

文章编号: 2095-4980(2021)06-1081-05

## 基于自适应非线性网络的压缩感知重构算法

郭媛, 姜津霖\*, 陈炜

(齐齐哈尔大学 计算机与控制工程学院, 黑龙江 齐齐哈尔 161006)

**摘要:** 针对传统压缩感知(CS)进行复杂的迭代运算, 重构时间长且质量差等问题, 结合深度学习学习方法, 提出一种自适应非线性测量卷积神经网络(NMECNN)的压缩感知重构算法。本算法将图像整体宽高进行压缩, 作为测量网络替代传统的随机测量矩阵进行图像重建, 同时利用多个扩张卷积层和上采样 PixelShuffle 方法获取图像不同尺度细节信息。通过与其他文献进行实验对比, 本算法在不同采样率下, 平均峰值信噪比(PSNR)分别高于 MSRNNets 算法 1 dB, 0.7 dB, 0.82 dB, 1.61 dB; 结构相似性(SSIM)值分别高 0.03, 0.04, 0.24, 0.10 个单位, 重构时间在 CPU 上比 MSRNet 算法快 0.175 s, 0.399 s, 0.41 s, 0.396 s。最后通过大数据集与噪声实验, 验证了本算法图像重构质量明显提高, 重构时间大幅缩短, 具有很强的抵抗噪声攻击能力。

**关键词:** 压缩感知; 图像重构; 自适应非线性网络; 深度学习; 扩张卷积

中图分类号: TN713

文献标志码: A

doi: 10.11805/TKYDA2020376

## Compressed Sensing reconstruction algorithm based on depth learning adaptive nonlinear networks

GUO Yuan, JIANG Jinlin\*, CHEN Wei

(School of Computer and Control Engineering, Qiqihar University, Qiqihar Heilongjiang 161006, China)

**Abstract:** Aiming at the complicated iterative operations of traditional Compressed Sensing(CS), long reconstruction time and poor quality, a compressed sensing reconstruction algorithm for Non-linear Measurement Convolutional Neural Network(NMECNN) is proposed by combining the deep learning method. This algorithm compresses the overall width and height of the image as a measurement network to replace the traditional random measurement matrix for image reconstruction. At the same time, it uses multiple expanded convolutional layers and upsampling PixelShuffle methods to obtain detailed information of different scales of the image. Through experimental comparison with other documents, the average Peak Signal to Noise Ratio(PSNR) values of this algorithm at different sampling rates are higher than that of MSRNNets algorithm by 1 dB, 0.7 dB, 0.82 dB, 1.61 dB, and the Structural Similarity(SSIM) values are higher by 0.03, 0.04, 0.24, 0.10 units. The reconstruction time in the CPU is less than that of the MSRNet algorithm by 0.175 s, 0.399 s, 0.41 s, 0.396 s, respectively. Through big data sets and noise experiments, it is verified that the image reconstruction quality of this algorithm is significantly improved, the reconstruction time is greatly shortened, and it has a strong ability to resist noise attacks.

**Keywords:** Compressed Sensing; image reconstruction; adaptive nonlinear network; deep learning; dilated convolution

Candes 等提出的压缩感知(CS)突破了传统奈奎斯特采样理论限制: 当信号在某个域是稀疏的, 采用低于两倍带宽的采样速率可使原始信号恢复<sup>[1-2]</sup>。目前传统压缩感知分为贪婪算法类和基追踪类等<sup>[3-4]</sup>, 这些算法迭代复杂且时间长, 最严重是在低采样率下图片无法还原。目标检测图像重建等日益成为学者们讨论的对象<sup>[5-7]</sup>。深度学习神经网络<sup>[8]</sup>在计算机视觉中应用广泛, 神经网络有强大的学习能力, 可以避免传统方法复杂的计算, 实现优

收稿日期: 2020-08-09; 修回日期: 2020-12-03

基金项目: 国家自然科学基金资助项目(61872204); 黑龙江省自然科学基金项目(LH2021F056); 研究生创新科研项目(YJSCX2020050)

\*通信作者: 姜津霖 1002723875@qq.com

秀的重建结果。文献[9]提出线性堆叠式降噪自动编码器(Stacked Denoising Autoencoder, SDA)与非线性测量 SDA 的 CS 信号重构性; Kulkarni 提出 ReconNet<sup>[10]</sup>网络: 先由一个线性网络得到初步的重构图像, 再由超分辨率卷积神经网络<sup>[6]</sup>(Super-Resolution Convolutional Neural Network, SRCNN)模型提高重构质量, 但该网络在重构不规则的结构和纹理图片时, 重构质量较低; Yao 提出了 DR<sup>2</sup>-Net<sup>[11]</sup>, 添加 4 个残差块进行重构, 解决了重构质量差问题, 但设计的网络较多, 重构时间较长; 文献[12]中, 学者提出基于多尺度残差网络的重建算法 MSRNet(Multi-Scale Residual Reconstruction Network), 该算法重构图像的结果与前面两种算法相比, 质量有很大提升, 但依然比 ReconNet 网络重构耗时长。

本文设计的重构网络, 首先运用自适应非线性测量网络获取高质量的图片特征, 然后利用扩张卷积和上采样方法提高图片重构质量, 最后通过重构网络将图片复原。通过实验比较, 本文算法的平均 PSNR 显著提高, 重构时间与之前的算法相比, 大大缩短, 有很强的实用性。

### 1 基本原理

#### 1.1 压缩感知原理

在 CS 理论中, 如果信号  $x \in \mathbf{R}^n$  稀疏, 则  $x$  的压缩观测值  $y$  可以表示为  $y = \Phi x$ , 其中  $\Phi \in \mathbf{R}^{m \times n}$  是测量矩阵, 该表达式是欠定方程, 有无数个解。考虑到  $x$  的稀疏性, 假设  $\Psi$  是由正交稀疏基组成的矩阵或是稀疏字典,  $\alpha$  是稀疏系数向量, 则  $x$  可以表示为  $x = \Psi\alpha$ , 最终可以得到压缩感知公式:

$$y = \Phi x = \Phi \Psi \alpha = D \alpha \quad (D = \Phi \Psi) \quad (1)$$

采用  $l_1$  范数最小化, 通过  $l_1$  范数近似  $l_0$  范数, 可以将式 (1) 转化成一个线性规划问题求解。

#### 1.2 网络设计原理

ReconNet, DR<sup>2</sup>-Net 和 MSRNet 都是通过随机高斯测量矩阵  $\Phi$  对图像块  $x_i$  降维得到测量值, 测量网络通过卷积层先增维得到足够的特征再降维。从图 1 可以看出, 测量矩阵常用方法是对图像每列进行采样率(Measurement Result, MR)为 0.25 的采样后再拼接, 得到随机高斯测量矩阵(256×64), 发现图片会有明显的模糊情况, 图片基本细节丢失, 影响图像重构质量。而本文设计的测量网络是将一张 256×256 图片整体以 MR=0.25 采样率采样后得到 131×124 矩阵, 测量网络能得到高质量的矩阵, 这为重构提供了有利条件。

利用上采样方法(PixelShuffle)<sup>[13]</sup>和扩张卷积<sup>[12]</sup>, 得到最优重构图像。文献[14]设计的 PixelShuffle 方法是将一个  $r^2 C \times H \times W$  的矩阵, 通过 Sub-pixel 操作将其变为  $C \times rH \times rW$  的矩阵, 该方法可以将低频特征转换为高频特征, 同时处理时间短。常规卷积网络利用大尺寸卷积核, 引入多个卷积层数和池化层来增加感受野范围, 这些方法计算复杂, 容易过拟合, 重构时间长且质量差。图 2 将 3×3 卷积核扩张成 5×5, 参数不变, 却获得了更大范围的感受野, 减少了计算成本。综上所述, 本文设计的自适应非线性测量卷积神经网络(NMECNN)利用不同大小扩张卷积核, 在重构网络中提取图像中不同尺度的特征细节, 再用 PixelShuffle 还原图像大小, 既提高了重构质量, 又减少了重构时间。本文设计的完整网络如图 3 所示, 首先使用测量网络得到图片高质量特征, 然后将原图块  $x_i$  通过采样网络  $F_s(\cdot)$  得到测量值  $y_i$ , 重构网络  $F_{mus}(\cdot)$  使用 3×3 卷积核、PixelShuffle 和扩张卷积重构出图像块  $x_i'$ , 最后通过拼接还原整个图像。

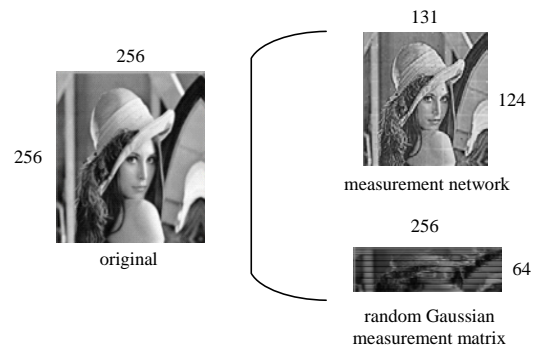


Fig.1 Comparison of effect between measurement network and random Gaussian measurement

图 1 测量网络与随机高斯测量矩阵的效果对比




Fig.2 Dilate convolution  
图 2 扩张卷积




Fig.3 Measurement network and reconstruction network

图 3 测量网络与重构网络

## 2 训练网络

本文训练集对 91 张自然风景图像进行 33×33 的块分割处理,取步长 14,使用图 4 所示的 11 张常用图像进行实验测试。训练时分别使用 0.25,0.1,0.04,0.01 采样率对图像进行压缩处理。使用均方误差作为损失函数进行网络模型训练。初始学习率设定为 0.001,对测试网络与重构网络进行训练。利用 Adam 方法,设置最大训练次数为 1 000 000,每训练 200 000 次,学习率衰减为原来的 0.5 倍。同时在测量值上添加强度  $\sigma=0.05$  的高斯噪声,提高对噪声的抗噪能力。网络通过 Pytorch 框架进行搭建,并在 Inter Core i5-7500 CPU 平台下进行实验对比。



Fig.4 Test images  
图 4 本文使用的 11 幅测试图像

## 3 实验与分析

### 3.1 重构结果

峰值信噪比(PSNR)是对比重构图像质量优劣的重要评价指标;结构相似性(SSIM)是比较原始图像与处理后图像的相似程度,理想值为 1。本文与已有的 5 种算法进行对比, NLR-CS<sup>[15]</sup>,D-AMP<sup>[14]</sup>属于传统迭代算法, ReconNet,DR<sup>2</sup>-Net,MSRNet 是深度学习算法。表 1 是重构图像在不同算法、不同测量率下的平均 PSNR 与 SSIM 值。

从表 1 中可看出,本文算法的实验结果数值最高。在  $MR=0.25$  时,平均 PSNR 比 MSRNet 算法高 1.18 dB,比 DR<sup>2</sup>-Net 算法高 2.00 dB。低采样率时,传统算法一般无法重构出完整图像,但深度学习的算法都能重构出图像的信息,且本文算法平均 PSNR 与其他 3 种算法相比也是最高的。SSIM 代表两幅图像的相似程度,本文算法平均 SSIM 明显高于其他算法,并在  $MR=0.25$  时,SSIM 可以达到 0.9 以上,说明重构图像的质量很高,与原图相似度极高,具有很好的实用性与还原性。

图 5 为不同算法重构性能对比图。通过算法 ReconNet、DR<sup>2</sup>-Net 重构的图像会有明显伪迹,图像整体比较模糊;MSRNet 算法在之前的基础上已有很大改善,但重构图像在放大时明显看出很多细节没有很好地重构出来;而本文算法重构出的图像在大采样率下放大某一处细节,能清楚还原,小采样率下也比其他 3 种算法重构出来的更加精细,细节处理得也好。

### 3.2 重构时间

与其他深度学习算法相比,本文算法在运行时间上明显少于其他算法的运行时间,如表 2 所示。这说明该算

表 1 测试图像在不同算法下的 PSNR 与 SSIM 对比

Table1 Comparison of PSNR and SSIM of test images under different algorithms

original	algorithm	MR=0.25	MR=0.10	MR=0.04	MR=0.01
Lena	NLR-CS	29.39	15.30	11.61	5.95
	D-AMP	28.00	22.51	16.52	5.73
	ReconNet	26.54	23.83	21.28	17.87
	DR <sup>2</sup> -Net	29.42	25.39	22.13	17.97
	MSRNet	30.21	26.28	22.76	18.06
	this proposed	<b>31.94</b>	<b>27.53</b>	<b>24.99</b>	<b>21.55</b>
Monarch	NLR-CS	25.91	14.59	11.62	6.38
	D-AMP	26.39	19.00	14.57	6.20
	ReconNet	24.31	21.10	18.19	15.39
	DR <sup>2</sup> -Net	27.95	23.10	18.93	15.33
	MSRNet	28.90	23.98	19.26	15.41
	this proposed	<b>30.38</b>	<b>24.54</b>	<b>20.67</b>	<b>17.33</b>
average PSNR	NLR-CS	28.05	14.19	10.58	5.30
	D-AMP	28.17	21.14	15.49	5.19
	ReconNet	25.54	22.68	19.99	17.27
	DR <sup>2</sup> -Net	28.66	24.32	20.80	17.44
	MSRNet	29.48	25.16	21.41	17.54
	this proposed	<b>30.66</b>	<b>26.56</b>	<b>23.65</b>	<b>20.54</b>
average SSIM	ReconNet	0.7579	0.6416	0.5266	0.4083
	DR <sup>2</sup> -Net	0.8431	0.7174	0.5804	0.4291
	MSRNet	0.8698	0.7598	0.4535	0.4535
	this proposed	<b>0.9069</b>	<b>0.8063</b>	<b>0.6960</b>	<b>0.5603</b>

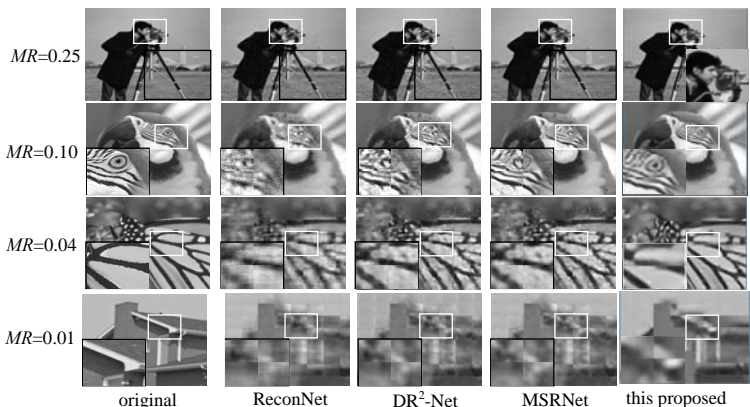


Fig.5 Reconstruction performance of different algorithms  
图 5 不同算法的重构性能

法不仅重构出来的性能好，重构时间也明显比其他算法少。实验过程均在 Pycharm+ Pytorch 和 Interi5-7500 CPU 配置下完成。

### 3.3 泛化能力

为验证本文算法在大测试集上同样有很好的适用性，实验在数据集 BSD500(共 500 张图片)上与其他算法作比较。如表 3 所示，本文算法在不同采样率下的平均 PSNR 和 SSIM 都明显高于其他算法。因此本文算法在大测试集上也表现出很好的重构性能，且与其他算法相比，本文平均 PSNR 比 MSRNet 高 1 dB,0.7 dB, 0.82dB,1.61 dB，SSIM 也高出 0.4,0.3,0.2,0.3 个单位。

表 2 重构 256×256 图像的运行时间(单位: s)

Table2 Operation time of reconstructing a 256×256 image(unit:s)

algorithm	MR=0.25	MR=0.10	MR=0.04	MR=0.01
ReconNet	0.536 1	0.536 6	0.536 9	0.536 3
DR <sup>2</sup> -Net	1.217 6	1.209 6	1.206 4	1.203 9
MSRNet	0.520 6	0.515 2	0.517 2	0.488 4
this proposed	<b>0.145 1</b>	<b>0.115 4</b>	<b>0.107 2</b>	<b>0.092 4</b>

表 3 各算法 BSD500 上的平均 PSNR 和 SSIM

Table3 Average PSNR and SSIM of each algorithm on data set BSD500

algorithm	MR=0.25		MR=0.10		MR=0.04		MR=0.01	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
ReconNet	25.48	0.724 1	23.28	0.612 1	21.40	0.514 9	19.17	0.424 7
DR <sup>2</sup> -Net	27.56	0.796 1	24.26	0.660 3	21.86	0.550 1	19.34	0.451 4
MSRNet	27.93	0.812 1	24.73	0.683 7	22.25	0.569 6	19.36	0.454 1
this proposed	<b>28.94</b>	<b>0.859 3</b>	<b>25.43</b>	<b>0.712 8</b>	<b>23.07</b>	<b>0.585 2</b>	<b>20.97</b>	<b>0.483 8</b>

### 3.4 鲁棒性分析

如图 6~图 7 所示，在采样率 MR=0.25,0.10 时，分别添加 4 种不同强度的高斯噪声和椒盐噪声(分别为 0.01,0.05, 0.10,0.25)。通过 4 种算法的折线图对比可以看出，本文算法的平均 PSNR 整体上高于其他 3 种算法。在 BSD500 的测试集下，平均 PSNR 更是比其他算法都高。因此，实验表明，整体上本文算法对噪声有很好的鲁棒性能，与其他算法相比，有较大优势。




Fig.6 Robustness analysis of each algorithm to Gaussian noise (11 test images/dataset BSD500)

图 6 各算法对高斯噪声的鲁棒性分析(11 幅测试图像/数据集 BSD500)




Fig.7 Robustness of each algorithm to salt and pepper noise (11 test images/dataset BSD500)

图 7 各算法对椒盐噪声的鲁棒性(11 幅测试图像/数据集 BSD500)

采样率 MR=0.25 时，添加 4 种噪声强度的重构图像如图 8 所示。ReconNet,DR<sup>2</sup>-Net,MSRNet 算法对椒盐抗噪性很差，尤其当噪声强度  $\sigma=0.01$  时，图像开始出现条纹模糊不清； $\sigma=0.10$  时，重构的图像已无法辨认出原来样子；使用本文算法重构的图像清晰，当噪声强度  $\sigma=0.10$  时，图像只是出现黑白点，图像轮廓还是非常清楚。

## 4 结论

本文提出一种基于深度学习的 NMECNN 架构,对常用测试图像和数据集 BSD500 进行实验与对比。NMECNN 算法将随机测量矩阵替换为测量网络,在性能上可优于对比文献:4 种不同的采样率下,平均 PSNR 可以提高 1 dB,0.7 dB,0.82 dB,1.61 dB;重构图片质量明显提高;重构时间也比之前最好的 MSRNet 算法快 0.175 5 s,0.399 8 s,0.41 s,0.396 s。重构网络中引入 PixelShuffle 和扩张卷积,因此在添加高斯噪声和椒盐噪声时重构图像也会有很好的鲁棒性,图像重构质量大大提高。

### 参考文献:

- [ 1 ] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006,52(4):1289–1306.
- [ 2 ] CANDES E J,WAKIN M B. An introduction to compressive sampling[J]. IEEE Signal Processing Magazine,2008,25(2):21–30.
- [ 3 ] ZHANG C,LIU Y,WU Y. On quantile regression in reproducing kernel Hilbert spaces with the data sparsity constraint[J]. The Journal of Machine Learning Research, 2016,17(1):1374–1418.
- [ 4 ] BELAGIANNIS V,AMIN S,ANDRILUKA M,et al. 3D pictorial structures for multiple human pose estimation[C]// 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus,OH,USA:IEEE, 2014:1669–1676.
- [ 5 ] KRIZHEVSKY A,SUTSKEVER I,HINTON G E. ImageNet classification with deep Convolutional Neural Networks[C]// Proceedings of the 25th International Conference on Neural Information Processing Systems. [S.l.]:ACM, 2017:1097–1105.
- [ 6 ] SVOBODA P,HRADIS M,BARINA D,et al. Compression artifacts removal using Convolutional Neural Networks[J]. Journal of WSCG, 2016,24(2):63–72.
- [ 7 ] DONG C,LOY C C,HE K,et al. Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016,38(2):295–307. doi:10.1109/TPAMI.2015.2439281.
- [ 8 ] 沈志伟,杨晓敏,吴伟,等. 自适应半耦合稀疏字典学习算法[J]. 太赫兹科学与电子信息学报, 2018,16(3):529–534. (SHEN Zhiwei,YANG Xiaomin,WU Wei,et al. Adaptive semi-coupled sparse dictionary learning algorithm[J]. Journal of Terahertz Science and Electronic Information Technology, 2018,16(3):529–534.) doi:10.11805/TKYDA201803.0522.
- [ 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(Allerton). Monticello IL,USA:IEEE, 2015:1336–1343.
- [ 10 ] 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). Las Vegas,NV,US:IEEE, 2016:449–458.
- [ 11 ] YAO H,DAI F,ZHANG D,et al. DR<sup>2</sup>-Net:deep residual reconstruction network for image Compressive Sensing[J]. Neurocomputing, 2017(359):483–493.
- [ 12 ] 练秋生,富利鹏,陈书贞,等. 基于多尺度残差网络的压缩感知重构算法[J]. 自动化学报, 2019,45(11):2082–2091. (LIAN Qiusheng,FU Lipeng,CHEN Shuzhen,et al. A compressed sensing algorithm based on multi-scale residual reconstruction network[J]. Acta Automatica Sinica, 2019,45(11):2082–2091.) doi:10.16383/j.aas.c170546.
- [ 13 ] SHI W,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). Las Vegas, NV,USA:IEEE, 2016:1874–1883.
- [ 14 ] METZLER C A,MALEKI A,BARANIUK R G. From denoising to Compressed Sensing[J]. IEEE Transactions on Information Theory, 2016,62(9):5117–5144. doi:10.1109/TIT.2016.2556683.
- [ 15 ] DONG W,SHI G,LI X,et al. Compressive Sensing via nonlocal low-rank regularization[J]. IEEE Transactions on Image Processing, 2014,23(8):3618–3632. doi:10.1109/TIP.2014.2329449.

### 作者简介:

郭 媛(1974–),女,黑龙江省齐齐哈尔市人,博士,教授,主要研究方向为光学图像处理及加密.email:Guoyuan171@126.com.

陈 炜(1992–),男,江苏省泰州市人,在读硕士研究生,主要研究方向为深度学习及图像处理.




Fig.8 Reconstruction comparison of each algorithm after adding salt and pepper noise

图 8 各算法添加椒盐噪声后的重构比较

姜津霖(1996–),男,石家庄市人,在读硕士研究生,主要研究方向为图像处理及深度学习.