



(12) 发明专利申请

(10) 申请公布号 CN 113516601 A

(43) 申请公布日 2021.10.19

(21) 申请号 202110669817.8

(22) 申请日 2021.06.17

(71) 申请人 西南大学

地址 400715 重庆市北碚区天生路2号

(72) 发明人 王建军 谢亚红 黄国钧 王洪荣  
刘晨

(74) 专利代理机构 池州优佐知识产权代理事务  
所(普通合伙) 34198

代理人 袁辉志

(51) Int. Cl.

G06T 5/00 (2006.01)

G06N 3/04 (2006.01)

G06N 3/08 (2006.01)

权利要求书6页 说明书16页 附图5页

(54) 发明名称

基于深度卷积神经网络与压缩感知的图像  
恢复技术

(57) 摘要

本发明公开了基于深度卷积神经网络与压缩感知的图像恢复技术,包括以下步骤:步骤1,全卷压缩感知网络设计:其中全卷压缩感知网络设计包括FCNN-CS的测量阶段;步骤2,数值实验:其中数值实验包括训练设置、重建结果的评价指标、在灰度图上的实验结果对比及讨论和在彩色图上的实验结果对比及讨论。本发明通过融合深度卷积神经网络与压缩感知的图像恢复研究,即在压缩感知恢复算法的指导下设计的深度卷积神经网络用于完成图像压缩和重建任务。一方面,相比于传统的线性压缩方式,采用基于学习的卷积测量的压缩方法更有利于保留图像的结构信息和设计出自适应的测量矩阵设计,另一方面,实现了基于稀疏编码的压缩感知恢复算法指导下的恢复网络设计。

1. 基于深度卷积神经网络与压缩感知的图像恢复技术,其特征在于,包括以下步骤:

步骤1,全卷压缩感知网络设计:其中全卷压缩感知网络设计包括FCNN-CS的测量阶段、多通道卷积测量的块RIP条件、FCNN-CS的重建阶段和联合损失函数;

在FCNN-CS的测量阶段,假设输入图像的大小为 $N \times N \times c$ ,其中 $c$ 表示通道数,取值为1或3;然后用大小为 $c \times B \times B \times c_0$ 的滤波器获

得压缩测量 $Y$ ,测量过程可以表示为: $Y=W*X$  (1.1),其中卷积步长为 $m$ ,测量 $Y$ 的维度为 $M \times M \times c_0$ , $M=\lfloor \frac{N-B}{m} \rfloor + 1$ ,记测量率为 $MR_s$ ,则可以由下式求得,

$$MR_s = \frac{c_0 \times M^2}{c \times N^2} = \frac{c_0 (\lfloor \frac{N-B}{m} \rfloor + 1)^2}{c \times N^2} \quad (1.2);$$

(Learned Convolutional Measurement, LCM) 过程的分解,卷积测量利用卷积滤波器 $W$ 实现了从原图 $X \in \mathbb{R}^{N \times N}$ 到压缩测量 $Y \in \mathbb{R}^{M \times M}$  ( $M < N$ ),该测量过程可以表示为: $Y=W*X$  (1.3),其中滤波器 $W \in \mathbb{R}^{B \times B}$ 中的系数为 $W=[w_1, w_2, \dots, w_B]$ , $w_i=[w_{1i}, w_{2i}, \dots, w_{Bi}]^T$ 。图像的卷积运算其实是基于图像局部块的运算特别地,我们定义一个块提取算子 $P_{ij}(\cdot)$ 来从整个图像 $X$ 上获取相应的图像块 $X^{ij}$ : $X^{ij}=P_{ij}(X)$ ,其中 $X^{ij} \in \mathbb{R}^{B \times B}$ ;方程(1.3)可以按像素点写为:

$$y_{ij} = W * P_{ij}(X), 0 < i, j \leq \lfloor \frac{N-B}{m} \rfloor + 1 \quad (1.4)$$

其中 $m$ 为卷积测量时的步长;此外,我们再定义两种拉伸算子 $Sc(\cdot)$ 和 $Sr(\cdot)$ ,如图1.4所示; $Sc(\cdot)$ 为列拉伸算子,它将矩阵按列重新排列为一个向量,即 $x_{ij} \text{ vect} = Sc(X^{ij})$ ,其中 $x_{ij} \text{ vect} \in \mathbb{R}^{B^2}$ ;  $Sr(\cdot)$ 为行拉伸算子,同理,它将矩阵按行重新排列为一个向量,即 $y^T = S_r(Y)$ ,其中 $y \in \mathbb{R}^{M^2}$ ;

多通道卷积测量的块RIP条件:(块RIP)对任意块长为 $c$ 的稀疏向量 $x$ ,测量矩阵 $D$ 满足 $k$ 阶块RIP条件,如果有下式成立:

$$(1 - \delta_d) \|x\|_2^2 \leq \|Dx\|_2^2 \leq (1 + \delta_d) \|x\|_2^2 \quad (1.6)$$

其中 $\delta_d$  ( $0 < \delta_d < 1$ ) 的下确界(定义为 $\delta_{dk}$ )称为观测矩阵的的块有限等距常数;

测量矩阵 $D$ 以级联块的方式表示:

$$D = \begin{pmatrix} D_{1,1}, \dots, D_{1,d} & D_{1,d+1}, \dots, D_{1,2d} & \dots & D_{1,N-d+1}, \dots, D_{1,N} \\ T[\tilde{y}_1] & T[\tilde{y}_2] & \dots & T[\tilde{y}_c] \\ \vdots & \vdots & \ddots & \vdots \\ D_{c_0,1}, \dots, D_{c_0,d} & D_{c_0,d+1}, \dots, D_{c_0,2d} & \dots & D_{c_0,N-d+1}, \dots, D_{c_0,N} \\ T[\tilde{c}_01] & T[\tilde{c}_02] & \dots & T[\tilde{c}_0c] \end{pmatrix} \quad (1.7);$$

如图1.6所示,其中 $T[ij]$  ( $i \in \{1, \dots, c_0\}$ ,  $j \in \{1, \dots, c\}$ ) 是矩阵 $D$ 的第 $ij$ 块;对于任意的块列索引集合 $\mathcal{I} = \{l_1, \dots, l_i\} \subseteq \{1, \dots, c_0\}$ ,块行索引集合 $\mathcal{J} = \{r_1, \dots, r_i\} \subseteq \{1, \dots, c\}$ , $|\mathcal{I}|$ 和 $|\mathcal{J}|$ 分别表示集合 $\mathcal{I}$ 和 $\mathcal{J}$ 的长度;矩阵 $D$ 满足 $k$ 阶块RIP条件,如果对任意的索引集合 $\mathcal{I} \subseteq \{1, \dots, c_0\}$ ,  $\mathcal{J} \subseteq \{1, \dots, c\}$ ,且 $|\mathcal{I}| * |\mathcal{J}| \leq k$ ,满足下式

$$(1 - \delta_d) \|x_{\mathcal{J}}\|_2^2 \leq \|D_{\mathcal{I},\mathcal{J}}x_{\mathcal{J}}\|_2^2 \leq (1 + \delta_d) \|x_{\mathcal{J}}\|_2^2 \quad (1.8)$$

等价于

$$(1 - \delta_d)_{j \in \mathcal{J}_r} \|x[j]\|_2^2 \leq \sum_{i \in \mathcal{J}_{ij} \in \mathcal{J}_r} \|T[ij]x[j]\|_2^2 \leq (1 + \delta_d)_{j \in \mathcal{J}_r} \|x[j]\|_2^2 \mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_B], \mathbf{w}_i = [\mathbf{w}_{1i}, \mathbf{w}_{2i}, \dots, \mathbf{w}_{Bi}]^T$$

$\delta_d$  ( $0 < \delta_d < 1$ ) 的下确界 (定义为  $\delta_{dk}$ ) 称为观测矩阵  $D$  的块有限等距常数;

FCNN-CS 的重建阶段: 恢复算法的设计也是压缩感知的核心研究问题之一, 其目标是从压缩测量中恢复出原始图像, 可以表示为形如式 (1.9) 的优化问题;

$$\min \|x\|_0 \text{ s.t. } y = \Phi x \quad (1.9)$$

其中  $\|x\|_0$  表示  $x$  中非零元素的个数, 记为  $l_0$ -范数,  $\Phi$  表示测量矩阵; 求解该问题的主要方法可以分为三类: 贪婪算法, 凸优化算法和基于深度学习的方法;

其中联合损失函数中假设  $\{Y_i, X_i\}_{i=1}^Q$  表示  $Q$  对输入的 CS 测量和对应的原始图片, 重构图片为  $\hat{X}_i$ , 则

$$\hat{X}_i = \mathcal{N}^D \left( \mathcal{N}^L \left( \mathcal{N}^I (Y_i, \mathbf{W}^I), \{\mathbf{W}_k\}_{k=1}^K, \{\mathbf{b}_k\}_{k=1}^K \right), \mathbf{W}^D \right). \quad (1.26)$$

我们的目标是使得  $\hat{X}_i$  尽可能的接近原始图片  $X_i$ , 同时使得中间层的稀疏约束成立; 由于我们选择 ReLU 作为激活函数, 可以使得中间层的系数高概率变得稀疏; 也就是说稀疏约束可以被吸收到网络中, 此时, 损失函数就变为

$$L(\mathbf{W}^I, \{\mathbf{W}_k\}_{k=1}^K, \{\mathbf{b}_k\}_{k=1}^K, \mathbf{W}^D) = \frac{1}{2Q} \sum_{i=1}^Q \left\| X_i - \hat{X}_i \right\|_2^2. \quad (1.27)$$

其中  $(\mathbf{W}^I, \{\mathbf{W}_k\}_{k=1}^K, \{\mathbf{b}_k\}_{k=1}^K, \mathbf{W}^D)$  为模型  $\mathcal{N}(\cdot)$  的参数;

步骤 2, 数值实验: 其中数值实验包括训练设置、重建结果的评价指标、在灰度图上的实验结果对比及讨论和在彩色图上的实验结果对比及讨论; 其中训练设置中的 FCNN-CS 与 Fully-conv 和 CSNet 采用相同的训练集训练, 训练数据集包含 400 幅图像, 由来自 BSDS500 数据库的 200 幅训练图像和 200 幅测试图像构成; 和文献 [66] 中的设置一样, 将训练图像裁剪成  $96 \times 96$  像素的子图像, 步长设为 57; 我们还使用了 8 种数据增强方法, 即将原始图像翻转、旋转  $90^\circ$ 、旋转  $90^\circ$  加翻转、旋转  $180^\circ$ 、旋转  $180^\circ$  加翻转、旋转  $270^\circ$  和旋转  $270^\circ$  加翻转; 最后我们得到选取 89600 个子图像进行网络训练; 对于每个图像块, 我们将其输入到基于 CNN 的 CS 框架中; 在给定输入图像  $X$  的情况下, 我们的目标是利用测量网络获得 CS 测量值  $Y$ , 然后使用重建网络从  $Y$  精确地恢复原始输入图像  $X$ ; 由于测量网络的输出是重建网络的输入, 可以直接将它们合并到端到端网络中进行联合优化, 而不需要考虑  $Y$  是什么; 也就是说, 输入和标签都是用于训练 FCNN-CS 的图像  $X$  本身, 训练数据集可以表示为  $Q$  组图像对  $\{X_i, X_i\}_{i=1}^Q$ ;

其中重建结果的评价指标中采用图像质量评价领域常用的三个全参考的指标来评估恢复图像质量的好坏, 这三个指标分别为峰值信噪比 (PSNR)、结构相似性 (SSIM) 和基于人类视觉系统的感知相似性 (PSIM):

$$\text{PSNR} = 10 \times \log_{10} \left( \frac{(2^n - 1)^2}{\text{MSE}} \right) \quad (1.28)$$

其中 MSE 表示原图与重建图之间的均方根误差,  $(2^n - 1)$  表示信号最大值, 当信号为 uint8 型时, 其值为 255, 为 oat 型时为 1; PSNR 指标值越大, 就表示失真越少, 图像重建效果越好;

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (1.29)$$

其中 $\mu_x$ 是x的平均值, $\mu_y$ 是y的平均值, $\sigma_x^2$ 是x的方差, $\sigma_y^2$ 是y的方差, $\sigma_{xy}$ 是x和y的协方差; $c_1 = (k_1L)^2$ , $c_2 = (k_2L)^2$ 是用来维持稳定的常数;L是像素值的动态范围; $k_1 = 0.01$ , $k_2 = 0.03$ ;SSIM指标值约接近1,代表图像重建效果越好;

$$\text{PSIM} = \frac{H^\tau}{L^\alpha} * S^\beta * C^0, \quad (1.30)$$

其中 $L^\alpha$ 和 $S^\beta$ 分别表示 $\alpha$ 和 $\beta$ 尺度下梯度大小的相似性, $C^0$ 表示颜色信息相似性, $H^\tau$ 表示基于高失真池化;PSIM指标值约接近1,代表图像重建效果越好;

所述在在灰度图上的实验结果对比及讨论中,在Set11[19](11张图像)和Set14[67](14张图像)两个数据集上测试上述训练得到的四个模型,并且给出了客观评价和主观评价的比较;

1.) 客观评价:我们计算了重建图片的PSNR指标来和现有方法进行比较,如图1.3所示,FCNN-CS包括一个测量网络和重构网络;采样网络可以获得输入图像的测量值并学习采样矩阵;重构网络包括反卷积层和基于阈值投影算法展开的非线性深度重构网络;

2.) 主观评价:接下来我们展示了实验所得的恢复视觉效果;

在彩色图上的实验结果对比及讨论中通过设置图像的通道 $c = 3$ ,我们的方法可以直接推广到压缩感知彩色图像的恢复;训练数据集为来自BSDS500[66]数据库的200幅训练图像和200幅测试图像构成的400幅彩色图像;对于彩色图像CS,我们在RGB颜色空间上训练了两个模型,分别对应于测量率为0.25和0.04;我们用Set5(5张彩色图片)作为测试集,采样率分别为0.25,0.04时,Set5上重构图片的平均PSNR值分别为32.71dB,24.85dB;显示了FCNN-CS在采样率为0.25时的重建结果的四个可视化示例,FCNN-CS获得了良好的彩色图像CS重建很容易可以看出,即使是纹理复杂的图像中,FCNN-CS在像虹膜与睫毛这样细节区域的恢复效果也能取得视觉上与原图相似的观感,PSNR值也达到了较高的水平35.11dB。

2. 根据权利要求1所述的基于深度卷积神经网络与压缩感知的图像恢复技术,其特征在于,在训练阶段,测量网络和重构网络形成端到端的联合优化网络;在应用阶段,测量网络作为编码器产生CS测量值,重建网络作为解码器进行图像重建。

3. 根据权利要求1所述的基于深度卷积神经网络与压缩感知的图像恢复技术,其特征在于,FCNN-CS的重建阶段中贪婪算法若允许少量重建误差存在,式(1.9)可以写为:

$$\min_{\mathbf{x}} \|\mathbf{x}\|_0 \quad \text{s.t.} \quad \|\Phi\mathbf{x} - \mathbf{y}\|_2^2 < \xi, \quad (1.10),$$

其中 $\xi$ 表示极小的常量。

4. 根据权利要求1所述的基于深度卷积神经网络与压缩感知的图像恢复技术,其特征在于,所述FCNN-CS的重建阶段中凸优化算法从求解优化问题的角度来看,式(1.9)中最小化 $l_0$ -范数的问题是非凸的、不易求解的;若将其转化为凸优化问题,则上述问题也就迎刃而解,常见的做法为用 $l_1$ -范数代替 $l_0$ -范数;式(1.9)可以写为:

$$\min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{s.t.} \quad \mathbf{y} = \Phi\mathbf{x}, \quad (1.11),$$

其中典型的凸优化算法有:迭代阈值算法(ITA)[31]和基追踪算法(BP)。

5. 根据权利要求1所述的基于深度卷积神经网络与压缩感知的图像恢复技术,其特征在于,所述FCNN-CS的重建阶段中将整个基于深度卷积神经网络的压缩感知重建过程记为 $\mathcal{N}$ ,反卷积网络记为 $\mathcal{N}I$ ,基于稀疏先验的多层非负软阈值投影算法(MNSTPA)展开的卷积神经网络结构记为 $\mathcal{N}L$ ,最后的卷积层记为 $\mathcal{N}D$ 。给定CS测量 $Y$ ,重建过程可以被表述为,

$$\hat{X} = \mathcal{N}(Y) = \mathcal{N}D(\mathcal{N}L(\mathcal{N}I(Y))). \quad (1.12)$$

给定CS测量,一些传统的压缩感知恢复方法通常使用一个伪逆矩阵来获得初始的重建图像[20,57]。受此启发,我们通过卷积运算的逆,即反卷积网络(Deconv)来获得与原始图像同纬度的低质量图像特征。假设 $\{Y_i, X_i\}$ 分别表示对应的一组压缩测量和原始图片,反卷积网络恢复得到与原始图像同维度的特征记为 $X_i$ 。对于给定的CS测量 $Y_i$ ,其初步重建结果为,

$$\mathbf{X}'_i = \mathcal{N}_I(\mathbf{Y}_i, \mathbf{W}^I) = \tilde{S}_{\text{vect}}(\tilde{\mathbf{T}} \cdot S_r(\mathbf{Y}_i)) \quad (1.13);$$

$S_{\text{vect}}(\cdot)$ 表示图1.5中图像向量化的逆过程, $\tilde{\mathbf{T}}$ 为反卷积操作的矩阵表示。显然,直接求逆得到的初步特征图像与原始图像之间会存在较大的差距。为了减少这种差距,我们在该结构之后再接一个融合了图像稀疏先验的DCNN结构来提高重构图像质量;子网络 $\mathcal{N}L$ 的核心思想是将截断的MNSTPA算法[50]嵌入到DCNN中,同时跟踪相应的稀疏表示。由于压缩感知和稀疏编码模型在图像去噪,图像超分辨率恢复,核磁共振成像(MRI)等计算机视觉任务中取得了先进的结果,采用稀疏编码模型来完成压缩感知的图像重建任务。稀疏编码的目标为将原始图像或信号数据 $x$ 表示为冗余字典 $D$ 中原子的线性组合,其中 $a$ 表示稀疏系数。即

$$\min_a \|a\|_0 \quad \text{s.t. } x = Da. \quad (1.14);$$

受计算复杂度和硬件成本的限制,该模型在图像处理任务中都是对从整张图像中提取的局部图像块进行操作。在该设置下,要求每个图像重叠块都可以在公共字典下稀疏。但问题是,如何保证公共字典 $D$ 的存在以及全局图像和局部块之间的稀疏一致性。为了解决上述问题,Elad等人提出了多层卷积稀疏编码模型。ML-CSC模型将图像表示为特征映射和相应滤波器的卷积和,并且假设中间层的稀疏表示可以被进一步稀疏分解,即 $X = D_1 A_1$ ,稀疏表示 $A_1$ 可以进一步写为 $A_1 = D_1 A_2$ 。以此类推,设有 $K$ 组字典 $\{D_i\}_{i=1}^K$ ,对应的稀疏表示为 $\{A_i\}_{i=1}^K$ ,ML-CSC模型可以写为,

$$\text{find } \{A_i, D_i\}_{i=1}^K \quad \text{s.t.} \quad \left\{ \begin{array}{ll} X = D_1 A_1 & \|A_1\|_1 \leq s_1 \\ A_1 = D_2 A_2 & \|A_2\|_1 \leq s_2 \\ \vdots & \\ A_{K-1} = D_K A_K & \|A_K\|_1 \leq s_K \end{array} \right\}. \quad (1.15)$$

其中 $\{s_i\}_{i=1}^K$ 表示每层稀疏表示的稀疏度;由于软阈值算法的简单性,经常被用来求解上式中的优化问题。先固定字典 $D$ ,用 $X$ 乘以 $D^T$ ,并对结果用软阈值算子 $S_\rho(\cdot)$ 进行收缩。 $S_\rho(\cdot)$ 可以通过使向量中较小的元素归零来促进解的稀疏性,其形式定义为:

$$S_\rho(x) = \begin{cases} x + \rho, & x < -\rho; \\ 0, & -\rho \leq x \leq \rho; \\ x - \rho, & \rho < x; \end{cases} \quad (1.16)$$

式 (1.15) 中的问题可以转为为求解下列问题:

$$\min_{\mathbf{X}, \mathbf{D}, \{\mathbf{A}_k\}_{k=1}^K} \frac{1}{2} \|\mathbf{X} - \mathbf{D}_{\text{all}} \mathbf{A}_K\|_2^2 + \rho_1 \|\mathbf{A}_1\|_1 + \cdots + \rho_K \|\mathbf{A}_K\|_1. \quad (1.17)$$

对应地, 可以用多层软阈值投影算法, 求解上式, MLSThPA算法的思想为, 在每次迭代中计算出第一层和第二层稀疏表示的估计。以此类推, 直到得到最深层的估计,

$$\hat{\mathbf{A}}_K = \mathcal{S}_{\rho_K} \left( \mathbf{D}_K^T \mathcal{S}_{\rho_{K-1}} \left( \mathbf{D}_{K-1}^T \left( \cdots \mathcal{S}_{\rho_1} \left( \mathbf{D}_1^T \mathbf{X} \right) \right) \right) \right). \quad (1.18)$$

再从最深层的估计  $\hat{\mathbf{A}}_K$  就可以很容易地得到中间表示  $\{\mathbf{A}_i\}_{K-1 \leq i \leq 1}$ , 然后进行下一次迭代, 直到误差收敛。得到了图像最深层的稀疏表示之后, 我们就可以通过下式回溯完成图像恢复任务:

$$\hat{\mathbf{X}} = \mathbf{D}_1 \mathbf{D}_2 \cdots \mathbf{D}_K \hat{\mathbf{A}}_K = \mathbf{D}_{\text{eff}} \hat{\mathbf{A}}_K, \quad (1.19)$$

其中  $\mathbf{D}_{\text{eff}}$  表示有效字典;

式 (1.18) 的传递很容易让人想起神经网络的前向传递。如图 1.7 所示, 我们可以看到, 软阈值函数与 ReLU 激活函数在正半轴是完全重合的。其中 ReLU 函数定

义为,

$$\text{ReLU}(x - \rho) = \max(x - \rho, 0). \quad (1.20)$$

由此, 我们不禁想到了非负稀疏编码 [54], 它的目标是将原始数据分解为非负稀疏分量。对 ML-CSC 模型中的稀疏向量加以非负约束, 则原模型变为下式:

$$\text{寻找 } \{\mathbf{A}_i, \mathbf{D}_i\}_{i=1}^K \text{ s.t. } \left\{ \begin{array}{l} \mathbf{X} = \mathbf{D}_1 \mathbf{A}_1, \quad \mathbf{A}_1 \geq 0, \quad \|\mathbf{A}_1\|_1 \leq s_1 \\ \mathbf{A}_1 = \mathbf{D}_2 \mathbf{A}_2, \quad \mathbf{A}_2 \geq 0, \quad \|\mathbf{A}_2\|_1 \leq s_2 \\ \vdots \\ \mathbf{A}_{K-1} = \mathbf{D}_K \mathbf{A}_K, \quad \mathbf{A}_K \geq 0, \quad \|\mathbf{A}_K\|_1 \leq s_K \end{array} \right\}. \quad (1.21)$$

6. 根据权利要求 5 所述的基于深度卷积神经网络与压缩感知的图像恢复技术, 其特征在于, 在原始 ML-CSC 模型上加以非负约束并不会影响模的表达能, 即模型 (1.15) 和 (1.21) 的表达能是相同的。因为模型 (1.15) 中稀疏表示中的非负项可以被吸收到模型 (1.21) 的字典中。具体地, 原始稀疏模型  $\mathbf{X} = \mathbf{D}\mathbf{A}$  可以被写为  $\mathbf{D}\mathbf{A} = \mathbf{D}\mathbf{A}^+ + (-\mathbf{D})(-\mathbf{A}^-)$ , 其中  $\mathbf{A}^+$  表示所有的正项系数,  $\mathbf{A}^-$  表示所有的负项系数。因为  $\mathbf{A}^+$  和  $-\mathbf{A}^-$  中的元素都为正, 即图像  $\mathbf{X}$  可以在字典  $[\mathbf{D}, -\mathbf{D}]$  上被非负稀疏表示  $[\mathbf{A}^+, -\mathbf{A}^-]^T$ ; 显然, 模型 (1.21) 可以通过多层非负软阈值投影算法) 求解, 其中非负软阈值算子  $\mathcal{S}^+_{\rho}(\cdot)$  定义为:

$$\mathcal{S}^+_{\rho}(x) = \begin{cases} 0, & x \leq \rho; \\ x - \rho, & x > \rho. \end{cases} \quad (1.22)$$

MNSTPA 算法的思想是在每次迭代中先后计算出第一层和第二层稀疏表示的估计:

$$\hat{\mathbf{A}}_1 = \mathcal{S}^+_{\rho_1}(\mathbf{D}_1^T \mathbf{X}), \quad \hat{\mathbf{A}}_2 = \mathcal{S}^+_{\rho_2}(\mathbf{D}_2^T \hat{\mathbf{A}}_1),$$

同理, 依次迭代直到得到最深层的估计,

$$\hat{A}_K = \mathcal{S}_{\rho_K}^+ \left( \mathbf{D}_K^T \mathcal{S}_{\rho_{K-1}}^+ \left( \mathbf{D}_{K-1}^T \left( \dots \mathcal{S}_{\rho_1}^+ \left( \mathbf{D}_1^T \mathbf{X} \right) \right) \right) \right). \quad (1.23)$$

再从最深层的估计 $\hat{A}_K$ 就可以很容易地得到中间表示 $\{A_i\}_{K-1 \leq i=1}$ , 然后进行下一轮迭代, 直到误差收敛。我们在算法1和图1.8中给出了MNSTPA的具体的步骤和流程示意。

7. 根据权利要求1所述的基于深度卷积神经网络与压缩感知的图像恢复技术, 其特征在于, 所述步骤2中训练了四个模型, 分别对应不同的测量率 $MR_s = 0.01, 0.04, 0.1, 0.25$ , 在训练模型时, 使用Adam[60]优化器来最小化损失函数。我们将迭代次数设置为50次, 每次迭代时的数据批次大小为64, 循环1400次。我们依旧采用学习率衰减的方法, 将初始学习率设置为 $1e-2$ , 当迭代达到31时, 学习速率会下降到 $1e-3$ , 对于Fully-conv和CSNet的训练使用其作者提到的默认参数训练。

8. 根据权利要求1所述的基于深度卷积神经网络与压缩感知的图像恢复技术, 其特征在于, 在所述灰度图上的实验结果对比及讨论中FCNN-CS模型、Fully-conv模型、CSNet模型以及CMCS-net模型在测试集Set11、Set14上的PSNR和SSIM结果分别汇总在表1.1和表1.2中。其中最高的PSNR和SSIM值用粗体标记。我们可以看到, FCNN-CS在不同测量率下的重构图像的PSNR和SSIM值都是最高的。如表1.1所示, 与CMCS-net、Fully-conv、CSNet相比, 在较高的测量率水平下 ( $MR=0.25$ ) FCNN-CS在测试集Set11中多数图片上有着的最佳的重构性能, 在很低的测量率水平下 ( $MR=0.01$ ) FCNN-CS在Set11中所有图片上都取得了最佳的重构性能。如表1.2所示, 当测量率降低时, FCNN-CS在Set14上的重构结果与第二好的结果之间的差值有所提升, 在较高的测量率水平下 ( $MR=0.25$ 和 $MR=0.1$ ) FCNN-CS比CSNet在测试集Set14上的重构图片的PSNR只高出0.23 {0.41dB, 而在较低的测量率水平下 ( $MR=0.01$ 和 $MR=0.04$ ) FCNN-CS比CSNet在Set14上的重构图片的PSNR高出0.72-0.76dB。

9. 根据权利要求1所述的基于深度卷积神经网络与压缩感知的图像恢复技术, 其特征在于, 在所述灰度图上的实验结果对比及讨论中如图1.9, 图1.10, 图1.11和图1.12所示, 图中列出了测量率分别为0.25, 0.1和0.04时, 图像Baboon, Flowers, Comic和Buttery分别通过算法Fully-conv, CSNet, FCNN-CS重建的视觉效果图。很容易可以看出, 即使是在纹理复杂的图像中, 相比与其他两种方法FCNN-CS模型在细节处的恢复效果也能取得视觉上令人满意的观感。如图1.9所示, Fully-conv, CSNet的恢复的图片放大之后胡子处会有点模糊, 而FCNN-CS恢复出的胡子最接近原始图片。我们的结果PSNR值比CSNet高出0.78dB。如图1.10所示, 在放大的红色窗口中, Fully-conv, CSNet的恢复的图片放大之后看不出花蕊处的细节, 而FCNN-CS恢复出的花蕊最接近原始图片。我们还注意到, 在测量率降低为0.1时, FCNN-CS模型在图片的线条处恢复效果依然能取得视觉上令人满意的观感。如图1.11所示, 在像人物的头饰以及背景围栏这样有明显分界的地方, Fully-conv和CSNet恢复得到的图片会出现明显的伪影, 而FCNN-CS恢复得到的图片中线条会更加流畅。我们的结果PSNR值比Fully-conv和CSNet分别高出0.62dB、0.51dB。当测量率降为更低的水平时, 即 $MR=0.04$ 时, FCNN-CS模型在图片的线条处恢复效果依然优于Fully-conv和CSNet, 从而提高了恢复性能。如图1.12所示, Fully-conv和CSNet恢复得到的图片会出现明显的伪影, 而FCNN-CS恢复得到的图片中花瓣与背景之间的分界线会更加分明。

## 基于深度卷积神经网络与压缩感知的图像恢复技术

### 技术领域

[0001] 本发明涉及图像恢复技术领域,尤其涉及基于深度卷积神经网络与压缩感知的图像恢复技术。

### 背景技术

[0002] 当今社会的信息化程度不断加深,人与物品、人与机器、物品与机器等开始愈来愈紧密的融合。在这种形势下,我们的生活中也开始处处充满“智能”,比如智慧医疗、智慧教育、智慧城市等,人们的生活方式和行为模式也因此受到着极大地影响与改变。我们获取信息的渠道和手段也变得越来越丰富多彩,也远远不再局限于简单的文字形式,例如平时使用微信聊天时,越来越多的人喜欢使用图片或者小视频的方式来表达想要传递的内容。图片和视频确实可以更直观地、生动地传递出文字消息无法表达出的信息,而图片和视频的海量应用面临着如何在无线信道上实时、高质量地传输大量信号、图像和视频数据的挑战。奈奎斯特采样定理[1]表明,在信号采集过程中,当采样频率大于信号中最高频率的两倍时,就可以完全保留原信号中的信息。该定理的提出为现有的信号、图像等数据的获取、存储和传输等过程提供了坚实的理论基础。我们现在有的采样方法几乎都是基于奈奎斯特采样定理,但是现在的电子设备支持的频率越来越高,信号的带宽也越来越高,这就意味着所需要的采样率将会很高。并且考虑到后续的传输、储存和计算成本等,往往需要对采集到的原始信号数据进行压缩,而压缩过程中需要丢弃大量的冗余信息。奈奎斯特采样定理表明,在信号采集过程中采样频率应该大于信号中最高频率的两倍,才能完整的保留原始信号中的信息。如图1.1所示,这种采样压缩的模式不仅提高了采样硬件的成本还造成了资源的浪费。面对这一问题Candes, Tao等人指出,既然要丢弃的信息为什么还要采集呢。Donoho, Candes和Tao等人随之提出了全新的压缩感知理论(CS)。压缩感知理论从数学上证明,当信号在某一变换域中表现出稀疏性或者近似稀疏性时,则可以将其投影到与其变换域不相关的测量矩阵上,所需的测量数可以远低于奈奎斯特采样定理规定的采样率。如图1.2所示,这一过程将采样过程和压缩过程合二为一,得到的测量数据维度远小于原始信号的维度,且测量中的每个元素都是由原始信号经过某种映射得到的。如果我们选择合适的映射关系,使低维的测量包含原始高维信号的主要信息,就可以用优化算法实现对原始信号数据的高质量重构。CS理论在信息获取领域给出了全新的理论指导,有效地降低了数据的压缩和存储成本,也极大地便利了数据的传输。自该理论出现以来在多个领域得到了广泛应用,如遥感应用,快速成像,无线通信,医疗影像,智能交通等领域。

[0003] 图像作为这些应用中越来越重要的传递信息的载体,如何使用较少的测量值重构出高质量的图像成为压缩感知过程中的关键问题。重构图像的质量既受到测量矩阵的影响,也受重建算法的影响。因此,如何设计出性能优异的测量矩阵和重构算法这两个问题吸引了越来越多研究者的关注。

发明内容

[0004] 1.要解决的技术问题

[0005] 本发明的目的是为了解决现有技术中如何使用较少的测量值重构出高质量的图像的问题,提出了基于深度卷积神经网络与压缩感知的图像恢复技术。

[0006] 2.技术方案

[0007] 为了实现上述目的,本发明采用了如下技术方案:

[0008] 基于深度卷积神经网络与压缩感知的图像恢复技术,包括以下步骤:

[0009] 步骤1,全卷积压缩感知网络设计:其中全卷积压缩感知网络设计包括FCNN-CS的测量阶段、多通道卷积测量的块RIP条件、FCNN-CS 的重建阶段和联合损失函数;

[0010] 在FCNN-CS的测量阶段,假设输入图像的大小为 $N \times N \times c$ ,其中 $c$  表示通道数,取值为1或3;然后用大小为 $c \times B \times B \times c_0$ 的滤波器获

[0011] 得压缩测量 $Y$ ,测量过程可以表示为: $Y=W*X$  (1.1), 其中卷积步长为 $m$ ,测量 $Y$ 的维度为 $M \times M \times c_0$ ,  $M=\lfloor \frac{N-B}{m} \rfloor + 1$ , 记测量率为 $MRs$ , 则可以由下式求得,

$$MRs = \frac{c_0 \times M^2}{c \times N^2} = \frac{c_0 (\lfloor \frac{N-B}{m} \rfloor + 1)^2}{c \times N^2} \quad (1.2);$$

我们以 $c$ 和 $c_0$ 都取值1为例给出基于学习的测量

(Learned Convolutional Measurement, LCM) 过程的分解,卷积测量利用卷积滤波器 $W$ 实现了从原图 $X \in \mathbb{R}^{N \times N}$ 到压缩测量 $Y \in \mathbb{R}^{M \times M}$  ( $M \ll N$ ), 该测量过程可以表示为: $Y=W*X$  (1.3), 其中滤波器 $W \in \mathbb{R}^{B \times B}$ 中的系数为  $W = [w_1, w_2, \dots, w_B]$ ,  $w_i = [w_{i1}, w_{i2}, \dots, w_{iB}]^T$ . 图像的卷积运算其实是基于图像局部块的运算特别地,我们定义一个块提取算子 $P_{ij}(\cdot)$ 来从整个图像 $X$  上获取相应的图像块 $x^{ij}$ :  $x^{ij} = P_{ij}(X)$ , 其中 $X^{ij} \in \mathbb{R}^{B \times B}$ ; 方程(1.3)可以按像素点写为:

$$y_{ij} = W * P_{ij}(X), 0 < i, j \leq \lfloor \frac{N-B}{m} \rfloor + 1 \quad (1.4)$$

[0013] 其中 $m$ 为卷积测量时的步长;此外,我们再定义两种拉伸算子 $Sc(\cdot)$  和 $Sr(\cdot)$ , 如图1.4所示; $Sc(\cdot)$  为列拉伸算子,它将矩阵按列重新排列为一个向量,即 $x_{ij} \text{ vect} = Sc(X^{ij})$ , 其中 $x_{ij} \text{ vect} \in \mathbb{R}^{B^2}$ ;  $Sr(\cdot)$  为行拉伸算子,同理,它将矩阵按行重新排列为一个向量,即 $y^T = S_r(Y)$ , 其中 $y \in \mathbb{R}^{M^2}$ ;

[0014] 多通道卷积测量的块RIP条件:(块RIP)对任意块长为 $c$ 的稀疏向量 $x$ ,测量矩阵 $D$ 满足 $k$ 阶块RIP条件,如果有下式成立:

$$(1 - \delta_d) \|x\|_2^2 \leq \|Dx\|_2^2 \leq (1 + \delta_d) \|x\|_2^2 \quad (1.6)$$

[0016] 其中 $\delta_d$  ( $0 < \delta_d < 1$ ) 的下确界(定义为 $\delta_{dk}$ ) 称为观测矩阵的的块有限等距常数;

[0017] 测量矩阵 $D$ 以级联块的方式表示:

$$D = \begin{pmatrix} D_{1,1}, \dots, D_{1,d} & D_{1,d+1}, \dots, D_{1,2d} & \dots & D_{1,N-d+1}, \dots, D_{1,N} \\ T[\tilde{y}_1] & T[\tilde{y}_2] & \dots & T[\tilde{y}_c] \\ \vdots & \vdots & \ddots & \vdots \\ D_{c_0,1}, \dots, D_{c_0,d} & D_{c_0,d+1}, \dots, D_{c_0,2d} & \dots & D_{c_0,N-d+1}, \dots, D_{c_0,N} \\ T[\tilde{c}_01] & T[\tilde{c}_02] & \dots & T[\tilde{c}_0c] \end{pmatrix} \quad (1.7);$$

[0019] 如图1.6所示,其中 $T[ij]$  ( $i \in \{1, \dots, c_0\}, j \in \{1, \dots, c\}$ ) 是矩阵 $D$ 的第 $ij$

块;对于任意的块列索引集合 $\mathcal{J}l = \{l1, \dots, li\} \subseteq \{1, \dots, co\}$ ,块行索引集合 $\mathcal{J}r = \{r1, \dots, ri\} \subseteq \{1, \dots, c\}$ , $|\mathcal{J}l|$ 和 $|\mathcal{J}r|$ 分别表示集合 $\mathcal{J}l$ 和 $\mathcal{J}r$ 的长度;矩阵D满足k阶块RIP条件,如果对任意的索引集合 $\mathcal{J}l \subseteq \{1, \dots, co\}$ , $\mathcal{J}r \subseteq \{1, \dots, c\}$ ,且 $|\mathcal{J}l| * |\mathcal{J}r| \leq k$ ,满足下式

$$[0020] \quad (1 - \delta_d) \|x_{\mathcal{J}r}\|_2^2 \leq \|D_{\mathcal{J}l\mathcal{J}r}x_{\mathcal{J}r}\|_2^2 \leq (1 + \delta_d) \|x_{\mathcal{J}r}\|_2^2 \quad (1.8)$$

[0021] 等价于

$$[0022] \quad (1 - \delta_d)_{j \in \mathcal{J}r} \|x[j]\|_2^2 \leq \sum_{i \in \mathcal{J}l} \|T[ij]x[j]\|_2^2 \leq (1 + \delta_d)_{j \in \mathcal{J}r} \|x[j]\|_2^2 \mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_B], \mathbf{w}_i = [w_{1i}, w_{2i}, \dots, w_{Bi}]^T$$

[0023]  $\delta_d$  ( $0 < \delta_d < 1$ ) 的下确界(定义为 $\delta_{dk}$ )称为观测矩阵D的块有限等距常数;

[0024] FCNN-CS的重建阶段:恢复算法的设计也是压缩感知的核心研究问题之一,其目标是从压缩测量中恢复出原始图像,可以表示为形如式(1.9)的优化问题;

$$[0025] \quad \min \|x\|_0 \text{ s.t. } y = \Phi_x \quad (1.9)$$

[0026] 其中 $\|x\|_0$ 表示x中非零元素的个数,记为l0-范数, $\Phi$ 表示测量矩阵;求解该问题的主要方法可以分为三类:贪婪算法,凸优化算法和基于深度学习的方法;

[0027] 其中联合损失函数中假设 $\{Y_i, X_i\}_{i=1}^Q$ 表示Q对输入的CS测量和对应的原始图片,重构图片为 $\hat{X}_i$ ,则

$$[0028] \quad \hat{X}_i = \mathcal{N}^D \left( \mathcal{N}^L \left( \mathcal{N}^I (Y_i, \mathbf{W}^I), \{\mathbf{W}_k\}_{k=1}^K, \{\mathbf{b}_k\}_{k=1}^K \right), \mathbf{W}^D \right). \quad (1.26)$$

[0029] 我们的目标是使得 $\hat{X}_i$ 尽可能的接近原始图片 $X_i$ ,同时使得中间层的稀疏约束成立;由于我们选择ReLU作为激活函数,可以使得中间层的系数高概率变得稀疏;也就是说稀疏约束可以被吸收到网络中,此时,损失函数就变为

$$[0030] \quad L(\mathbf{W}^I, \{\mathbf{W}_k\}_{k=1}^K, \{\mathbf{b}_k\}_{k=1}^K, \mathbf{W}^D) = \frac{1}{2Q} \sum_{i=1}^Q \|X_i - \hat{X}_i\|_2^2. \quad (1.27)$$

[0031] 其中 $(\mathbf{W}^I, \{\mathbf{W}_k\}_{k=1}^K, \{\mathbf{b}_k\}_{k=1}^K, \mathbf{W}^D)$ 为模型 $\mathcal{N}(\cdot)$ 的参数;

[0032] 步骤2,数值实验:其中数值实验包括训练设置、重建结果的评价指标、在灰度图上的实验结果对比及讨论和在彩色图上的实验结果对比及讨论;其中训练设置中的FCNN-CS与Fully-conv和CSNet采用相同的训练集训练,训练数据集包含400幅图像,由来自BSDS500数据库的200幅训练图像和200幅测试图像构成;和文献[66]中的设置一样,将训练图像裁剪成 $96 \times 96$ 像素的子图像,步长设为57;我们还使用了8种数据增强方法,即将原始图像翻转、旋转 $90^\circ$ 、旋转 $90^\circ$ 加翻转、旋转 $180^\circ$ 、旋转 $180^\circ$ 加翻转、旋转 $270^\circ$ 和旋转 $270^\circ$ 加翻转;最后我们得到选取89600个子图像进行网络训练;对于每个图像块,我们将其输入到基于CNN的CS框架中;在给定输入图像X的情况下,我们的目标是利用测量网络获得CS测量值Y,然后使用重建网络从Y精确地恢复原始输入图像X;由于测量网络的输出是重建网络的输入,可以直接将它们合并到端到端网络中进行联合优化,而不需要考虑Y是什么;也就是说,输入和标签都是用于训练FCNN-CS的图像X本身,训练数据集可以表示为Q组图像对 $\{X_i, X_i\}$

Q;

[0033] 其中重建结果的评价指标中采用图像质量评价领域常用的三个全参考的指标来评估恢复图像质量的好坏,这三个指标分别为峰值信噪比 (PSNR)、结构相似性 (SSIM) 和基于人类视觉系统的感知相似性 (PSIM):

$$[0034] \quad \text{PSNR} = 10 \times \log_{10}\left(\frac{(2^n - 1)^2}{\text{MSE}}\right) \quad (1.28)$$

[0035] 其中MSE表示原图与重建图之间的均方根误差,  $(2^n - 1)$  表示信号最大值,当信号为 uint8型时,其值为255,为oat型时为1;PSNR指标值越大,就表示失真越少,图像重建效果越好;

$$[0036] \quad \text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (1.29)$$

[0037] 其中 $\mu_x$ 是x的平均值, $\mu_y$ 是y的平均值, $\sigma_x^2$ 是x的方差, $\sigma_y^2$ 是y的方差, $\sigma_{xy}$ 是x和y的协方差; $c_1 = (k_1L)^2$ , $c_2 = (k_2L)^2$ 是用来维持稳定的常数;L是像素值的动态范围; $k_1 = 0.01$ , $k_2 = 0.03$ ;SSIM指标值约接近1,代表图像重建效果越好;

$$[0038] \quad \text{PSIM} = \frac{H^\tau}{L^\alpha} * S^\beta * C^\theta, \quad (1.30)$$

[0039] 其中 $L^\alpha$ 和 $S^\beta$ 分别表示 $\alpha$ 和 $\beta$ 尺度下梯度大小的相似性, $C^\theta$ 表示颜色信息相似性, $H^\tau$ 表示基于高失真池化;PSIM指标值约接近1,代表图像重建效果越好;

[0040] 所述在在灰度图上的实验结果对比及讨论中,在Set11[19] (11 张图像) 和Set14 [67] (14张图像) 两个数据集上测试上述训练得到的四个模型,并且给出了客观评价和主观评价的比较;

[0041] 1.) 客观评价:我们计算了重建图片的PSNR指标来和现有方法进行比较,如图1.3所示,FCNN-CS包括一个测量网络和重构网络;采样网络可以获得输入图像的测量值并学习采样矩阵;重构网络包括反卷积层和基于阈值投影算法展开的非线性深度重构网络;

[0042] 2.) 主观评价:接下来我们展示了实验所得的恢复视觉效果;

[0043] 在彩色图上的实验结果对比及讨论中通过设置图像的通道 $c = 3$ ,我们的方法可以直接推广到压缩感知彩色图像的恢复;训练数据集为来自BSDS500[66]数据库的200幅训练图像和200幅测试图像构成的 400幅彩色图像;对于彩色图像CS,我们在RGB颜色空间上训练了两个模型,分别对应于测量率为0.25和0.04;我们用Set5 (5张彩色图片) 作为测试集,采样率分别为0.25,0.04时,Set5上重构图片的平均PSNR值分别为32.71dB,24.85dB;图中显示了FCNN-CS在采样率为0.25时的重建结果的四个可视化示例,FCNN-CS获得了良好的彩色图像CS重建;如图所示,很容易可以看出,即使是纹理复杂的图像中,FCNN-CS在像虹膜与睫毛这样细节区域的恢复效果也能取得视觉上与原图相似的观感,PSNR值也达到了较高的水平35.11dB。

[0044] 优选地,所述步骤1中如图1.3所示,FCNN-CS包括一个测量网络和重构网络;采样网络可以获得输入图像的测量值并学习采样矩阵;重构网络包括反卷积层和基于阈值投影算法展开的非线性深度重构网络;在训练阶段,测量网络和重构网络形成端到端的联合优化网络;在应用阶段,测量网络作为编码器产生CS测量值,重建网络作为解码器进行图像

重建。

[0045] 优选地,FCNN-CS的重建阶段中贪婪算法若允许少量重建误差存在,式(1.9)可以写为:

$$[0046] \quad \min_{\mathbf{x}} \|\mathbf{x}\|_0 \quad \text{s.t.} \quad \|\Phi\mathbf{x} - \mathbf{y}\|_2^2 < \xi, \quad (1.10),$$

[0047] 其中 $\xi$ 表示极小的常量。

[0048] 优选地,所述FCNN-CS的重建阶段中凸优化算法从求解优化问题的角度来看,式(1.9)中最小化 $l_0$ -范数的问题是非凸的、不易求解的;若将其转化为凸优化问题,则上述问题也就迎刃而解,常见的做法为用 $l_1$ -范数代替 $l_0$ -范数;式(1.9)可以写为:

$$[0049] \quad \min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{s.t.} \quad \mathbf{y} = \Phi\mathbf{x}, \quad (1.11), \quad \text{其中}$$

典型的凸优化算法有:迭代阈值算法(ITA) [31]和基追踪算法(BP)。

[0050] 优选地,所述FCNN-CS的重建阶段中将整个基于深度卷积神经网络的压缩感知重建过程记为 $\mathcal{N}$ ,反卷积网络记为 $\mathcal{N}I$ ,基于稀疏先验的多层非负软阈值投影算法(MNSTPA)展开的卷积神经网络结构记为 $\mathcal{N}L$ ,最后的卷积层记为 $\mathcal{N}D$ 。给定CS测量 $\mathbf{Y}$ ,重建过程可以被表述为,

$$[0051] \quad \hat{\mathbf{X}} = \mathcal{N}(\mathbf{Y}) = \mathcal{N}D(\mathcal{N}L(\mathcal{N}I(\mathbf{Y}))). \quad (1.12)$$

[0052] 给定CS测量,一些传统的压缩感知恢复方法通常使用一个伪逆矩阵来获得初始的重建图像[20,57]。受此启发,我们通过卷积运算的逆,即反卷积网络(Deconv)来获得与原始图像同纬度的低质量图像特征。假设 $\{\mathbf{Y}_i, \mathbf{X}_i\}$ 分别表示对应的一组压缩测量和原始图片,反卷积网络恢复得到与原始图像同维度的特征记为 $\mathbf{X}_i$ 。对于给定的CS测量 $\mathbf{Y}_i$ ,其初步重建

$$[0052] \quad \text{结果为, } \mathbf{X}'_i = \mathcal{N}_I(\mathbf{Y}_i, \mathbf{W}^I) = \tilde{\mathbf{S}}_{\text{vect}} \left( \tilde{\mathbf{T}} \cdot \mathbf{S}_r(\mathbf{Y}_i) \right) \quad (1.13);$$

数, $\text{Svect}(\cdot)$ 表示图1.5中图像向量化的逆过程, $\mathbf{T}$ 为反卷积操作的矩阵表示。显然,直接求逆得到的初步特征图像与原始图像之间会存在较大的差距。为了减少这种差距,我们在该结构之后再接一个融合了图像稀疏先验的DCNN结构来提高重构图像质量;子网络 $\mathcal{N}L$ 的核心思想是将截断的MNSTPA算法[50]嵌入到DCNN中,同时跟踪相应的稀疏表示。由于压缩感知和稀疏编码模型在图像去噪,图像超分辨率恢复,核磁共振成像(MRI)等计算机视觉任务中取得了先进的结果,采用稀疏编码模型来完成压缩感知的图像重建任务。稀疏编码的目标为将原始图像或信号数据 $\mathbf{x}$ 表示为冗余字典 $\mathbf{D}$ 中原子的线性组合,其中 $\mathbf{a}$ 表示稀疏系数。即

$$[0053] \quad \min_{\mathbf{a}} \|\mathbf{a}\|_0 \quad \text{s.t.} \quad \mathbf{x} = \mathbf{D}\mathbf{a}. \quad (1.14);$$

[0054] 受计算复杂度和硬件成本的限制,该模型在图像处理任务中都是对从整张图像中提取的局部图像块进行操作。在该设置下,要求每个图像重叠块都可以在公共字典下稀疏。但问题是,如何保证公共字典 $\mathbf{D}$ 的存在以及全局图像和局部块之间的稀疏一致性。为了解决上述问题,Elad等人提出了多层卷积稀疏编码模型。ML-CSC模型将图像表示为特征映射和相应滤波器的卷积和,并且假设中间层的稀疏表示可以被进一步稀疏分解,即 $\mathbf{X} = \mathbf{D}_1\mathbf{A}_1$ ,稀疏表示 $\mathbf{A}_1$ 可以进一步写为 $\mathbf{A}_1 = \mathbf{D}_1\mathbf{A}_2$ 。以此类推,设有 $K$ 组字典 $\{\mathbf{D}_i\}_{K_i=1}$ ,对应的稀疏表示为 $\{\mathbf{A}_i\}_{K_i=1}$ ,ML-CSC模型可以写为,

$$[0055] \quad \text{find } \{\mathbf{A}_i, \mathbf{D}_i\}_{i=1}^K \text{ s.t. } \left\{ \begin{array}{l} \mathbf{X} = \mathbf{D}_1 \mathbf{A}_1 \quad \|\mathbf{A}_1\|_1 \leq s_1 \\ \mathbf{A}_1 = \mathbf{D}_2 \mathbf{A}_2 \quad \|\mathbf{A}_2\|_1 \leq s_2 \\ \vdots \\ \mathbf{A}_{K-1} = \mathbf{D}_K \mathbf{A}_K \quad \|\mathbf{A}_K\|_1 \leq s_K \end{array} \right\}. \quad (1.15)$$

[0056] 其中  $\{s_i\}_{i=1}^K$  表示每层稀疏表示的稀疏度；由于软阈值算法的简单性，经常被用来求解上式中的优化问题。先固定字典  $\mathbf{D}$ ，用  $\mathbf{X}$  乘以  $\mathbf{D}^T$ ，并对结果用软阈值算子  $\mathcal{S}_\rho(\cdot)$  进行收缩。 $\mathcal{S}_\rho(\cdot)$  可以通过使向量中较小的元素归零来促进解的稀疏性，其形式定义为：

$$[0057] \quad \mathcal{S}_\rho(x) = \begin{cases} x + \rho, & x < -\rho; \\ 0, & -\rho \leq x \leq \rho; \\ x - \rho, & \rho < x; \end{cases} \quad (1.16)$$

[0058] 式 (1.15) 中的问题可以转为为求解下列问题：

$$[0059] \quad \min_{\mathbf{X}, \mathbf{D}, \{\mathbf{A}_k\}_{k=1}^K} \frac{1}{2} \|\mathbf{X} - \mathbf{D}_{\text{all}} \mathbf{A}_K\|_2^2 + \rho_1 \|\mathbf{A}_1\|_1 + \cdots + \rho_K \|\mathbf{A}_K\|_1. \quad (1.17)$$

[0060] 对应地，可以用多层软阈值投影算法，求解上式，MLSThPA算法的思想为，在每次迭代中计算出第一层和第二层稀疏表示的估计。以此类推，直到得到最深层的估计，

$$[0061] \quad \hat{\mathbf{A}}_K = \mathcal{S}_{\rho_K} \left( \mathbf{D}_K^T \mathcal{S}_{\rho_{K-1}} \left( \mathbf{D}_{K-1}^T \left( \cdots \mathcal{S}_{\rho_1} \left( \mathbf{D}_1^T \mathbf{X} \right) \right) \right) \right). \quad (1.18)$$

[0062] 再从最深层的估计  $\hat{\mathbf{A}}_K$  就可以很容易地得到中间表示  $\{\mathbf{A}_i\}_{i=1}^{K-1}$ ，然后进行下一次迭代，直到误差收敛。得到了图像最深层的稀疏表示之后，我们就可以通过下式回溯完成图像恢复任务：

$$[0063] \quad \hat{\mathbf{X}} = \mathbf{D}_1 \mathbf{D}_2 \cdots \mathbf{D}_K \hat{\mathbf{A}}_K = \mathbf{D}_{\text{eff}} \hat{\mathbf{A}}_K, \quad (1.19)$$

[0064] 其中  $\mathbf{D}_{\text{eff}}$  表示有效字典；

[0065] 式 (1.18) 的传递很容易让人想起神经网络的前向传递。如图 1.7 所示，我们可以看到，软阈值函数与 ReLU 激活函数在正半轴是完全重合的。其中 ReLU 函数定

[0066] 义为，

$$[0067] \quad \text{ReLU}(x - \rho) = \max(x - \rho, 0). \quad (1.20)$$

[0068] 由此，我们不禁想到了非负稀疏编码 [54]，它的目标是将原始数据分解为非负稀疏分量。对 ML-CSC 模型中的稀疏向量加以非负约束，则原模型变为下式：

$$[0069] \quad \text{寻找 } \{\mathbf{A}_i, \mathbf{D}_i\}_{i=1}^K \text{ s.t. } \left\{ \begin{array}{l} \mathbf{X} = \mathbf{D}_1 \mathbf{A}_1, \quad \mathbf{A}_1 \geq \mathbf{0}, \|\mathbf{A}_1\|_1 \leq s_1 \\ \mathbf{A}_1 = \mathbf{D}_2 \mathbf{A}_2, \quad \mathbf{A}_2 \geq \mathbf{0}, \|\mathbf{A}_2\|_1 \leq s_2 \\ \vdots \\ \mathbf{A}_{K-1} = \mathbf{D}_K \mathbf{A}_K, \quad \mathbf{A}_K \geq \mathbf{0}, \|\mathbf{A}_K\|_1 \leq s_K \end{array} \right\}. \quad (1.21)$$

[0070] 优选地，在原始 ML-CSC 模型上加以非负约束并不会影响模的表达能，即模型 (1.15) 和 (1.21) 的表达能是相同的。因为模型 (1.15) 中稀疏表示中的非负项可以被吸收到模型 (1.21) 的字典中。具体地，原始稀疏模型  $\mathbf{X} = \mathbf{D}\mathbf{A}$  可以被写为  $\mathbf{D}\mathbf{A} = \mathbf{D}\mathbf{A}^+ + (-\mathbf{D})(-\mathbf{A}^-)$ ，其中  $\mathbf{A}^+$  表示所有的正项系数， $\mathbf{A}^-$  表示所有的负项系数。因为  $\mathbf{A}^+$  和  $-\mathbf{A}^-$  中的元素都为正，即图像  $\mathbf{X}$

可以在字典  $[D, -D]$  上被非负稀疏表示  $[A+, -A-]T$ ; 显然, 模型 (1.21) 可以通过多层非负软阈值投影算法) 求解, 其中非负软阈值算子  $\mathcal{S}^+_{\rho}(\cdot)$  定义为:

$$[0071] \quad \mathcal{S}^+_{\rho}(x) = \begin{cases} 0, & x \leq \rho; \\ x - \rho, & x > \rho. \end{cases} \quad (1.22)$$

[0072] MNSTPA算法的思想是在每次迭代中先后计算出第一层和第二层稀疏表示的估

[0073] 计:  $\hat{A}_1 = \mathcal{S}^+_{\rho_1}(D_1^T X)$ ,  $\hat{A}_2 = \mathcal{S}^+_{\rho_2}(D_2^T \hat{A}_1)$ , 同理, 依次迭代直到得到最深层的估计,

$$[0074] \quad \hat{A}_K = \mathcal{S}^+_{\rho_K}(D_K^T \mathcal{S}^+_{\rho_{K-1}}(D_{K-1}^T(\dots \mathcal{S}^+_{\rho_1}(D_1^T X))))). \quad (1.23)$$

[0075] 再从最深层的估计  $\hat{A}_K$  就可以很容易地得到中间表示  $\{A_i\}_{K-1 \leq i=1}$ , 然后进行下一轮迭代, 直到误差收敛。我们在算法1和图1.8中给出了 MNSTPA的具体的步骤和流程示意。

[0076] 优选地, 所述步骤2中训练了四个模型, 分别对应不同的测量率  $MRs=0.01, 0.04, 0.1, 0.25$ , 在训练模型时, 使用Adam[60]优化器来最小化损失函数。我们将迭代次数设置为50次, 每次迭代时的数据批次大小为64, 循环1400次。我们依旧采用学习率衰减的方法, 将初始学习率设置为  $1e-2$ , 当迭代达到31时, 学习速率会下降到  $1e-3$ , 对于Fully-conv和CSNet的训练使用其作者提到的默认参数训练。

[0077] 优选地, 在所述灰度图上的实验结果对比及讨论中FCNN-CS模型、Fully-conv模型、CSNet模型以及CMCS-net模型在测试集Set11、Set14上的PSNR和SSIM结果分别汇总在表1.1和表1.2中。其中最高的PSNR和SSIM值用粗体标记。我们可以看到, FCNN-CS在不同测量率下的重构图像的PSNR和SSIM值都是最高的。如表1.1所示, 与CMCS-net、Fully-conv、CSNet相比, 在较高的测量率水平下 ( $MR=0.25$ ) FCNN-CS在测试集Set11中多数图片上有着的最佳的重构性能, 在很低的测量率水平下 ( $MR=0.01$ ) FCNN-CS在Set11中所有图片上都取得了最佳的重构性能。如表1.2所示, 当测量率降低时, FCNN-CS在Set14上的重构结果与第二好的结果之间的差值有所提升, 在较高的测量率水平下 ( $MR=0.25$ 和 $MR=0.1$ ) FCNN-CS比CSNet 在测试集Set14上的重构图片的PSNR只高出0.23 {0.41dB, 而在较低的测量率水平下 ( $MR=0.01$ 和 $MR=0.04$ ) FCNN-CS比CSNet在Set14 上的重构图片的PSNR高出0.72-0.76dB。

[0078] 优选地, 在所述灰度图上的实验结果对比及讨论中如图1.9, 图 1.10, 图1.11和图1.12所示, 图中列出了测量率分别为0.25, 0.1 和0.04时, 图像Baboon, Flowers, Comic和Buttery分别通过算法Fully-conv, CSNet, FCNN-CS重建的视觉效果图。很容易可以看出, 即使是在纹理复杂的图像中, 相比与其他两种方法FCNN-CS模型在细节处的恢复效果也能取得视觉上令人满意的观感。如图1.9所示, Fully-conv, CSNet的恢复的图片放大之后胡子处会有点模糊, 而FCNN-CS 恢复出的胡子最接近原始图片。我们的结果PSNR值比CSNet高出 0.78dB。如图1.10所示, 在放大的红色窗口中, Fully-conv, CSNet 的恢复的图片放大之后看不出花蕊处的细节, 而FCNN-CS恢复出的花蕊最接近原始图片。我们还注意到, 在测量率降低为0.1时, FCNN-CS模型在图片的线条处恢复效果依然能取得视觉上令人满意的观感。如图1.11所示, 在像人物的头饰以及背景围栏这样有明显分界的地方, Fully-conv和

CSNet恢复得到的图片会出现明显的伪影,而FCNN-CS恢复得到的图片中线条会更加流畅。我们的结果PSNR 值比Fully-conv和CSNet分别高出0.62dB、0.51dB。当测量率降为更低的水平时,即 $MR=0.04$ 时,FCNN-CS模型在图片的线条处恢复效果依然优于Fully-conv和CSNet,从而提高了恢复性能。如图 1.12所示,Fully-conv和CSNet恢复得到的图片会出现明显的伪影,而FCNN-CS恢复得到的图片中花瓣与背景之间的分界线会更加分明。

[0079] 3.有益效果

[0080] 相比于现有技术,本发明的优点在于:

[0081] (1)本发明中,通过融合深度卷积神经网络与压缩感知的图像恢复研究,即在压缩感知恢复算法的指导下设计的深度卷积神经网络用于完成图像压缩和重建任务。一方面,相比于传统的线性压缩方式,采用基于学习的卷积测量的压缩方法更有利于保留图像的结构信息和设计出自适应的测量矩阵设计。另一方面,实现了基于稀疏编码的压缩感知恢复算法指导下的恢复网络设计。

[0082] (2)基于深度卷积神经网络的压缩感知恢复算法相较于传统的恢复算法大大提升了计算效率和重构质量。我们将测量阶段和恢复阶段联合到同一个网络中进行训练。此时,测量阶段可以看作是自适应的,网络学习了从原始图像到测量的转换再将原始图像恢复出来。从而可以在测量阶段保留原始图像中更多的信息使恢复结果大幅提高。

## 附图说明

[0083] 图1.1:传统测量理论原理图;

[0084] 图1.2:压缩感知理论原理图;

[0085] 图1.3:FCNN-CS网络结构示意图;

[0086] 图1.4:块提取算子 $P_{ij}(\cdot)$ 和两种拉伸算子 $S_c(\cdot)$ , $S_r(\cdot)$ 的图示解释

[0087] 图1.5:卷积测量过程 $W*X$ 的实例表示,其中 $S_r(W*X) = T \cdot \text{xvect}, c=co=1$ ;

[0088] 图1.6:基于学习的多通道卷积测量过程的实例表示,其中 $c=2, co=2$ ;

[0089] 图1.7:软阈值函数与ReLU激活函数的示意图(其中参数 $\rho$ 取2 为例);

[0090] 图1.8:算法1的图示结构;

[0091] 图1.9:MR为0.25时,从左到右依次为图像Baboon原图,分别通过算法Fullyconv, CSNet,FCNN-CS重建的视觉效果图;

[0092] 图1.10:MR为0.25时,从左到右依次为图像Flowers原图,分别通过算法Fullyconv,CSNet,FCNN-CS重建的视觉效果图;

[0093] 图1.11:MR为0.1时,从左到右依次为图像Comic原图,分别通过算法Fullyconv, CSNet,FCNN-CS重建的视觉效果图;

[0094] 图1.12:MR为0.04时,从左到右依次为图像Butterfly原图,分别通过算法Fullyconv,CSNet,FCNN-CS重建的视觉效果图。

## 具体实施方式

[0095] 下面将结合本发明实施例中的附图,对本发明实施例中的技术方案进行清楚、完整地描述,显然,所描述的实施例仅仅是本发明一部分实施例,而不是全部的实施例。

[0096] 实施例1:

[0097] 基于深度卷积神经网络与压缩感知的图像恢复技术,包括以下步骤:

[0098] 1、包括以下步骤:

[0099] 步骤1,全卷积压缩感知网络设计:其中全卷积压缩感知网络设计包括FCNN-CS的测量阶段、多通道卷积测量的块RIP条件、FCNN-CS 的重建阶段和联合损失函数;

[0100] 在FCNN-CS的测量阶段,假设输入图像的大小为 $N \times N \times c$ ,其中 $c$ 表示通道数,取值为1或3;然后用大小为 $c \times B \times B \times c_0$ 的滤波器获

[0101] 得压缩测量 $Y$ ,测量过程可以表示为: $Y=W*X$  (1.1), 其中卷积步长为 $m$ ,测量 $Y$ 的维

度为 $M \times M \times c_0$ ,  $M = \left\lfloor \frac{N-B}{m} \right\rfloor + 1$ , 记测量率为 $MR_s$ , 则可以由下式求得,

$$MR_s = \frac{c_0 \times M^2}{c \times N^2} = \frac{c_0 \left( \left\lfloor \frac{N-B}{m} \right\rfloor + 1 \right)^2}{c \times N^2} \quad (1.2);$$

量(Learned Convolutional Measurement, LCM)过程的分解,卷积测量利用卷积滤波器 $W$ 实现了从原图 $X \in \mathbb{R}^{N \times N}$ 到压缩测量 $Y \in \mathbb{R}^{M \times M}$  ( $M < N$ ),该测量过程可以表示为: $Y=W*X$  (1.3),其中滤波器 $W \in \mathbb{R}^{B \times B}$ 中的系数为  $W = [w_1, w_2, \dots, w_B]$ ,  $w_i = [w_{1i}, w_{2i}, \dots, w_{Bi}]^T$ .图像的卷积运算其实是基于图像局部块的运算;特别地,我们定义一个块提取算子 $P_{ij}(\cdot)$ 来从整个图像 $X$ 上获取相应的图像块 $X^{ij}$ : $X^{ij} = P_{ij}(X)$ ,其中 $X^{ij} \in \mathbb{R}^{B \times B}$ ;方程(1.3)可以按像素点写为:

$$y_{ij} = W * P_{ij}(X), 0 < i, j \leq \left\lfloor \frac{N-B}{m} \right\rfloor + 1 \quad (1.4)$$

[0103] 其中 $m$ 为卷积测量时的步长;此外,我们再定义两种拉伸算子 $Sc(\cdot)$ 和 $Sr(\cdot)$ ,如图1.4所示; $Sc(\cdot)$ 为列拉伸算子,它将矩阵按列重新排列为一个向量,即 $x_{ij} \text{ vect} = Sc(X^{ij})$ ,其中 $x_{ij} \text{ vect} \in \mathbb{R}^{B^2}$ ;  $Sr(\cdot)$ 为行拉伸算子,同理,它将矩阵按行重新排列为一个向量,即 $y^T = S_r(Y)$ ,其中 $y \in \mathbb{R}^{M^2}$ ;

[0104] 多通道卷积测量的块RIP条件:(块RIP)对任意块长为 $c$ 的稀疏向量 $x$ , 测量矩阵 $D$ 满足 $k$ 阶块RIP条件,如果有下式成立:

$$(1 - \delta_d) \|x\|_2^2 \leq \|Dx\|_2^2 \leq (1 + \delta_d) \|x\|_2^2 \quad (1.6)$$

[0106] 其中 $\delta_d$  ( $0 < \delta_d < 1$ )的下确界(定义为 $\delta_{dk}$ )称为观测矩阵的的块有限等距常数;

[0107] 测量矩阵 $D$ 以级联块的方式表示:

$$D = \begin{pmatrix} D_{1,1}, \dots, D_{1,d} & D_{1,d+1}, \dots, D_{1,2d} & \dots & D_{1,N-d+1}, \dots, D_{1,N} \\ \vdots & \vdots & \ddots & \vdots \\ D_{c_0,1}, \dots, D_{c_0,d} & D_{c_0,d+1}, \dots, D_{c_0,2d} & \dots & D_{c_0,N-d+1}, \dots, D_{c_0,N} \\ \vdots & \vdots & \ddots & \vdots \\ T[\tilde{c}_0 1] & T[\tilde{c}_0 2] & \dots & T[\tilde{c}_0 c] \end{pmatrix} \quad (1.7);$$

[0109] 如图1.6所示,其中 $T[ij]$  ( $i \in \{1, \dots, c_0\}$ ,  $j \in \{1, \dots, c\}$ )是矩阵 $D$ 的第 $ij$ 块;对于任意的块列索引集合 $\mathcal{J}_l = \{l_1, \dots, l_i\} \subseteq \{1, \dots, c_0\}$ , 块行索引集合 $\mathcal{J}_r = \{r_1, \dots, r_i\} \subseteq \{1, \dots, c\}$ ,  $|\mathcal{J}_l|$ 和 $|\mathcal{J}_r|$ 分别表示集合 $\mathcal{J}_l$ 和 $\mathcal{J}_r$ 的长度;矩阵 $D$ 满足 $k$ 阶块RIP条件,如果对任意的索引集合 $\mathcal{J}_l \subseteq \{1, \dots, c_0\}$ ,

$co\}$ ,  $\mathcal{I}_r \subseteq \{1, \dots, c\}$ , 且  $|\mathcal{I}_l| * |\mathcal{I}_r| \leq k$ , 满足下式

$$[0110] \quad (1 - \delta_d) \|x_{\mathcal{I}_r}\|_2^2 \leq \|D_{\mathcal{I}_l \mathcal{I}_r} x_{\mathcal{I}_r}\|_2^2 \leq (1 + \delta_d) \|x_{\mathcal{I}_r}\|_2^2 \quad (1.8)$$

[0111] 等价于

$$[0112] \quad (1 - \delta_d)_{j \in \mathcal{I}_r} \|x[j]\|_2^2 \leq \sum_{i \in \mathcal{I}_l} \|T[ij]x[j]\|_2^2 \leq (1 + \delta_d)_{j \in \mathcal{I}_r} \|x[j]\|_2^2 \mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_B], \mathbf{w}_i = [\mathbf{w}_{1i}, \mathbf{w}_{2i}, \dots, \mathbf{w}_{Bi}]^T$$

[0113]  $\delta_d$  ( $0 < \delta_d < 1$ ) 的下确界 (定义为  $\delta_{dk}$ ) 称为观测矩阵  $D$  的块有限等距常数;

[0114] FCNN-CS 的重建阶段: 恢复算法的设计也是压缩感知的核心研究问题之一, 其目标是从压缩测量中恢复出原始图像, 可以表示为形如式 (1.9) 的优化问题;

$$[0115] \quad \min \|x\|_0 \text{ s.t. } y = \Phi x \quad (1.9)$$

[0116] 其中  $\|x\|_0$  表示  $x$  中非零元素的个数, 记为  $l_0$ -范数,  $\Phi$  表示测量矩阵; 求解该问题的主要方法可以分为三类: 贪婪算法, 凸优化算法和基于深度学习的方法;

[0117] 其中联合损失函数中假设  $\{Y_i, X_i\}_{i=1}^Q$  表示  $Q$  对输入的 CS 测量和对应的原始图片, 重构图片为  $\hat{X}_i$ , 则

$$[0118] \quad \hat{X}_i = \mathcal{N}^D \left( \mathcal{N}^L \left( \mathcal{N}^I (Y_i, \mathbf{W}^I), \{\mathbf{W}_k\}_{k=1}^K, \{\mathbf{b}_k\}_{k=1}^K \right), \mathbf{W}^D \right). \quad (1.26)$$

[0119] 我们的目标是使得  $\hat{X}_i$  尽可能的接近原始图片  $X_i$ , 同时使得中间层的稀疏约束成立; 由于我们选择 ReLU 作为激活函数, 可以使得中间层的系数高概率变得稀疏; 也就是说稀疏约束可以被吸收到网络中, 此时, 损失函数就变为

$$[0120] \quad L(\mathbf{W}^I, \{\mathbf{W}_k\}_{k=1}^K, \{\mathbf{b}_k\}_{k=1}^K, \mathbf{W}^D) = \frac{1}{2Q} \sum_{i=1}^Q \|X_i - \hat{X}_i\|_2^2. \quad (1.27)$$

[0121] 其中  $(\mathbf{W}^I, \{\mathbf{W}_k\}_{k=1}^K, \{\mathbf{b}_k\}_{k=1}^K, \mathbf{W}^D)$  为模型  $\mathcal{N}(\cdot)$  的参数;

[0122] 步骤 2, 数值实验: 其中数值实验包括训练设置、重建结果的评价指标、在灰度图上的实验结果对比及讨论和在彩色图上的实验结果对比及讨论; 其中训练设置中的 FCNN-CS 与 Fully-conv 和 CSNet 采用相同的训练集训练, 训练数据集包含 400 幅图像, 由来自 BSDS500 [66] 数据库的 200 幅训练图像和 200 幅测试图像构成和文献 [66] 中的设置一样, 将训练图像裁剪成  $96 \times 96$  像素的子图像, 步长设为 57; 我们还使用了 8 种数据增强方法, 即将原始图像翻转、旋转  $90^\circ$ 、旋转  $90^\circ$  加翻转、旋转  $180^\circ$ 、旋转  $180^\circ$  加翻转、旋转  $270^\circ$  和旋转  $270^\circ$  加翻转; 最后我们得到选取 89600 个子图像进行网络训练; 对于每个图像块, 我们将其输入到基于 CNN 的 CS 框架中; 在给定输入图像  $X$  的情况下, 我们的目标是利用测量网络获得 CS 测量值  $Y$ , 然后使用重建网络从  $Y$  精确地恢复原始输入图像  $X$ ; 由于测量网络的输出是重建网络的输入, 可以直接将它们合并到端到端网络中进行联合优化, 而不需要考虑  $Y$  是什么; 也就是说, 输入和标签都是用于训练 FCNN-CS 的图像  $X$  本身, 训练数据集可以表示为  $Q$  组图像对  $\{X_i, X_i\}_Q$ ;

[0123] 本发明中, 其中重建结果的评价指标中采用图像质量评价领域常用的三个全参考的指标来评估恢复图像质量的好坏, 这三个指标分别为峰值信噪比 (PSNR)、结构相似性 (SSIM) 和基于人类视觉系统的感知相似性 (PSIM):

$$[0124] \quad \text{PSNR} = 10 \times \log_{10} \left( \frac{(2^n - 1)^2}{\text{MSE}} \right) \quad (1.28)$$

[0125] 本发明中,其中MSE表示原图与重建图之间的均方根误差,( $2^n - 1$ )表示信号最大值,当信号为uint8型时,其值为255,为oat型时为1;PSNR指标值越大,就表示失真越少,图像重建效果越好;

$$[0126] \quad \text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (1.29)$$

[0127] 其中 $\mu_x$ 是x的平均值, $\mu_y$ 是y的平均值, $\sigma_x^2$ 是x的方差, $\sigma_y^2$ 是y的方差, $\sigma_{xy}$ 是x和y的协方差; $c_1 = (k_1L)^2$ , $c_2 = (k_2L)^2$ 是用来维持稳定的常数;L是像素值的动态范围; $k_1 = 0.01$ , $k_2 = 0.03$ ;SSIM指标值约接近1,代表图像重建效果越好;

$$[0128] \quad \text{PSIM} = \frac{H^\tau}{L^\alpha} * S^\beta * C^\theta, \quad (1.30)$$

[0129] 其中 $L^\alpha$ 和 $S^\beta$ 分别表示 $\alpha$ 和 $\beta$ 尺度下梯度大小的相似性, $C^\theta$ 表示颜色信息相似性, $H^\tau$ 表示基于高失真池化;PSIM指标值约接近1,代表图像重建效果越好;

[0130] 本发明中,所述在在灰度图上的实验结果对比及讨论中,在 Set11[19](11张图像)和Set14[67](14张图像)两个数据集上测试上述训练得到的四个模型,并且给出了客观评价和主观评价的比较;

[0131] 1.) 客观评价:我们计算了重建图片的PSNR指标来和现有方法进行比较;

[0132] 2.) 主观评价:接下来我们展示了实验所得的恢复视觉效果;

[0133] 在彩色图上的实验结果对比及讨论中通过设置图像的通道 $c = 3$ ,我们的方法可以直接推广到压缩感知彩色图像的恢复;训练数据集为来自BSDS500[66]数据库的200幅训练图像和200幅测试图像构成的400幅彩色图像;对于彩色图像CS,我们在RGB颜色空间上训练了两个模型,分别对应于测量率为0.25和0.04;我们用Set5(5张彩色图片)作为测试集,采样率分别为0.25,0.04时,Set5上重构图片的平均PSNR值分别为32.71dB,24.85dB;图中显示了FCNN-CS在采样率为0.25时的重建结果的四个可视化示例,FCNN-CS获得了良好的彩色图像CS重建;如图所示,很容易可以看出,即使是纹理复杂的图像中,FCNN-CS在像虹膜与睫毛这样细节区域的恢复效果也能取得视觉上与原图相似的观感,PSNR值也达到了较高的水平35.11dB;

[0134] 本发明中,FCNN-CS的重建阶段中贪婪算法若允许少量重建误差存在,式(1.9)可以写为: $\min \|x\|_0 \text{ s.t. } \|\Phi x - y\|_2 \leq \xi$ , (1.10),其中 $\xi$ 表示极小的常量;

[0135] 本发明中,所述FCNN-CS的重建阶段中凸优化算法从求解优化问题的角度来看,式(1.9)中最小化 $l_0$ -范数的问题是非凸的、不易求解的;若将其转化为凸优化问题,则上述问题也就迎刃而解,常见的做法为用 $l_1$ -范数代替 $l_0$ -范数;式(1.9)可以写为: $\min \|x\|_1 \text{ s.t. } y = \Phi x$ , (1.11),其中典型的凸优化算法有:迭代阈值算法(ITA) [31]和基追踪算法(BP);

[0136] 所述FCNN-CS的重建阶段中将整个基于深度卷积神经网络的压缩感知重建过程记为 $\mathcal{N}$ ,反卷积网络记为 $\mathcal{NI}$ ,基于稀疏先验的多层非负软阈值投影算法(MNSTPA)展开的卷

积神经

[0137] 网络结构记为 $\mathcal{NL}$ ,最后的卷积层记为 $\mathcal{ND}$ 。给定CS测量 $Y$ ,重建过程可以被表述为,

$$[0138] \quad \hat{X} = \mathcal{N}(Y) = \mathcal{ND}(\mathcal{NL}(\mathcal{NI}(Y))). \quad (1.12)$$

[0139] 给定CS测量,一些传统的压缩感知恢复方法通常使用一个伪逆矩阵来获得初始的重建图像[20,57]。受此启发,我们通过卷积运算的逆,即反卷积网络(Deconv)来获得与原始图像同纬度的低质量图像特征。假设 $\{Y_i, X_i\}$ 分别表示对应的一组压缩测量和原始图片,反卷积网络恢复得到与原始图像同维度的特征记为 $X_i$ 。对于给定的CS测量 $Y_i$ ,其初步重建

$$[0139] \quad \text{结果为, } \mathbf{X}'_i = \mathcal{N}_I(\mathbf{Y}_i, \mathbf{W}^I) = \tilde{S}_{\text{vect}} \left( \tilde{\mathbf{T}} \cdot S_r(\mathbf{Y}_i) \right) \quad (1.13);$$

参数, $S_{\text{vect}}(\cdot)$ 表示图1.5中图像向量化的逆过程, $T$ 为反卷积操作的矩阵表示。显然,直接求逆得到的初步特征图像与原始图像之间会存在较大的差距。为了减少这种差距,我们在该结构之后再接一个融合了图像稀疏先验的DCNN结构来提高重构图像质量;子网络 $\mathcal{NL}$ 的核心思想是将截断的MNSTPA算法[50]嵌入到DCNN中,同时跟踪相应的稀疏表示。由于压缩感知和稀疏编码模型在图像去噪,图像超分辨率恢复,核磁共振成像(MRI)等计算机视觉任务中取得了先进的结果,采用稀疏编码模型来完成压缩感知的图像重建任务。稀疏编码的目标为将原始图像或信号数据 $x$ 表示为冗余字典 $D$ 中原子的线性组合,其中 $a$ 表示稀疏系数。即

$$[0140] \quad \min_a \|a\|_0 \text{ s.t. } x = Da. \quad (1.14);$$

[0141] 受计算复杂度和硬件成本的限制,该模型在图像处理任务中都是对从整张图像中提取的局部图像块进行操作。在该设置下,要求每个图像重叠块都可以在公共字典下稀疏。但问题是,如何保证公共字典 $D$ 的存在以及全局图像和局部块之间的稀疏一致性。为了解决上述问题,Elad等人提出了多层卷积稀疏编码模型。ML-CSC模型将图像表示为特征映射和相应滤波器的卷积和,并且假设中间层的稀疏表示可以被进一步稀疏分解,即 $X = D_1 A_1$ ,稀疏表示 $A_1$ 可以进一步写为 $A_1 = D_2 A_2$ 。以此类推,设有 $K$ 组字典 $\{D_i\}_{i=1}^K$ ,对应的稀疏表示为 $\{A_i\}_{i=1}^K$ ,ML-CSC模型可以写为,

$$[0142] \quad \text{find } \{A_i, D_i\}_{i=1}^K \text{ s.t. } \left\{ \begin{array}{ll} X = D_1 A_1 & \|A_1\|_1 \leq s_1 \\ A_1 = D_2 A_2 & \|A_2\|_1 \leq s_2 \\ \vdots & \\ A_{K-1} = D_K A_K & \|A_K\|_1 \leq s_K \end{array} \right\}. \quad (1.15)$$

[0143] 其中 $\{s_i\}_{i=1}^K$ 表示每层稀疏表示的稀疏度;由于软阈值算法的简单性,经常被用来求解上式中的优化问题。先固定字典 $D$ ,用 $X$ 乘以 $D^T$ ,并对结果用软阈值算子 $S_\rho(\cdot)$ 进行收缩。 $S_\rho(\cdot)$ 可以通过使向量中较小的元素归零来促进解的稀疏性,其形式定义为:

$$[0144] \quad S_\rho(x) = \begin{cases} x + \rho, & x < -\rho; \\ 0, & -\rho \leq x \leq \rho; \\ x - \rho, & \rho < x; \end{cases} \quad (1.16)$$

[0145] 式(1.15)中的问题可以转为为求解下列问题:

$$[0146] \quad \min_{\mathbf{X}, \mathbf{D}, \{\mathbf{A}_k\}_{k=1}^K} \frac{1}{2} \|\mathbf{X} - \mathbf{D}_{\text{all}} \mathbf{A}_K\|_2^2 + \rho_1 \|\mathbf{A}_1\|_1 + \cdots + \rho_K \|\mathbf{A}_K\|_1. \quad (1.17)$$

[0147] 对应地,可以用多层软阈值投影算法,求解上式,MLSThPA算法的思想为,在每次迭代中计算出第一层和第二层稀疏表示的估计。以此类推,直到得到最深层的估计,

$$[0148] \quad \hat{\mathbf{A}}_K = \mathcal{S}_{\rho_K} \left( \mathbf{D}_K^T \mathcal{S}_{\rho_{K-1}} \left( \mathbf{D}_{K-1}^T \left( \cdots \mathcal{S}_{\rho_1} \left( \mathbf{D}_1^T \mathbf{X} \right) \right) \right) \right). \quad (1.18)$$

[0149] 再从最深层的估计 $\hat{\mathbf{A}}_K$ 就可以很容易地得到中间表示 $\{\mathbf{A}_i\}_{K-1 \leq i \leq 1}$ ,然后进行下一次迭代,直到误差收敛。得到了图像最深层的稀疏表示之后,我们就可以通过下式回溯完成图像恢复任务:

$$[0150] \quad \hat{\mathbf{X}} = \mathbf{D}_1 \mathbf{D}_2 \cdots \mathbf{D}_K \hat{\mathbf{A}}_K = \mathbf{D}_{\text{eff}} \hat{\mathbf{A}}_K, \quad (1.19)$$

[0151] 其中 $\mathbf{D}_{\text{eff}}$ 表示有效字典;

[0152] 式(1.18)的传递很容易让人想起神经网络的前向传递。如图1.7所示,我们可以看到,软阈值函数与ReLU激活函数在正半轴是完全重合的。其中ReLU函数定

[0153] 义为,

$$[0154] \quad \text{ReLU}(x - \rho) = \max(x - \rho, 0). \quad (1.20)$$

[0155] 由此,我们不禁想到了非负稀疏编码[54],它的目标是将原始数据分解为非负稀疏分量。对ML-CSC模型中的稀疏向量加以非负约束,则原模型变为下式:

$$[0156] \quad \text{寻找 } \{\mathbf{A}_i, \mathbf{D}_i\}_{i=1}^K \text{ s.t. } \left\{ \begin{array}{l} \mathbf{X} = \mathbf{D}_1 \mathbf{A}_1, \quad \mathbf{A}_1 \geq 0, \|\mathbf{A}_1\|_1 \leq s_1 \\ \mathbf{A}_1 = \mathbf{D}_2 \mathbf{A}_2, \quad \mathbf{A}_2 \geq 0, \|\mathbf{A}_2\|_1 \leq s_2 \\ \vdots \\ \mathbf{A}_{K-1} = \mathbf{D}_K \mathbf{A}_K, \quad \mathbf{A}_K \geq 0, \|\mathbf{A}_K\|_1 \leq s_K \end{array} \right\}. \quad (1.21)$$

[0157] 在原始ML-CSC模型上加以非负约束并不会影响模的表达能,即模型(1.15)和(1.21)的表达能是相同的。因为模型(1.15)中稀疏表示中的非负项可以被吸收到模型(1.21)的字典中。具体地,原始稀疏模型 $\mathbf{X} = \mathbf{D}\mathbf{A}$ 可以被写为 $\mathbf{D}\mathbf{A} = \mathbf{D}\mathbf{A}^+ - \mathbf{D}\mathbf{A}^-$ ,其中 $\mathbf{A}^+$ 表示所有的正项系数, $\mathbf{A}^-$ 表示所有的负项系数。因为 $\mathbf{A}^+$ 和 $\mathbf{A}^-$ 中的元素都为正,即图像 $\mathbf{X}$ 可以在字典 $[\mathbf{D}, -\mathbf{D}]$ 上被非负稀疏表示 $[\mathbf{A}^+, -\mathbf{A}^-]\mathbf{Y}$ ;显然模型(121)可以通过多层非负软阈值投影算法)求解,其中非负软阈值算子 $\mathcal{S}^+_{\rho}(\cdot)$ 定义为:

$$[0158] \quad \mathcal{S}^+_{\rho}(x) = \begin{cases} 0, & x \leq \rho; \\ x - \rho, & x > \rho. \end{cases} \quad (1.22)$$

[0159] MNSTPA算法的思想是在每次迭代中先后计算出第一层和第二层稀疏表示的估

[0160] 计:  $\hat{\mathbf{A}}_1 = \mathcal{S}^+_{\rho_1}(\mathbf{D}_1^T \mathbf{X})$ ,  $\hat{\mathbf{A}}_2 = \mathcal{S}^+_{\rho_2}(\mathbf{D}_2^T \hat{\mathbf{A}}_1)$ , 同理,依次迭代直到得

到最深层的估计,

$$[0161] \quad \hat{\mathbf{A}}_K = \mathcal{S}_{\rho_K}^+ \left( \mathbf{D}_K^T \mathcal{S}_{\rho_{K-1}}^+ \left( \mathbf{D}_{K-1}^T \left( \dots \mathcal{S}_{\rho_1}^+ \left( \mathbf{D}_1^T \mathbf{X} \right) \right) \right) \right). \quad (1.23)$$

[0162] 再从最深层的估计 $\hat{\mathbf{A}}_K$ 就可以很容易地得到中间表示 $\{\mathbf{A}_i\}_{K-1 \leq i=1}$ ,然后进行下一轮迭代,直到误差收敛。我们在算法1和图1.8中给出了 MNSTPA的具体的步骤和流程示意;

[0163] 本发明中,所述步骤2中训练了四个模型,分别对应不同的测量率 $\text{MR}_s = 0.01, 0.04, 0.1, 0.25$ ,在训练模型时,使用Adam[60]优化器来最小化损失函数。我们将迭代次数设置为50次,每次迭代时的数据批次大小为64,循环1400次。我们依旧采用学习率衰减的方法,将初始学习率设置为 $1e-2$ ,当迭代达到31时,学习速率会下降到 $1e-3$ ,对于Fully-conv和CSNet的训练使用其作者提到的默认参数训练;

[0164] 本发明中,在所述灰度图上的实验结果对比及讨论中FCNN-CS模型、Fully-conv模型、CSNet模型以及CMCS-net模型在测试集Set11、Set14上的PSNR和SSIM结果分别汇总在表1.1和表1.2中。其中最高的PSNR和SSIM值用粗体标记。我们可以看到,FCNN-CS在不同测量率下的重构图像的PSNR和SSIM值都是最高的。如表1.1所示,与CMCS-net、Fully-conv、CSNet相比,在较高的测量率水平下 ( $\text{MR}=0.25$ ) FCNN-CS在测试集Set11中多数图片上有着的最佳的重构性能,在很低的测量率水平下 ( $\text{MR}=0.01$ ) FCNN-CS在Set11中所有图片上都取得了最佳的重构性能。如表1.2所示,当测量率降低时, FCNN-CS在Set14上的重构结果与第二好的结果之间的差值有所提升,在较高的测量率水平下 ( $\text{MR}=0.25$ 和 $\text{MR}=0.1$ ) FCNN-CS比CSNet 在测试集Set14上的重构图片的PSNR只高出0.23 {0.41dB,而在较低的测量率水平下 ( $\text{MR}=0.01$ 和 $\text{MR}=0.04$ ) FCNN-CS比CSNet在Set14 上的重构图片的PSNR高出0.72-0.76dB;

[0165] 本发明中,在所述灰度图上的实验结果对比及讨论中如图1.9,图1.10,图1.11和图1.12所示,图中列出了测量率分别为0.25,0.1 和0.04时,图像Baboon,Flowers,Comic和Buttery分别通过算法 Fully-conv,CSNet,FCNN-CS重建的视觉效果图。很容易可以看出,即使是在纹理复杂的图像中,相比与其他两种方法FCNN-CS模型在细节处的恢复效果也能取得视觉上令人满意的观感。如图1.9所示, Fully-conv,CSNet的恢复的图片放大之后胡子处会有点模糊,而 FCNN-CS恢复出的胡子最接近原始图片。我们的结果PSNR值比CSNet高出0.78dB。如图1.10所示,在放大的红色窗口中,Fully-conv, CSNet的恢复的图片放大之后看不出花蕊处的细节,而FCNN-CS恢复出的花蕊最接近原始图片。我们还注意到,在测量率降低为0.1 时,FCNN-CS模型在图片的线条处恢复效果依然能取得视觉上令人满意的观感。如图1.11所示,在像人物的头饰以及背景围栏这样有明显分界的地方,Fully-conv和CSNet恢复得到的图片会出现明显的伪影,而FCNN-CS恢复得到的图片中线条会更加流畅。我们的结果 PSNR值比Fully-conv和CSNet分别高出0.62dB、0.51dB。当测量率降为更低的水平时,即 $\text{MR}=0.04$ 时,FCNN-CS模型在图片的线条处恢复效果依然优于Fully-conv和CSNet,从而提高了恢复性能。如图1.12所示,Fully-conv和CSNet恢复得到的图片会出现明显的伪影,而FCNN-CS恢复得到的图片中花瓣与背景之间的分界线会更加分明。

[0166] 表1.1:在不同的测量率下,不同算法Set11测试集上重构图像的 PSNR指标(单位: dB) 和SSIM指标比较;

图像	算法	MR=0.25	MR=0.1	MR=0.04	MR=0.01
		PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
Barbara	Fully-conv <sup>[64]</sup>	28.61/0.8758	24.29/0.7278	23.35/0.6358	21.67/0.5138
	CMCS-net <sup>[68]</sup>	24.45/0.8384	-/-	<b>23.56/0.6520</b>	21.63/0.5269
	CSNet <sup>[65]</sup>	28.06/0.8682	24.37/0.7319	23.40/0.6401	21.67/0.5155
	FCNN-CS	<b>29.80/0.9050</b>	<b>24.52/0.7559</b>	<b>23.54/0.6580</b>	<b>22.01/0.5489</b>
Parrot	Fully-conv	32.03/0.9357	27.78/0.8876	24.34/0.8035	22.23/0.7280
	CMCS-net	<b>33.42/0.9557</b>	-/-	24.44/ <b>0.8442</b>	21.76/0.7330
	CSNet	32.18/0.9405	28.41/0.8984	24.55/0.8132	22.24/0.7304
	FCNN-CS	32.60/0.9509	<b>28.47/0.9067</b>	<b>24.89/0.8336</b>	<b>22.77/0.7539</b>
Peppers	Fully-conv	32.76/0.9288	27.90/0.8707	23.90/0.7444	20.67/0.6107
	CMCS-net	28.70/0.9363	-/-	23.45/0.8020	19.73/0.6098
	CSNet	33.20/0.9354	28.10/0.8770	23.92/0.7534	20.70/0.6131
	FCNN-CS	<b>33.52/0.9453</b>	<b>29.29/0.8976</b>	<b>24.80/0.8025</b>	<b>21.11/0.6544</b>
Boats	Fully-conv	33.78/0.9362	29.37/0.8537	25.32/0.7057	21.88/0.5531
	CMCS-net	32.53/0.9359	-/-	24.96/0.7397	21.09/0.5374
	CSNet	34.10/0.9392	29.49/0.8617	25.36/0.7086	21.86/0.5531
	FCNN-CS	<b>35.69/0.9704</b>	<b>30.01/0.8845</b>	<b>26.28/0.7633</b>	<b>22.33/0.5964</b>
Cameraman	Fully-conv	29.26/0.8988	25.71/0.8266	22.49/0.7040	20.32/0.6288
	CMCS-net	28.76/0.9046	-/-	22.96/0.7490	20.24/0.6413
	CSNet	29.40/0.9036	25.79/0.8356	22.61/0.7155	20.27/0.6267
	FCNN-CS	<b>29.76/0.9164</b>	<b>26.05/0.8509</b>	<b>23.35/0.7594</b>	<b>20.73/0.6602</b>
Fingerprint	Fully-conv	31.97/0.9669	26.76/0.8906	20.77/0.6654	16.20/0.1690
	CMCS-net	<b>32.46/0.9678</b>	-/-	20.08/0.6406	16.00/0.1702
	CSNet	32.33/ <b>0.9683</b>	<b>26.81/0.8936</b>	21.06/0.6808	16.25/0.1790
	FCNN-CS	32.11/0.9674	26.19/0.8836	<b>21.26/0.6932</b>	<b>16.31/0.2109</b>
Flinstones	Fully-conv	29.98/0.8918	24.72/0.7932	19.52/0.5617	16.59/0.3888
	CMCS-net	30.47/ <b>0.9085</b>	-/-	20.05/ <b>0.6855</b>	16.17/0.4055
	CSNet	30.16/0.8955	24.78/0.8037	19.92/0.5863	16.59/0.3879
	FCNN-CS	<b>30.69/0.9054</b>	<b>25.91/0.8364</b>	<b>20.71/0.6635</b>	<b>17.05/0.4366</b>
Foreman	Fully-conv	36.97/0.9491	33.55/0.9118	29.62/0.8403	26.36/0.7635
	CMCS-net	<b>38.67/0.9663</b>	-/-	30.59/ <b>0.8839</b>	26.07/0.7799
	CSNet	37.74/0.9578	<b>34.50/0.9255</b>	29.97/0.8559	26.43 /0.7722
	FCNN-CS	<b>38.17/0.9684</b>	<b>34.40/0.9357</b>	<b>31.25/0.8818</b>	<b>27.20/0.8027</b>
	Fully-conv	35.90/0.9107	32.36/0.8672	27.70/0.7735	23.65/0.6797

[0167]

续表 1.1

图像	算法	MR=0.25	MR=0.1	MR=0.04	MR=0.01
		PSNR/SSIM	PSNR/SSIM	PSNR/SSIM	PSNR/SSIM
House	CMCS-net	35.20/0.9171	-/-	26.79/0.8113	22.48/0.6784
	CSNet	36.24/0.9164	32.56/0.8754	27.63/0.7811	23.71/0.6878
	FCNN-CS	<b>36.65/0.9320</b>	<b>32.72/0.8854</b>	<b>29.12/0.8241</b>	<b>24.72/0.7318</b>
Lena	Fully-conv	32.46/0.9342	28.92/0.8652	25.41/0.7459	22.10/0.6161
	CMCS-net	<b>33.34/0.9545</b>	-/-	26.00/0.7930	21.67/0.6183
	CSNet	32.88/0.9410	29.00/0.8704	25.54/0.7544	22.10/0.6193
	FCNN-CS	33.07/0.9503	<b>29.27/0.8878</b>	<b>26.28/0.7959</b>	<b>22.86/0.6706</b>
Monarch	Fully-conv	32.21/0.9548	27.67/0.8906	23.01/0.7483	18.01/0.5320
	CMCS-net	32.63/ <b>0.9686</b>	-/-	22.54/0.7923	17.75/0.5388
	CSNet	32.53/0.9588	28.12/0.9020	23.09/0.7568	18.05/0.5335
	FCNN-CS	<b>32.76/0.9662</b>	<b>28.67/0.9189</b>	<b>24.01/0.8102</b>	<b>18.73/0.5922</b>
Mean PSNR	Fully-conv	32.36/0.9257	28.09/0.8532	24.13/0.7208	20.88/0.5616
	CMCS-net	31.87/0.9322	-/-	24.13/0.7630	20.42/0.5672
	CSNet	32.62/0.9326	28.36/0.8614	24.28/0.7315	20.90/0.5653
	FCNN-CS	<b>33.16/0.9425</b>	<b>28.68/0.8767</b>	<b>25.05/0.7730</b>	<b>21.44/0.6053</b>

[0168] 表1.2:在不同的测量率下,不同算法Set14测试集上重构图像的 PSNR(单位:dB)和SSIM指标比较;

	Fully-conv PSNR/SSIM	CSNet PSNR/SSIM	FCNN-CS PSNR/SSIM
MR=0.25	31.21/0.8891	31.46/0.8975	<b>31.69/0.9061</b>
MR=0.1	27.57/0.7913	27.74/0.8019	<b>28.15/0.8153</b>
MR=0.04	24.38/0.6589	24.46/0.6643	<b>25.22/0.6937</b>
MR=0.01	21.33/0.5195	21.46/0.5281	<b>22.18/0.5649</b>

[0169]

[0170] 本发明中,压缩感知理论的提出打破了传统的采样理论,它可以在远小于Nyquist采样率的条件下获取信号的测量值,并保证信号的无失真重建。如何设计测量矩阵使得采样效率达到最佳,以及如何设计重建算法使得重建效果达到更高的质量,仍然是压缩感知领域内研究的两大热点问题。针对这两个问题,本文提出了基于学习的卷积压缩采样并给出了该测量方法的理论保障,还根据稀疏先验下的多层非负软阈值投影算法设计了包含重复迭代模块的卷积神经网络来恢复图像。将测量网络与恢复网络联合训练,相比于传统的

与图像无关的分块测量方法,这种基于学习的测量方法可以自适应的学习图像的信息,在相同的测量率下能够保留更多的信息和有效的消除块效应;相比于已有的基于神经网络的压缩感知恢复算法,我们的网络结构根据算法来设计,为深度卷积神经网络的理论解释提供了新思路。

[0171] 以上所述,仅为本发明较佳的具体实施方式,但本发明的保护范围并不局限于此,任何熟悉本技术领域的技术人员在本发明揭露的技术范围内,根据本发明的技术方案及其发明构思加以等同替换或改变,都应涵盖在本发明的保护范围之内。



图1.1



图1.2

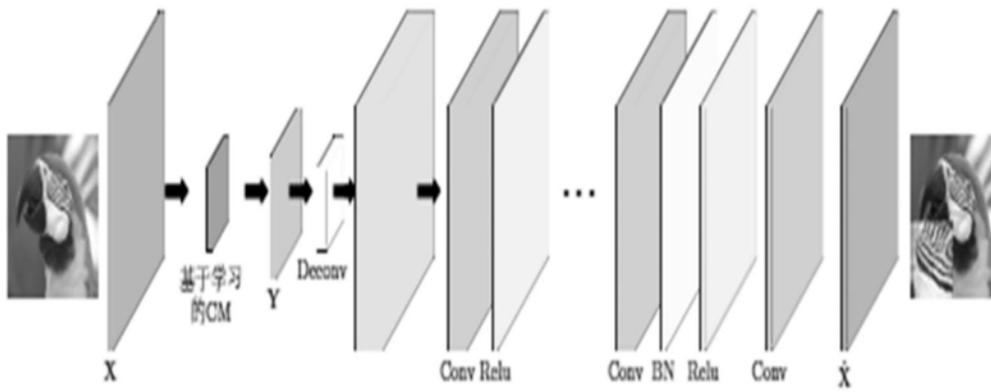


图1.3

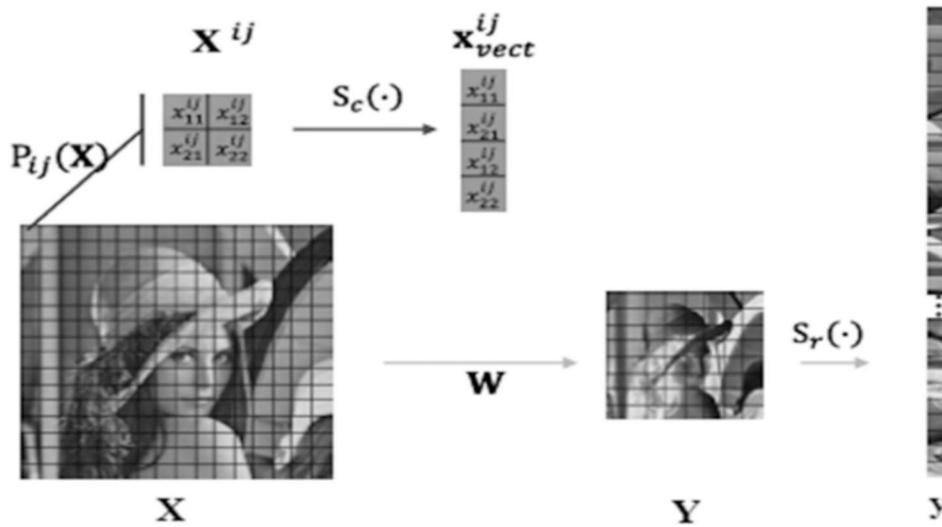


图1.4

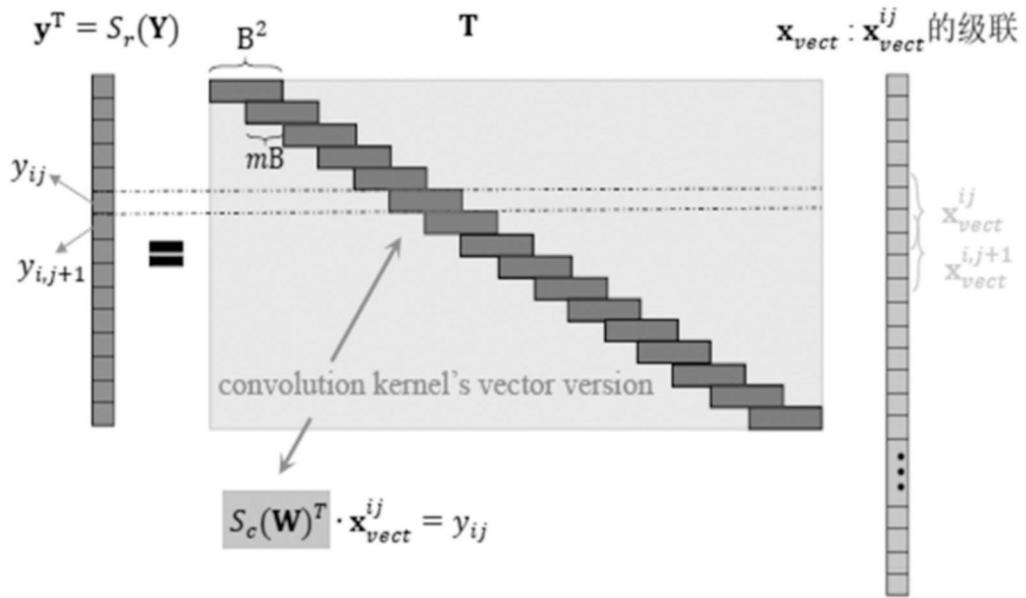


图1.5

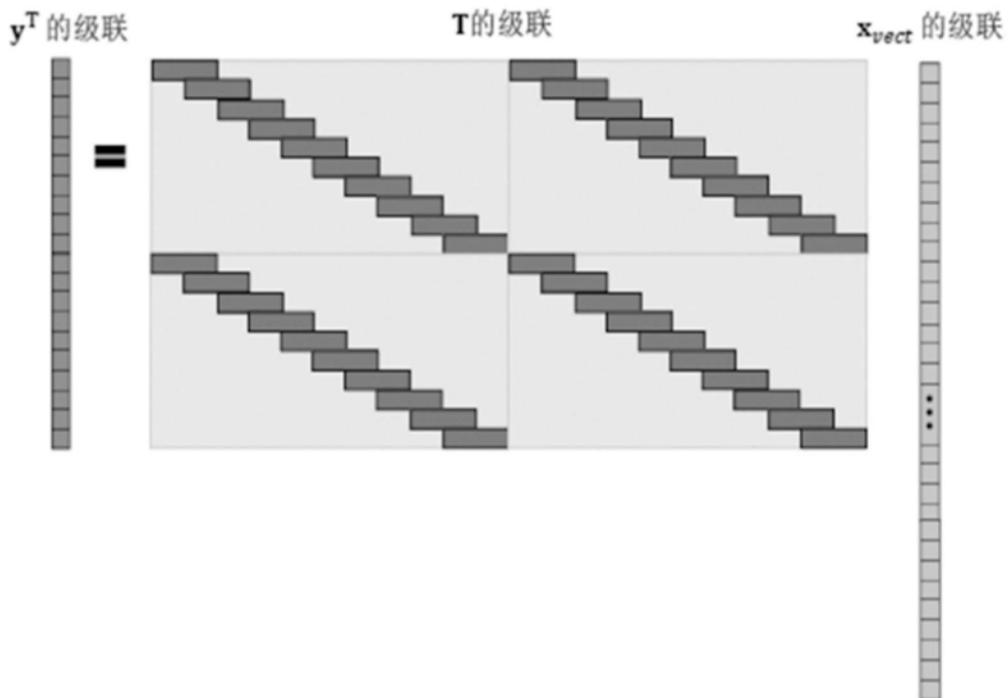


图1.6

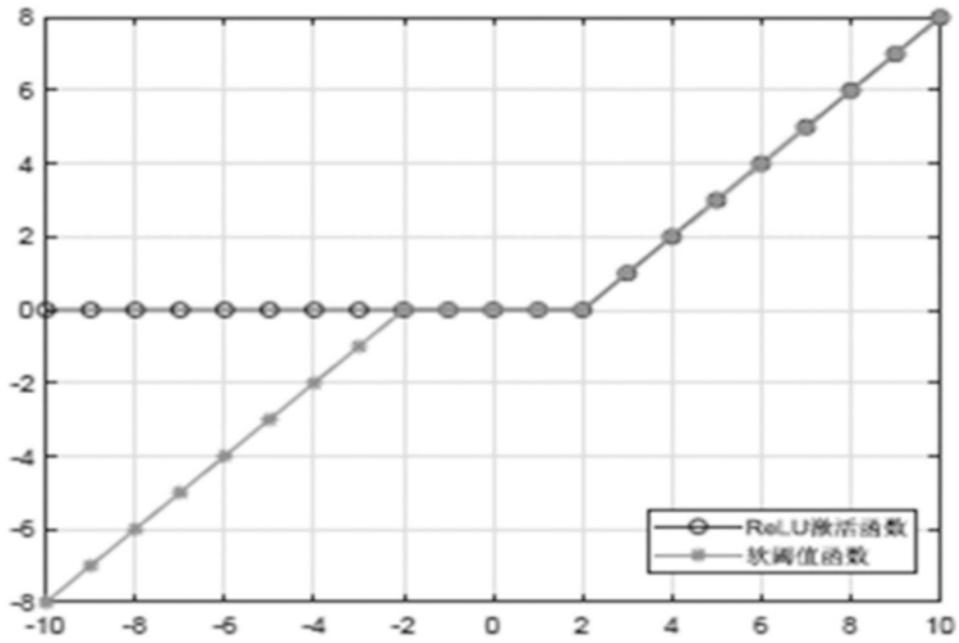


图1.7

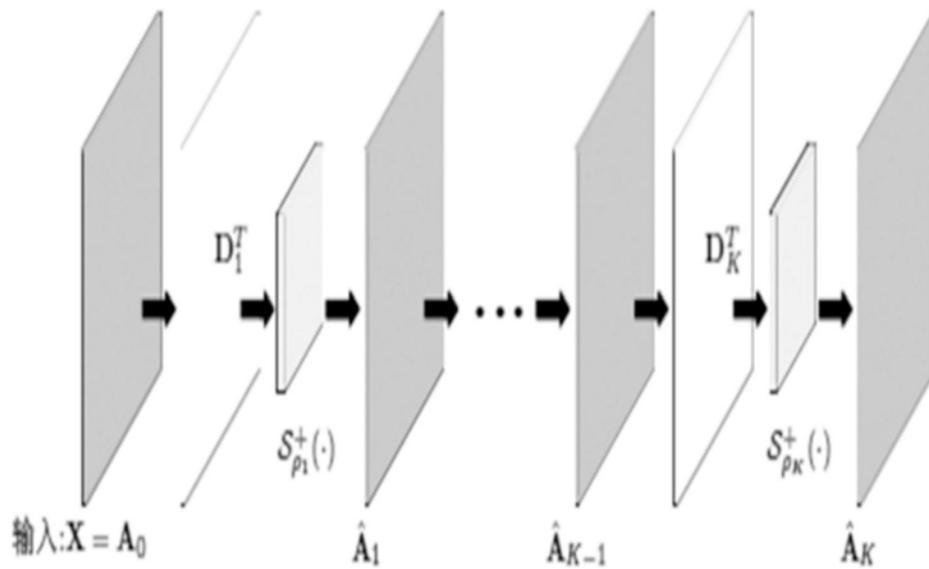


图1.8

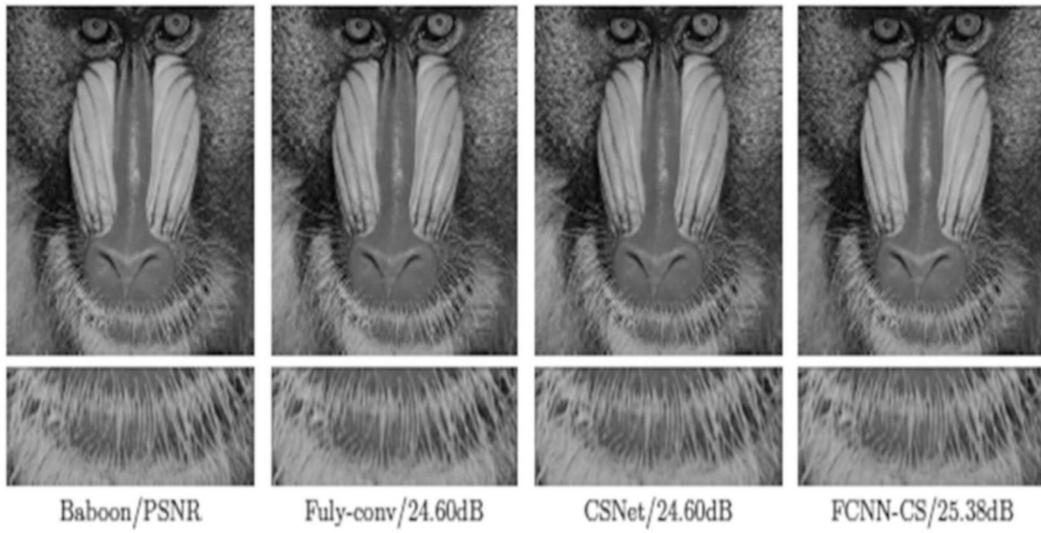


图1.9

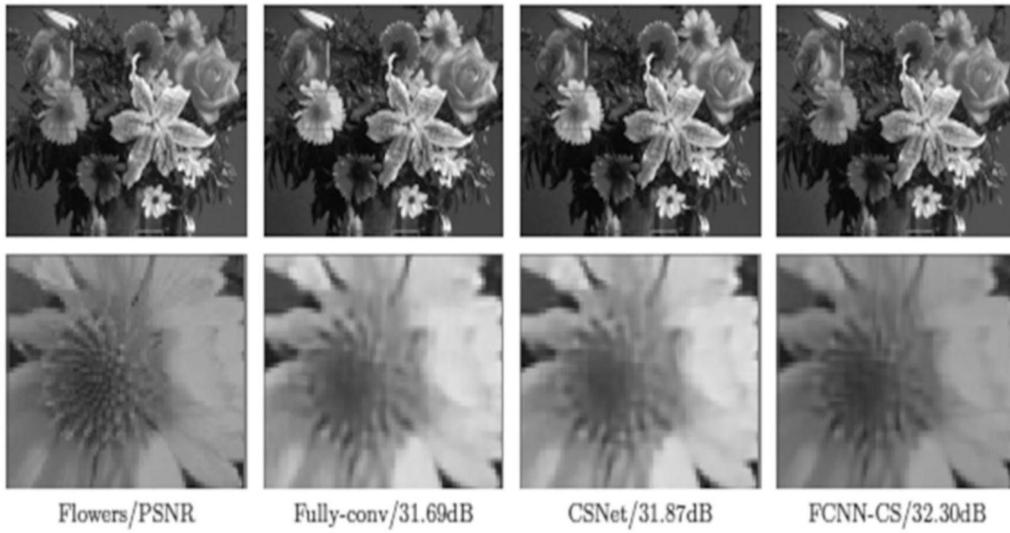


图1.10

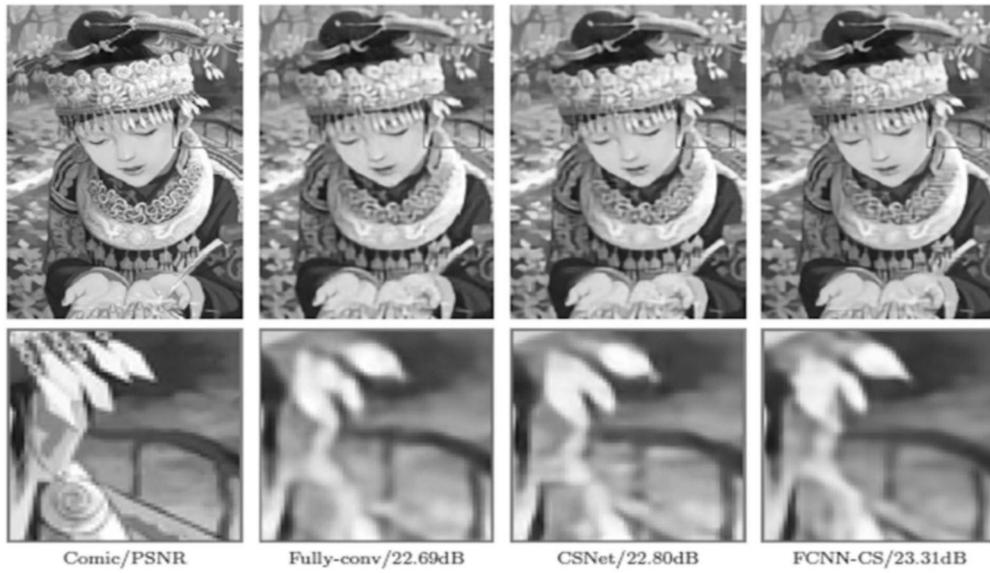


图1.11

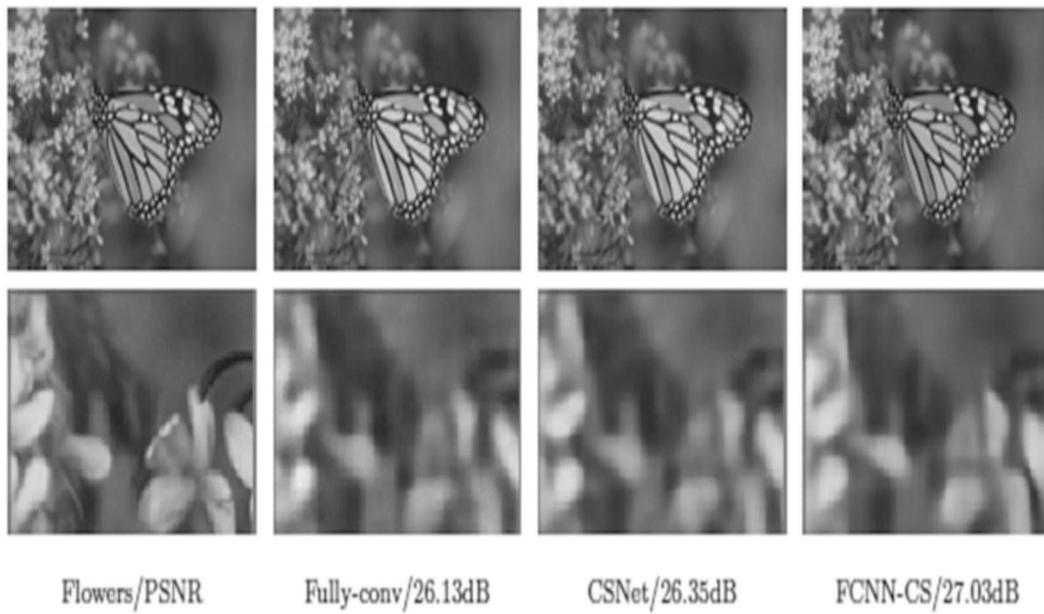


图1.12