolution

2.6 重构过程

在图像重构过程中, 给出一幅图像, 对图像进行非重叠取块, 块大小为 33×33 . 用随机行正交高斯矩阵对每一个图像块进行采样, 得到的测量值 \mathbf{y} 作为 MSRNet 网络的输入, 重构出高质量的图像块. 由于 MSRNet 所重构出的图像块在测量矩阵上的投影与测量值具有一些误差, 所以本文对重构图像进行修正, 进一步提高图像的重构质量. 利用式 (11) 对重构图像进行修正:

$$\mathbf{z}_i^* = \arg \min_{\mathbf{z}_i} \{ \|\mathbf{A}\mathbf{z}_i - \mathbf{y}_i\|_2^2 + \lambda \|\mathbf{z}_i - \mathbf{x}_i^*\|_2^2 \} \quad (11)$$

其中, \mathbf{z}_i^* 为修正后的重构图像块, \mathbf{x}_i^* 为网络重构的图像块, \mathbf{A} 为随机行正交的高斯采样矩阵. 在式 (11) 中, $\|\mathbf{A}\mathbf{z}_i - \mathbf{y}_i\|_2^2$ 这一项衡量重构图像块在测量矩阵

上投影与测量值的误差, $\|\mathbf{z}_i - \mathbf{x}_i^*\|_2^2$ 使得修正后的图像块与网络重构图像块更加接近, 实验中令参数 $\lambda = 1$. 对式 (11) 求导, 令导数为零, 得

$$\mathbf{z}_i^* = (\mathbf{A}^T \mathbf{A} + \lambda \mathbf{I})^{-1} (\mathbf{A}^T \mathbf{y} + \mathbf{x}_i^*) \quad (12)$$

其中, \mathbf{I} 为 1089×1089 的单位阵. 然后使用 BM3D^[23] 去除块效应, 再通过式 (12) 进行一次修正, 最终获得一幅高质量的重构图像. 利用式 (12) 进行修正时, $(\mathbf{A}^T \mathbf{A} + \lambda \mathbf{I})^{-1}$ 计算一次即可, 因此在修正过程中只需计算 $(\mathbf{A}^T \mathbf{y} + \mathbf{x}_i^*)$ 这一项, 修正过程时间复杂度较低.

图 4 显示了 Barbara 重构图像块修正前后在测量矩阵上投影与测量值误差的比较, 明显可以看出修正后的图像块在测量矩阵的投影与测量值更加接近. 误差 Error 为重构图像在测量矩阵的投影与测量值的差的 l_2 范数, N 为重构图像块的序号.

3 网络的训练

3.1 训练多尺度残差网络

本文使用和文献 [16] 一样的训练集, 共 91 幅图像. 将图像分别放缩到 0.75、1、1.25 三个不同的尺度得到 273 幅图像. 不同的颜色空间对图像分类、图像分割有一定的影响^[24], 但对图像重构方面影响较小. 为了公平起见, 本文采用与 ReconNet 和 DR²-Net 相同的颜色空间, 将 RGB 图像空间变换到 YCrCb 图像空间, 选取亮度通道, 对图像进行取块操作, 块大小为 33×33 , 取块步长为 14. 为了增加训练集中图像数量, 分块前对图像做翻转, 旋转等操作, 最终得到 128×5414 块图像块. 再对图像块进行随机投影, 将 33×33 的图像块向量化为 1089×1 维的向量. 本文采用 4 种不同的采样率对图像块进行采样, 分别是 0.25、0.1、0.04、0.01, 每一个图像块有 1089 个像素, 所以测量值 \mathbf{y}_i 的长度分别是 272、109、43、10. 训练过程中使用图 5 中




图 4 重构图像块修正前后误差的比较 (Barbara 图像)

Fig. 4 The comparison of the error of the reconstructed image block before and after refined (Barbara)



图 5 标准测试集图像

Fig. 5 Standard test set images

的图像作为测试集. 使用 Tensorflow^[25] 深度学习开源工具训练网络, 所有实验均在 Inter Core i5-7500 CPU, 主频 3.4 GHz, 内存 16 GB, 显卡 GTX 1080ti 平台下完成.

3.2 网络参数初始化

训练线性生成网络 $F^f(\cdot)$ 时, 使用均值为 0, 方差为 0.01 的高斯矩阵初始化权重, 偏置初始化为 0. 训练多尺度残差网络 $F^{msr}(\cdot)$ 时, 所有卷积层的权重, 使用 Xavier^[26] 初始化方法进行初始化, 偏置初始化为 0.

3.3 网络训练参数设置

网络分两步进行训练, 首先使用比较大的学习率训练子网络 $F^f(\cdot)$, 学习率为 0.001, 最大迭代次数为 1 000 000, 每训练 200 000 次学习率衰减为原来的 0.5 倍. 子网络 $F^f(\cdot)$ 训练完成后, 使用较小的学习率对整个网络进行训练, 迭代 120 轮, 学习率为 0.0001, 每训练 40 轮学习率衰减为原来的 0.5 倍. 使用 Adam^[21] 方法训练网络, 动量因子分别为 0.9 和 0.999. 图 6 为训练期间采样率为 0.10、0.25 时, 损失函数随迭代次数的衰减曲线. 图中损失函数的值随迭代次数的增加逐渐降低, 当迭代到 40 轮时, 学习率衰减为原来的 0.5 倍, 损失函数的值会骤降, 迭代到 80 轮时, 学习率继续衰减 0.5 倍, 损失函数的值变化较小, 随着迭代次数的增加, 曲线趋于平稳, 网络收敛.

4 实验结果

4.1 重构结果

本文与已有的五种算法进行比较, 这五种算法分别是 TVAL3^[27]、NLR-CS^[28]、D-AMP^[29]、ReconNet、DR²-Net. 前三种是基于迭代优化的算法, 后两种是基于深度学习的算法. 实验结果如表 1 所示, 在测量值没有噪声的情况下, 本文算法具有较好的重构效果. 图 7 显示, 本文提出的算法能够有效地重构出图像的细节, 在采样率较大时重构图像中含有的伪迹较少.

表 1 显示了 6 幅测试图像在不同算法不同测量率下的 PSNR 和图 5 中 11 幅测试图像的平均 PSNR. TVAL3、NLR-CS 和 D-AMP 使用文献 [16] 提供的结果, 表中 “w/o BM3D” 表示未使用 BM3D 去除块效应, “w/BM3D” 表示使用 BM3D 去除块

效应, “平均 PSNR” 表示图 5 中 11 幅图像的平均 PSNR. 从表 1 中看出, 多尺度残差网络 (MSR-Net) 的重构图像平均 PSNR 最高. 在较高的采样率下, 基于深度学习的算法 ReconNet 重构性能低于传统的优化迭代算法 TVAL3、NLR-CS、D-AMP. 但是本文算法和 DR²-Net 的重构性能优于上述三种算法, 相比于上述五种算法, 本文算法重构图像质量较好. 例如, 在 MR = 0.25 的情况下, 平均 PSNR 比 DR²-Net 高 0.82 dB, 高于 NLR-CS 算法 1.43 dB. 在较低采样率下, 传统的优化迭代算法 TVAL3、NLR-CS、D-AMP 基本不能够重构出有意义的图像, 但是基于深度学习的算法 ReconNet、DR²-Net、MSRNet 都能重构出图像的大致信息, 且本文算法性能优于 ReconNet 和 DR²-Net.

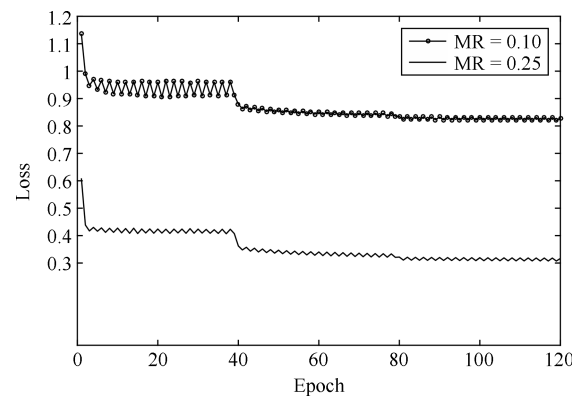


图 6 训练期间的损失

Fig. 6 The network losses in training phase

图像重构质量的评价也应该包含人的视觉效果. 结构相似指数 (Structural similarity index, SSIM) 是衡量两幅图像的相似度. SSIM 越接近于 1, 表示两幅图像越相似. 比较结果如表 2 所示, 本文算法的平均 SSIM 明显高于其他算法, 重构图像质量不仅 PSNR 值比较高, 且有较好的视觉效果.

图 8 显示了修正前后的 Barbara 图像, 从图中可以看出修正后的图像块效应明显减少, 与修正前图像相比细节更加清晰. 如表 3 所示, 修正后的重构图像 PSNR 和 SSIM 均有不同程度的提高, 有更好的视觉效果.

4.2 扩张卷积对图像重构性能的影响

扩张卷积能够增大网络的感受野, 本文算法中

表 1 6 幅测试图像在不同算法不同采样率下的 PSNR

Table 1 PSNR values in dB for six testing images by different algorithms at different measurement rates

图像	算法	MR = 0.25		MR = 0.10		MR = 0.04		MR = 0.01	
		w/o BM3D	w/BM3D	w/o BM3D	w/BM3D	w/o BM3D	w/BM3D	w/o BM3D	w/BM3D
Barbara	TVAL3	24.19	24.20	21.88	22.21	18.98	18.98	11.94	11.96
	NLR-CS	28.01	28.00	14.80	14.84	11.08	11.56	5.50	5.86
	D-AMP	25.08	25.96	21.23	21.23	16.37	16.37	5.48	5.48
	ReconNet	23.25	23.52	21.89	22.50	20.38	21.02	18.61	19.08
	DR ² -Net	25.77	25.99	22.69	22.82	20.70	21.30	18.65	19.10
	MSRNet	26.69	26.91	23.04	23.06	21.01	21.28	18.60	18.90
Boats	TVAL3	28.81	28.81	23.86	23.86	19.20	19.20	11.86	11.88
	NLR-CS	29.11	29.27	14.82	14.86	10.76	11.21	5.38	5.72
	D-AMP	29.26	29.26	21.95	21.95	16.01	16.01	5.34	5.34
	ReconNet	27.30	27.35	24.15	24.10	21.36	21.62	18.49	18.83
	DR ² -Net	30.09	30.30	25.58	25.90	22.11	22.50	18.67	18.95
	MSRNet	30.74	30.93	26.32	26.50	22.58	22.79	18.65	18.88
Flinstones	TVAL3	24.05	24.07	18.88	18.92	14.88	14.91	9.75	9.77
	NLR-CS	22.43	22.56	12.18	12.21	8.96	9.29	4.45	4.77
	D-AMP	25.02	24.45	16.94	16.82	12.93	13.09	4.33	4.34
	ReconNet	22.45	22.59	18.92	19.18	16.30	16.56	13.96	14.08
	DR ² -Net	26.19	26.77	21.09	21.46	16.93	17.05	14.01	14.18
	MSRNet	26.67	26.89	21.72	21.81	17.28	17.40	13.83	14.10
Lena	TVAL3	28.67	28.71	24.16	24.18	19.46	19.47	11.87	11.89
	NLR-CS	29.39	29.67	15.30	15.33	11.61	11.99	5.95	6.27
	D-AMP	28.00	27.41	22.51	22.47	16.52	16.86	5.73	5.96
	ReconNet	26.54	26.53	23.83	24.47	21.28	21.82	17.87	18.05
	DR ² -Net	29.42	29.63	25.39	25.77	22.13	22.73	17.97	18.40
	MSRNet	30.21	30.37	26.28	26.41	22.76	23.06	18.06	18.35
Monarch	TVAL3	27.77	27.77	21.16	21.16	16.73	16.73	11.09	11.11
	NLR-CS	25.91	26.06	14.59	14.67	11.62	11.97	6.38	6.71
	D-AMP	26.39	26.55	19.00	19.00	14.57	14.57	6.20	6.20
	ReconNet	24.31	25.06	21.10	21.51	18.19	18.32	15.39	15.49
	DR ² -Net	27.95	28.31	23.10	23.56	18.93	19.23	15.33	15.50
	MSRNet	28.90	29.04	23.98	24.17	19.26	19.48	15.41	15.61
Peppers	TVAL3	29.62	29.65	22.64	22.65	18.21	18.22	11.35	11.36
	NLR-CS	28.89	29.25	14.93	14.99	11.39	11.80	5.77	6.10
	D-AMP	29.84	28.58	21.39	21.37	16.13	16.46	5.79	5.85
	ReconNet	24.77	25.16	22.15	22.67	19.56	20.00	16.82	16.96
	DR ² -Net	28.49	29.10	23.73	24.28	20.32	20.78	16.90	17.11
	MSRNet	29.51	29.86	24.91	25.18	20.90	21.16	17.10	17.33
平均 PSNR	TVAL3	27.84	27.87	22.84	22.86	18.39	18.40	11.31	11.34
	NLR-CS	28.05	28.19	14.19	14.22	10.58	10.98	5.30	5.62
	D-AMP	28.17	27.67	21.14	21.09	15.49	15.67	5.19	5.23
	ReconNet	25.54	25.92	22.68	23.23	19.99	20.44	17.27	17.55
	DR ² -Net	28.66	29.06	24.32	24.71	20.80	21.29	17.44	17.80
	MSRNet	29.48	29.67	25.16	25.38	21.41	21.68	17.54	17.82




图 7 比较几种算法的重构性能 (第 1 行到第 3 行采样率 $MR = 0.25, 0.10, 0.04$)

Fig. 7 Comparison of reconstruction performance of various algorithms ($MR = 0.25, 0.10, 0.04$)

表 2 不同算法下 11 幅测试图像平均 SSIM

Table 2 Mean SSIM values for 11 testing images by different algorithms

算法	MR = 0.01	MR = 0.04	MR = 0.10	MR = 0.25
ReconNet	0.4083	0.5266	0.6416	0.7579
DR ² -Net	0.4291	0.5804	0.7174	0.8431
MSRNet	0.4535	0.6167	0.7598	0.8698



(a) 修正前 PSNR = 26.69 dB (a) PSNR = 26.69 dB before refined
(b) 修正后 PSNR = 27.53 dB (b) PSNR = 27.53 dB after refined

图 8 修正前后的重构图像对比 ($MR = 0.25$)

Fig. 8 The comparison of reconstructed images before and after refined ($MR = 0.25$)

所有的卷积层都使用扩张卷积. 为了比较使用扩张卷积的网络与普通卷积网络的重构性能, 本文

设计了一组对比实验, 训练两个网络, 即采用普通卷积的网络和采用扩张卷积的网络, 分别对 BSD500 数据集和图 5 中的 11 幅图像进行测试. 测试结果如表 4、5 所示, 在图 5 中测试集上, 当采样率为 0.25、0.10、0.04 和 0.01 时, 使用扩张卷积网络的重构图像平均 PSNR 分别高于普通卷积网络 0.43 dB、0.37 dB、0.18 dB 和 0.04 dB. 在 BSD500 测试集上, 使用扩张卷积网络的重构图像平均 PSNR 也都高于普通卷积网络. 结果表明, 使用扩张卷积的网络重构性能优于普通卷积网络.

4.3 时间复杂度

重构时间也是比较的重要标准之一. 基于深度学习的重构算法比传统的迭代算法快 100 多倍^[16], 所以只比较 MSRNet 和其他基于深度学习算法的重构时间. 为了公平起见, 表 6 只比较网络重构图像所消耗的时间. 如表 6 所示, 与 DR²-Net 相比, 本文算法重构时间较短. 与 ReconNet 相比, 重构时间基本相同, 但本文算法重构性能较好.

4.4 大数据集下的评估

为了验证本文算法在大测试集上的泛化能力, 比较 MSRNet、DR²-Net 和 ReconNet 在 BSD500 (该数据集包含 500 张图像) 上的重构性能.

表 3 MSRNet 重构图像修正后 11 幅测试图像的 PSNR (dB) 和 SSIM

Table 3 The PSNR (dB) and SSIM of 11 test images of refined MSRNet reconstruction

图像	MR = 0.25		MR = 0.10		MR = 0.04	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
Monarch	29.74	0.9189	24.40	0.8078	19.62	0.6400
Parrots	30.13	0.9054	25.15	0.8240	22.06	0.7311
Barbara	27.53	0.8553	23.28	0.6630	21.39	0.5524
Boats	31.63	0.8999	26.73	0.7753	22.86	0.6355
C-man	27.17	0.8433	23.33	0.7400	20.51	0.6378
Fingerprint	28.75	0.9280	23.18	0.7777	18.81	0.5212
Flinstones	27.77	0.8529	22.14	0.7114	17.46	0.4824
Foreman	35.85	0.9297	31.71	0.8740	26.97	0.7939
House	34.15	0.8891	29.55	0.8196	25.60	0.7443
Lena	30.95	0.9019	26.68	0.7965	23.16	0.6882
Peppers	30.67	0.8898	25.43	0.7811	21.28	0.6382
平均值	30.39	0.8922	25.59	0.7791	21.79	0.6423

表 4 不同卷积方式在图 5 的测试集中重构图像的平均 PSNR (dB)

Table 4 Mean PSNR in dB for testing set in Fig. 5 by different convolution

卷积形式	MR = 0.01	MR = 0.04	MR = 0.10	MR = 0.25
普通卷积	17.50	21.23	24.79	29.05
扩张卷积	17.54	21.41	25.16	29.48

表 5 不同卷积方式在 BSD500 测试集中重构图像平均 PSNR (dB)

Table 5 Mean PSNR in dB for BSD500 testing set by different convolution

算法	MR = 0.01	MR = 0.04	MR = 0.10	MR = 0.25
普通卷积	19.34	22.14	24.48	27.78
扩张卷积	19.35	22.25	24.73	27.93

表 6 重构一幅 256×256 图像的运行时间 (s)Table 6 Time (in seconds) for reconstruction a single 256×256 image

算法	MR = 0.01 (CPU/GPU)	MR = 0.04 (CPU/GPU)	MR = 0.10 (CPU/GPU)	MR = 0.25 (CPU/GPU)
ReconNet	0.5363/ 0.0107	0.5369/ 0.0100	0.5366/ 0.0101	0.5361/ 0.0105
DR ² -Net	1.2039/0.0317	1.2064/0.0317	1.2096/0.0314	1.2176/0.0326
MSRNet	0.4884 /0.0121	0.5172 /0.0124	0.5152 /0.0117	0.5206 /0.0126

表 7 不同算法在 BSD500 测试集的平均 PSNR (dB) 和平均 SSIM

Table 7 Mean PSNR in dB and SSIM values for BSD500 testing images by different algorithms

模型	MR = 0.01		MR = 0.04		MR = 0.10		MR = 0.25	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
ReconNet	19.17	0.4247	21.40	0.5149	23.28	0.6121	25.48	0.7241
DR ² -Net	19.34	0.4514	21.86	0.5501	24.26	0.6603	27.56	0.7961
MSRNet	19.35	0.4541	22.25	0.5696	24.73	0.6837	27.93	0.8121

MSRNet、DR²-Net 和 ReconNet 的模型参数都是基于相同训练集训练得到的. 如表 7 所示 (重构图像未经修正), 本文算法在 BSD500 测试集下也表现出较好的重构性能. 在采样率为 0.25、0.10、0.04 和 0.01 时, MSRNet 的重构图像平均 PSNR 和 SSIM 都高于 DR²-Net. 实验表明, 本文算法在大的测试集中也能表现出较好的重构性能.

4.5 网络的抗噪性能

对图像测量值添加四种不同水平的高斯噪声, 噪声强度 0.01、0.05、0.10、0.25. 使用的 MSRNet 模型是在无噪测量值下训练得到的. 如表 8、9 所示 (重构图像未经修正), 在采样率 MR = 0.25、0.10 时四种不同噪声强度下, 本文算法重构图像的平均 PSNR 均高于 ReconNet 和 DR²-Net, 尤其在 MR = 0.25, 噪声强度 $\sigma = 0.25$, 图 5 中的

表 8 比较 ReconNet、DR²-Net 和 MSRNet 三种算法对高斯噪声的鲁棒性 (图 5 中 11 幅测试图像)
Table 8 Comparison of robustness to Gaussian noise among of ReconNet, DR²-Net, MSRNet
(11 testing images in Fig. 5)

模型	MR = 0.25				MR = 0.10			
	$\sigma = 0.01$	$\sigma = 0.05$	$\sigma = 0.10$	$\sigma = 0.25$	$\sigma = 0.01$	$\sigma = 0.05$	$\sigma = 0.10$	$\sigma = 0.25$
ReconNet	25.44	23.81	20.81	14.15	22.63	21.64	19.54	14.17
DR ² -Net	28.49	25.63	21.45	14.32	24.17	22.70	20.04	14.54
MSRNet	29.28	26.50	22.63	18.46	25.06	23.56	21.11	15.46

表 9 比较 ReconNet、DR²-Net 和 MSRNet 三种算法对高斯噪声的鲁棒性 (BSD500 数据集)
Table 9 Comparison of robustness to Gaussian noise among of ReconNet, DR²-Net, MSRNet (BSD500 dataset)

模型	MR = 0.25				MR = 0.10			
	$\sigma = 0.01$	$\sigma = 0.05$	$\sigma = 0.10$	$\sigma = 0.25$	$\sigma = 0.01$	$\sigma = 0.05$	$\sigma = 0.10$	$\sigma = 0.25$
ReconNet	25.38	22.03	20.72	14.03	23.22	22.06	19.85	14.51
DR ² -Net	27.40	24.99	21.32	14.47	24.17	22.74	20.26	14.85
MSRNet	27.78	25.53	22.37	18.38	24.67	23.34	21.22	16.37

测试集上重构图像的平均 PSNR 比 ReconNet 和 DR²-Net 分别高 4.31 dB 和 4.14 dB. 在测试集 BSD500 上, 本文算法在不同噪声的强度下, 对图像的重构性能也优于 ReconNet 和 DR²-Net. 因此, 本文算法相比 ReconNet、DR²-Net 对噪声具有更好的鲁棒性.

5 结论

本文提出了一种基于深度学习的多尺度残差网络结构, 利用测量值通过网络重构图像. 网络引入多尺度卷积层用来学习图像中的多尺度信息, 重构网络中使用扩张卷积增大网络中的感受野从而重构出高质量的图像. 最后, 本文算法对网络重构图像进行了修正, 使得重构图像在测量矩阵上的投影更加接近测量值. 在常用的 11 幅测试图像和 BSD500 测试集的实验结果进一步表明了本文的算法相比于其他几种算法在图像重构质量和重构时间拥有更好的表现, 并且对噪声具有鲁棒性.


References

- 1 Donoho D L. Compressed sensing. *IEEE Transactions on Information Theory*, 2006, **52**(4): 1289–1306
- 2 Candes E J, Justin R J, Tao T. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information. *IEEE Transactions on Information Theory*, 2006, **52**(2): 489–509
- 3 Candes E J, Wakin M B. An introduction to compressive sampling. *IEEE Signal Processing Magazine*, 2008, **25**(2): 21–30
- 4 Ren Yue-Mei, Zhang Yan-Ning, Li Ying. Advances and perspective on compressed sensing and application on image processing. *Acta Automatica Sinica*, 2014, **40**(8): 1563–1575
(任越美, 张艳宁, 李映. 压缩感知及其图像处理应用研究进展与展望. *自动化学报*, 2014, **40**(8): 1563–1575)
- 5 Tropp J A, Gilbert A C. Signal recovery from random measurements via orthogonal matching pursuit. *IEEE Transactions on Information Theory*, 2007, **53**(12): 4655–4666
- 6 Blumensath T, Davies M E. Iterative hard thresholding for compressed sensing. *Applied and Computational Harmonic Analysis*, 2009, **27**(3): 265–274
- 7 Xiao Y H, Yang J F, Yuan X M. Alternating algorithms for total variation image reconstruction from random projections. *Inverse Problems and Imaging*, 2012, **6**(3): 547–563
- 8 Dong W S, Shi G M, Li X, Zhang L, Wu X L. Image reconstruction with locally adaptive sparsity and nonlocal robust regularization. *Signal Processing: Image Communication*, 2012, **27**(10): 1109–1122
- 9 Eldar Y C, Kuppinger P, Bolcskei H. Block-sparse signals: uncertainty relations and efficient recovery. *IEEE Transactions on Signal Processing*, 2010, **58**(6): 3042–3054
- 10 Lian Qiu-Sheng, Chen Shu-Zhen. Image reconstruction for compressed sensing based on the combined sparse image representation. *Acta Automatica Sinica*, 2010, **36**(3): 385–391
(练秋生, 陈书贞. 基于混合基稀疏图像表示的压缩传感图像重构. *自动化学报*, 2010, **36**(3): 385–391)
- 11 Shen Yan-Fei, Li Jin-Tao, Zhu Zhen-Min, Zhang Yong-Dong, Dai Feng. Image reconstruction algorithm of compressed sensing based on nonlocal similarity model. *Acta Automatica Sinica*, 2015, **41**(2): 261–272
(沈燕飞, 李锦涛, 朱珍民, 张勇东, 代锋. 基于非局部相似模型的压缩感知图像恢复算法. *自动化学报*, 2015, **41**(2): 261–272)
- 12 Dong C, Loy C C, He K M, Tang X O. Image super-resolution using deep convolutional networks. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2016, **38**(2): 295–307


- 13 Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation. In: Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA: IEEE, 2015. 3431–3440
- 14 Zhang K, Zuo W M, Chen Y J, Meng D Y, Zhang L. Beyond a gaussian denoiser: residual learning of deep CNN for image denoising. *IEEE Transactions on Image Processing*, 2017, **26**(7): 3142–3155
- 15 Mousavi A, Patel A B, Baraniuk R G. A deep learning approach to structured signal recovery. In: Proceedings of the 53rd Annual Allerton Conference on Communication, Control, and Computing. Monticello, IL, USA: IEEE, 2015. 1336–1343
- 16 Kulkarni K, Lohit S, Turaga P, Kerviche R, Ashok A. ReconNet: non-iterative reconstruction of images from compressively sensed measurements. In: Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016. 449–458
- 17 He K M, Zhang X Y, Ren S Q, Sun J. Deep residual learning for image recognition. In: Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016. 770–778
- 18 Yao H T, Dai F, Zhang D M, Ma Y K, Zhang S L, Zhang Y D, et al. DR²-Net: deep residual reconstruction network for image compressive sensing [Online], available: <https://arxiv.org/pdf/1702.05743.pdf>, July 6, 2017.
- 19 Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions [Online], available: <https://arxiv.org/abs/1511.07122>, April 30, 2016.
- 20 Gan L. Block compressed sensing of natural images. In: Proceedings of the 15th International Conference on Digital Signal Processing. Cardiff, UK: IEEE, 2007. 403–406
- 21 Kingma D P, Ba J L. Adam: a method for stochastic optimization. In: Proceedings of the 3rd International Conference for Learning Representations. San Diego, USA: Computer Science, 2014.
- 22 Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 2017, **60**(6): 84–90
- 23 Dabov K, Foi A, Katkovnik V, Egiazarian K. Image denoising by sparse 3-D transform-domain collaborative filtering. *IEEE Transactions on Image Processing*, 2007, **16**(8): 2080–2095
- 24 Wu J S, Jiang L Y, Han X, Senhadji L, Shu H Z. Performance evaluation of wavelet scattering network in image texture classification in various color spaces. *Journal of Southeast University*, 2015, **31**(1): 46–50
- 25 Abadi M, Agarwal A, Barham P, Brevdo E, Chen Z F, Citro C, et al. TensorFlow: large-scale machine learning on heterogeneous distributed systems [Online], available: <http://tensorflow.org>, September 19, 2017.
- 26 Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks. In: Proceedings of the 13th International Conference on Artificial Intelligence and Statistics. Sardinia, Italy: JMLR, 2010. 249–256
- 27 Li C B, Yin W T, Jiang H, Zhang Y. An efficient augmented lagrangian method with applications to total variation minimization. *Computational Optimization & Applications*, 2013, **56**(3): 507–530
- 28 Dong W S, Shi G M, Li X, Ma Y, Huang F. Compressive sensing via nonlocal low-rank regularization. *IEEE Transactions on Image Processing*, 2014, **23**(8): 3618–3632
- 29 Metzler C A, Maleki A, Baraniuk R G. From denoising to compressed sensing. *IEEE Transactions on Information Theory*, 2016, **62**(9): 5117–5144




练秋生 燕山大学信息科学与工程学院教授。主要研究方向为图像处理, 稀疏表示, 压缩感知及深度学习。本文通信作者。
E-mail: lianqs@ysu.edu.cn
(**LIAN Qiu-Sheng** Professor at the School of Information Science and Engineering, Yanshan University. His research interest covers image processing, sparse representation, compressed sensing and deep learning. Corresponding author of this paper.)



富利鹏 燕山大学信息科学与工程学院硕士研究生。主要研究方向为图像压缩感知, 深度学习。
E-mail: fulipeng87@gmail.com
(**FU Li-Peng** Master student at the School of Information Science and Engineering, Yanshan University. His research interest covers image compressed sensing and deep learning.)



陈书贞 燕山大学信息科学与工程学院副教授。主要研究方向为图像处理, 压缩感知及生物识别。
E-mail: chen_sz818@163.com
(**CHEN Shu-Zhen** Associate professor at the School of Information Science and Engineering, Yanshan University. Her research interest covers image processing, compressed sensing and biometrics recognition.)



石保顺 燕山大学信息科学与工程学院博士研究生。主要研究方向为图像处理, 压缩感知及深度学习。
E-mail: shibaoshun@ysu.edu.cn
(**SHI Bao-Shun** Ph.D. candidate at the School of Information Science and Engineering, Yanshan University. His research interest covers image processing, compressed sensing and deep learning.)