

doi: 10.3788/gzxb20144305.0510002

一种数字微镜阵列分区控制和超分辨重建的 压缩感知成像法

刘海英, 李云松, 吴成柯

(西安电子科技大学 综合业务网国家重点实验室, 西安 710071)

摘 要:提出一种压缩感知成像框架结构. 该结构采样端用新建的采样矩阵实现数字微镜阵列分区控制, 可增强信息获取的准确性, 测量得到与新数字微镜阵列对应的压缩采样值; 重构端由采样值优化重构出低分辨率图像后, 根据分区控制过程建立压缩感知理论框架下的超分辨重建模型, 利用梯度稀疏约束优化算法进行求解, 恢复出原高分辨率图像. 实验结果表明: 数字微镜阵列分区控制与超分辨重建相结合的方法可以明显降低压缩感知成像系统的计算量, 缩短成像时间, 并且具有较高的图像重构质量.

关键词:光学成像; 成像系统; 压缩感知; 超分辨重建; 总变差算法; 数字微镜阵列; 优化

中图分类号: TN957.52

文献标识码: A

文章编号: 1004-4213(2014)05-0510002-8

A Method for Compressive Sensing of Images Based on Zone Control of Digital Micromirror Device and Super-resolution

LIU Hai-ying, LI Yun-song, WU Cheng-ke

(State Key Laboratory of Integrated Service Networks, Xidian University, Xi'an 710071, China)

Abstract: A compressive sensing based imaging framework was proposed. At the sampling end, in order to enhance the acquisition accuracy of information, a new measurement matrix was designed to carry out zone control on digital micromirror device and the new digital micromirror device with zone control was used to make compressive measurements. At the recovery end, a low resolution image was first recovered by solving an optimization problem from the received measurements. Then, the modeling of a super-resolution problem in a compressive sensing framework was constructed according to the zone control process, and a total variation algorithm was exploited to solve such a compressive sensing based super-resolution problem for the high resolution image. Experimental results show that the proposed method based on zone control of digital micromirror device and super-resolution reconstruction can greatly shorten the imaging time and has very low computational complexity and excellent recovery performance.

Key words: Optical imaging; Imaging systems; Compressive Sensing (CS); Super-Resolution (SR); Total Variation (TV); Digital Micromirror Device (DMD); Optimization

OCIS Codes: 100.3010; 100.3090; 110.1758; 110.3010

0 引言

现有的以奈奎斯特采样定理为基础的信号采样技术要求采样速度必须达到信号带宽的两倍以上才能精确重构信号. 然而, 随着人们对信息量的需求日益增加, 现有技术对于采样和存储设备的要求急剧提高, 这

使得设备制造难度加大, 成本激增. 同时, 由于信号的可压缩性, 在该采样模式下, 实际上大量的采样和存储资源被浪费在冗余信息上. 压缩感知理论^[1-4] (Compressive Sensing, CS) 为从根本上解决此类采样问题提供了有力的理论支持. 该理论指出: 信号采样可以不受限于信号带宽, 而取决于信号所含信息的内容

基金项目: 国家优秀青年科学基金 (No. 61222101)、国家自然科学基金 (Nos. 61301291, 61072065, 61007011) 和 111 基地项目 (No. B08038) 资助

第一作者: 刘海英 (1982-), 女, 博士研究生, 主要研究方向为深空通信. Email: hylu@mail.xidian.edu.cn

导师 (通讯作者): 吴成柯 (1938-), 男, 教授, 博导, 主要研究方向为深空通信. Email: ckwu@mail.xidian.edu.cn

收稿日期: 2013-09-26; **录用日期:** 2013-11-26

<http://www.photon.ac.cn>

及信息在信号中的结构. CS 理论的直接信息采样特性,使其具备有效解放硬件资源的能力,在雷达成像^[5-6]、医学成像^[7-8]、高分辨率遥感探测^[9-11]等领域有着广泛的应用前景.

压缩感知光学成像^[12-14] (Compressive Imaging, CI) 技术是压缩感知理论在光学成像领域的成功应用. 在图像像素个数不变的条件下, CI 技术实现了采样量远低于像素个数和单个光子探测器成像,有效地解决了高分辨率探测器阵列制造困难、成本高和冗余信息的问题. 但现有以数字微镜阵列 (Digital Micromirror Device, DMD) 为信息抽取器件的 CI 技术,实际上是将传统的并行采样转换为串行采样,虽减少了采样量,但增加了采样的时间. 加之 CI 技术本质上是一种计算成像,其算法需较长运算时间,使得该技术难以实时成像和高帧频成像,极大地限制了该技术的发展和推广应用.

针对 CI 技术存在的问题,本文提出一种基于 DMD 分区控制与超分辨重建的压缩感知成像新方法. 采样端利用 DMD 分区控制方法,降低 DMD 分辨率,达到减小重构时测量矩阵大小的目的;重构端用较少的计算量由压缩采样值优化重构得到与新 DMD 对应的低分辨率图像后,根据分区控制过程建立 CS 理论框架下的超分辨重建模型,并利用梯度稀疏约束优化算法进行求解,恢复出原高分辨率图像. 实验结果表明,与现有 CS 方法相比,该方法可以大大缩短压缩感知成像系统的成像时间和降低计算量,并且具有更好的图像重构质量.

1 压缩感知理论

考虑一个一维实值离散信号 $\mathbf{X} \in R^N$, 在某个正交基或紧框架 $\Psi \in R^{N \times N}$ 下是 S 稀疏的,即变换系数向量 $\boldsymbol{\theta} = \Psi \mathbf{X}$, $\|\boldsymbol{\theta}\|_0 = S$. 用测量矩阵 $\Phi \in R^{M \times N}$, $M < N$, 对 \mathbf{X} 进行非自适应线性测量,得到 M 维的测量向量 \mathbf{Y} ,即

$$\mathbf{Y} = \Phi \mathbf{X} = \Phi \Psi \boldsymbol{\theta} \quad (1)$$

显然,由于 \mathbf{Y} 的维度小于 \mathbf{X} 的维度,满足式(1)的解有无穷多个,很难由 \mathbf{Y} 精确重构出 \mathbf{X} . 但 CS 理论指出,如果 $\Phi \Psi$ 满足有限等距性质 (Restricted Isometry Property, RIP)^[3-4,15], 就可以通过求解 ℓ_1 -范数最小化问题,从少量的测量值 \mathbf{Y} 中精确或 1 概率重构出原信号 \mathbf{X} ,即

$$\hat{\mathbf{X}} = \operatorname{argmin} \|\Psi^T \mathbf{X}\|_1 \text{ s. t. } \Phi \mathbf{X} = \mathbf{Y} \quad (2)$$

式中, $\|\cdot\|_1$ 为 ℓ_1 -范数,表示向量所有元素的绝对值之和,即 $\|\boldsymbol{\theta}\|_1 = \sum_{i=1}^N |\theta_i|$.

$\Phi \Psi$ 具有 S 阶 RIP 性质,是指 $\Phi \Psi$ 满足,

$$(1 - \delta_s) \|\mathbf{X}\|_2^2 \leq \|\Phi \Psi \boldsymbol{\theta}\|_2^2 \leq (1 + \delta_s) \|\mathbf{X}\|_2^2 \quad (3)$$

式中 \mathbf{X} 表示所有 S 稀疏信号 ($\mathbf{X} = \Psi \boldsymbol{\theta}$), δ_s 为等距常量, $0 < \delta_s < 1$. 直接证明 RIP 性质是非常困难的,文献 [1,15] 给出了 RIP 性质的另一种等价性证明,即如果能够证明测量矩阵 Φ 与稀疏基 Ψ 高度不相关,就说明 $\Phi \Psi$ 具有良好的 RIP 性质. 相干系数 $\mu(\Phi, \Psi)$ 定义为^[1,15]

$$\mu(\Phi, \Psi) = \sqrt{N} \max_{j,k} |\langle \boldsymbol{\phi}_j, \boldsymbol{\psi}_k \rangle| \quad (4)$$

式中 $\boldsymbol{\phi}_j$ 为测量矩阵 Φ 的行向量, $\boldsymbol{\psi}_k$ 为稀疏基 Ψ 的列向量 ($\|\boldsymbol{\phi}_j\|_2 = 1, j = 1, 2, \dots, M, \|\boldsymbol{\psi}_k\|_2 = 1, k = 1, 2, \dots, N$). $\mu(\Phi, \Psi)$ 越小,表明 Φ 与 Ψ 不相干程度越高, $\Phi \Psi$ 具有更高阶的 RIP 性质,信号重构准确度就越高.

ℓ_1 -范数最小化问题式(2)本质上是一个凸优化问题,可方便地化简为线性规划问题进行求解. 目前已提出一些效率较高的重构算法,如正交匹配追踪^[16] (Orthogonal Matching Pursuit, OMP), 总变差^[17] (Total Variation, TV) 和基于模型的自适应重构^[18] (Model-based Adaptive Recovery, MARX) 等算法.

2 基于 DMD 分区控制和超分辨重建的压缩感知成像方法

CS 单像素相机^[12-13] 是美国 Rice 大学 Takhar, Duarte 等人于 2006 年提出的一种基于 CS 理论的全新成像方法. CS 单像素相机主要包括:采样过程和重构过程. 采样过程使用 DMD 完成图像在伪随机二值模型上的线性投影的光学计算,然后用单个光子探测器多次检测得到一组比图像点数少得多的测量值;重构过程采用优化算法从少量的测量值中恢复出原图像. 不难看到,单像素相机是以增加采样时间和重构端的计算复杂度来换取硬件采样成本的减少. 而采样时间与采样量成正比,CS 重构算法的计算复杂度主要取决于信号 \mathbf{X} 与测量矩阵 Φ 的乘积,计算量与 Φ 的大小成正比. 例如基追踪算法 (Basic Pursuit, BP) 的复杂度量级为 $O(N^3)$ (其中 $\mathbf{X} \in R^N, \Phi \in R^{M \times N}$),即使是常见的图像尺寸,计算量都是非常大的. 为了缩短成像系统的采样时间和降低计算量,本文考虑从采样端出发,提出一种基于 DMD 分区控制和超分辨重建的压缩感知成像方法,总体框图如图 1 所示. 采样端来自成像场景 \mathbf{X} 上的光线经第一个镜头汇聚投影在分区控制的 DMD 上,进行成像光束的选择;被选择的成像光束经第二个镜头汇聚后,由单个光子探测器接收,获得一个采样值,重复此过程 M 次,即可获得对应于低分辨率场景 \mathbf{X} 的压缩采样值向量 \mathbf{Y} ;重构端首先通过优化算法从采样值 \mathbf{Y} 中重构出低分辨率图像 \mathbf{X}_1 ,最后使用基于 CS 框架的超分辨重建算法由 \mathbf{X}_1 恢复出场景 \mathbf{X} 的高分辨率图像 $\hat{\mathbf{X}}$.

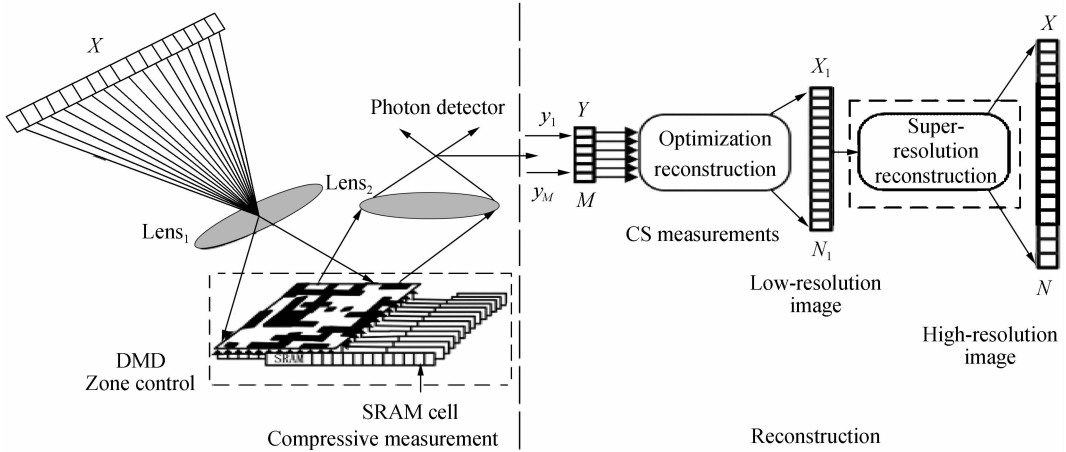


图1 系统总体框图

Fig.1 System diagram

2.1 DMD 分区控制

DMD 分区控制的目的是增强信息获取的准确性,缩短成像时间;通过减小重构时测量矩阵的大小,降低重构端的计算量。在单像素相机中,DMD 上每个微镜的翻转是通过编程控制与之相对应的单个静态存储器(Static Random Access Memory, SRAM)单元的加载状态来完成,而 SRAM 的加载状态由所构建的(0,1)二进制随机测量矩阵的元素取值决定。当元素取值为“1”时,即 SRAM 单元的加载状态为“1”,微镜翻转后与水平轴成 $+10^\circ$ 角,投影在该微镜上的光束被反射进入第二个镜头,经第二个镜头汇聚后被光子探测器接收,表示该成像光束被选择;当元素取值为“0”时,SRAM 单元的加载状态为“0”,微镜翻转后与水平轴成 -10° 角,投影在该微镜上的光束被反射掉,表示该成像光束不被选择。

DMD 分区控制过程如图 2。具体操作是:通过构建分区(0,1)二进制随机矩阵给每个分区内的 SRAM 单元加载相同状态,使在该分区的微镜朝同一方向翻转。进行分区控制后的新 DMD 实际上是一个分辨率降低了的 DMD,它的每个微镜由原 DMD 中同一区域的微镜组合而成,而与新 DMD 对应的(0,1)二进制随机矩阵与分区(0,1)二进制随机矩阵相比,大小变小了,相应地由新 DMD 获取的压缩采样数据进行优化重构时用的测量矩阵大小也变小了,用很少的计算量就可以恢复出场景 \mathbf{X} 的低分辨率图像 \mathbf{X}_1 。记对应于原 DMD(大小为 $m \times n$)的重构时用的测量矩阵为 $\Phi_{\text{original}} = [\phi_0^i]_{i=1}^M$,其中 ϕ_0^i 为第 i 个测量行向量, ϕ_0^i 为第 i 次采样时用的分区(0,1)二进制随机矩阵的行向量表示,长度为 $N = m \times n$, M 为测量次数。记对应于新 DMD(大小为 $m_1 \times n_1$)的重构时用的测量矩阵为 $\Phi_{\text{new}} = [\phi_n^i]_{i=1}^M$,其中 ϕ_n^i 为第 i 个测量行向量, ϕ_n^i 为第 i 次采样时用的(0,1)二进制随机矩阵的行向量表示,长度为 $N_1 = m_1 \times n_1$ 。由于 $N_1 < N$,所以新测量矩阵 $\Phi_{\text{new}} \in$

$R^{M \times N_1}$ 的大小小于原测量矩阵 $\Phi_{\text{original}} \in R^{M \times N}$ 。例如在图 2 中,经过分区控制后,每四个微镜组合成一个新的微镜,大小为 6×6 的 DMD 变成了大小为 3×3 的 DMD,相应地大小为 6×6 的分区(0,1)二进制随机矩阵变成了大小为 3×3 的(0,1)二进制随机矩阵,而对应的用于重构时的测量行向量由 ϕ_0 变成 ϕ_n ,即




图2 DMD 分区控制

Fig.2 Zone control of DMD

$$\phi_0 = \text{vec} \begin{pmatrix} 1 & 1 & 0 & 0 & 1 & 1 \\ 1 & 1 & 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 & 1 & 1 \\ 1 & 1 & 0 & 0 & 1 & 1 \end{pmatrix}_{6 \times 6}, \quad \phi_n = \text{vec} \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 1 \end{pmatrix}_{3 \times 3} \quad (5)$$

式中,行向量 ϕ_0 的长度为 36,行向量 ϕ_n 的长度为 9。符号 $\text{vec}(\cdot)$ 表示将矩阵向量化,遵循从上到下、从左到右的原则。对于矩阵 $\mathbf{A} = [a_{i,j}]$ (其中 $a_{i,j}$ 表示 \mathbf{A} 的第 i 行第 j 列元素, $i = 1, 2, \dots, m, j = 1, 2, \dots, n$), $\text{vec}(\mathbf{A}) = [a_{11}, a_{21}, \dots, a_{m1}, a_{12}, a_{22}, \dots, a_{m2}, \dots, a_{1n}, a_{2n}, \dots, a_{mn}]$ 。此时,新测量矩阵 $\Phi_{\text{new}} \in R^{M \times 9}$ 的大小只有原测量矩阵 $\Phi_{\text{original}} \in R^{M \times 36}$ 的四分之一。

所以说 DMD 分区控制方法可以有效减小测量矩阵的大小,从而达到降低重构端计算复杂度的目的。另

一方面,由于分区控制后的新 DMD 所成之像为低分辨率图像 \mathbf{X}_1 ,最后需要采用超分辨重建算法恢复出高分辨率图像 $\hat{\mathbf{X}}$.

2.2 基于 CS 理论框架的超分辨重建

根据 DMD 分区控制过程,建立低分辨率图像 \mathbf{X}_1 与高分辨率图像 \mathbf{X} 之间的成像模型,即

$$\mathbf{X}_1 = \mathbf{R}\mathbf{L}_p\mathbf{X} = \mathbf{L}\mathbf{X}, \mathbf{X} \in \mathbb{R}^{m \times n}, \mathbf{X}_1 \in \mathbb{R}^{m_1 \times n_1} \quad (6)$$

式中 \mathbf{L}_p 是低通滤波器, \mathbf{R} 是下采样算子. 因为线性算子之间的乘积运算仍是线性的,记线性算子 $\mathbf{L} = \mathbf{R}\mathbf{L}_p$ 为超分辨重建问题(6)的投影矩阵. 定义放大系数为 $U = N/N_1$ ($N = m \times n$, $N_1 = m_1 \times n_1$). 图 3 给出一个从 6×6 图像中获取 2×2 图像的例子. 从图 3 可以看出,投影矩阵 \mathbf{L} 是一个非常稀疏的正交循环矩阵,每一行只有 U 个非零元素,每一列仅有一个非零元素,所以用于重构时的计算量是很低的.




图 3 低分辨率图像的成像模型

Fig. 3 Low resolution image generation model

不难看到,式(6)是一个欠定逆问题,可采用简单的图像插值算法,如两次立方插值算法,从低分辨率图像 \mathbf{X}_1 中恢复出高分辨率图像 \mathbf{X} ,但是由于这类超分辨重建算法没有引入新的信息量,容易产生过平滑效应,造成重建图像模糊;也可以采用复杂的基于机器学习^[19]和稀疏表示^[20]的超分辨重建算法对问题式(6)进行求解,这类算法的重建效果好,但同时计算复杂度也较高.根据 CS 理论得知,CS 是求解欠定逆问题的有力工具,所以本文提出一种低复杂度的基于 CS 的超分辨重建算法对式(6)进行求解.

根据 CS 理论,只需证明投影矩阵 \mathbf{L} 与稀疏基 Ψ 的相干系数 $\mu(\mathbf{L}, \Psi)$ 很小即可.为简单起见,不妨假设低通滤波器 \mathbf{L}_p 采用线性平滑滤波器,滤波器系数均为 1,则投影矩阵 \mathbf{L} 中的每一行仅有 U 个元素为 1.对 \mathbf{L} 进行归一化处理,每个元素乘以因子 $\frac{1}{\sqrt{U}}$,则每行的最大元素值 $\max_{j,t} |\mathbf{L}_j(t)| = \frac{1}{\sqrt{U}}$ ($t \in T = \{t_1, t_2, \dots, t_U\}$, $T \in \{1, 2, \dots, N\}$).假设稀疏基 Ψ 中每一列至少有 αN ($0 < \alpha \leq 1$) 个非零元素 (Ψ 为稠密稀疏基时, $\alpha = 1$; Ψ 为非稠密稀疏基时, $0 < \alpha < 1$),则每列中的元素 $|\psi_k(t)| \leq \frac{1}{\sqrt{\beta N}}$ ($t \in \{1, 2, \dots, N\}$, $0 < \beta \leq \alpha$).于是

$$|\langle \mathbf{L}_j, \psi_k \rangle| = \left| \sum_{t=1}^N \mathbf{L}_j(t) \psi_k(t) \right| = \left| \sum_{t \in T} \mathbf{L}_j(t) \psi_k(t) \right| \leq U \cdot \frac{1}{\sqrt{U}} \cdot \frac{1}{\sqrt{\beta N}} = \frac{\sqrt{U}}{\sqrt{\beta N}} \quad (7)$$

所以

$$\mu(\mathbf{L}, \Psi) = \sqrt{N} \max_{j,k} |\langle \mathbf{L}_j, \psi_k \rangle| \leq \sqrt{N} \cdot \frac{\sqrt{U}}{\sqrt{\beta N}} = \sqrt{\frac{U}{\beta}} \quad (8)$$

由式(8)知,投影矩阵 \mathbf{L} 和稀疏基 Ψ 的相干程度不高于 $\sqrt{\frac{U}{\beta}}$,这里 U 为放大系数.因为 U 很小,所以 $\mu(\mathbf{L}, \Psi)$ 很小,特别当 Ψ 为稠密稀疏基时,例如傅里叶稀疏基和梯度稀疏基, $\mu(\mathbf{L}, \Psi) = \sqrt{U}$ ($\beta = \alpha = 1$).这就证明了投影矩阵 \mathbf{L} 与大多数稀疏基 Ψ 高度不相干, $\mathbf{L}\Psi$ 具有良好的 RIP 性质.

式(6)是一个 CS 理论框架下的超分辨重建问题,可转化为梯度稀疏约束的优化问题,用重构准确度较高的 TV 算法进行求解,即

$$\hat{\mathbf{X}} = \operatorname{argmin} TV(\mathbf{X}), s. t. \mathbf{L}\mathbf{X} = \mathbf{X}_1 \text{ and } \mathbf{X} \geq 0 \quad (9)$$

式中稀疏基为梯度稀疏基 $TV(\cdot)$.为了更好地表示图像 \mathbf{X} 的边缘信息,综合考虑水平方向、垂直方向和对角方向的梯度.记水平梯度为 \mathbf{G}_h ,垂直梯度为 \mathbf{G}_v ,对角梯度为 \mathbf{G}_{hw} 和 \mathbf{G}_{sh} .则式(9)可表示为

$$\hat{\mathbf{X}} = \operatorname{argmin} \{ \|\mathbf{G}_h\|_1 + \|\mathbf{G}_v\|_1 + \lambda (\|\mathbf{G}_{hw}\|_1 + \|\mathbf{G}_{sh}\|_1) \} (\mathbf{X}), s. t. \mathbf{L}\mathbf{X} = \mathbf{X}_1 \text{ and } \mathbf{X} \geq 0 \quad (10)$$

式中 $TV(\mathbf{X}) = \{ \|\mathbf{G}_h\|_1 + \|\mathbf{G}_v\|_1 + \lambda (\|\mathbf{G}_{hw}\|_1 + \|\mathbf{G}_{sh}\|_1) \} (\mathbf{X})$,像素位置 (i, j) 的梯度为: $(\mathbf{G}_h)_{i,j} = \mathbf{X}_{i+1,j} - \mathbf{X}_{i,j}$, $(\mathbf{G}_v)_{i,j} = \mathbf{X}_{i,j+1} - \mathbf{X}_{i,j}$, $(\mathbf{G}_{hw})_{i,j} = (\mathbf{G}_h)_{i,j} + (\mathbf{G}_v)_{i+1,j}$ 和 $(\mathbf{G}_{sh})_{i,j} = (\mathbf{G}_v)_{i,j} - (\mathbf{G}_h)_{i,j}$.约束条件 $\mathbf{X} \geq 0$ 表示图像的灰度像素值非负. λ 为加权因子, $0 \leq \lambda \leq 1$.本文取 $\lambda = 0.5$.

最后采用原始对偶内点法 (PDICO) 对式(10)进行求解,即可得到高分辨率图像 $\hat{\mathbf{X}}$.

3 实验结果

在 MATLAB 环境下选用标准灰度图像 (180×180 , 8 bit) 对本文方法进行性能测试.计算平台为: Intel(R) Xeon(R) X5690 CPU 和 96G 内存.实验中测量矩阵选用二进制 Rademacher (± 1) 随机矩阵,该矩阵与实际成像系统中采用的 (0, 1) 二进制随机矩阵相等价,可以真实模拟实际成像系统的硬件采样过程,在具体应用时,只需要一个简单的运算就可以从由 (0, 1) 二进制随机矩阵获取的采样数据中得到与二进制 Rademacher (± 1) 随机矩阵相对应的采样数据.假设由 (0, 1) 二进制随机矩阵获取的一组压缩采样值为: y_i

$(m), m = 1, 2, \dots, M, M$ 为采样次数, 则与二进制 Rademacher(± 1) 随机矩阵相对应的压缩采样值为: $y(m) = 2 \times y_1(m) - y_0, m = 1, 2, \dots, M$, 其中 y_0 为图像的能量值, y_0 的获取很简单, 只需构建一个全 1 矩阵 (矩阵元素全为 1) 对图像进行采样, 获得的采样值就是图像的能量值 y_0 . 稀疏基采用梯度稀疏基 $TV(\cdot)$, 重建算法采用 TV 算法, 放大系数 $U = 4$. 定义采样率 $MR = M/N \times 100\%$, M 为测量值个数, N 为信号长度.

3.1 图像重建性能对比

为验证方案的性能, 在相同计算平台下做了 3 组实验: 1) 本文方法; 2) CS+Bicubic 方法 (用两次立方插值算法 (Bicubic_SR 替换本文方法中基于 CS 理论框架的超分辨重建算法 (TV_SR); 3) CS 方法. 其中 CS 方法采用二进制 Rademacher(± 1) 随机矩阵对图像进行

压缩采样, 然后在梯度稀疏基约束下采用 TV 算法从采样数据中恢复出原图像. 本文方法和 CS+Bicubic 方法分两步进行: 首先采用分区二进制 Rademacher(± 1) 随机矩阵对图像进行压缩采样, 然后根据分区控制过程从分区二进制 Rademacher(± 1) 随机矩阵中抽取出一个比原矩阵大小要小的二进制 Rademacher(± 1) 随机矩阵用于重构, 并在梯度稀疏基约束下采用 TV 算法从采样数据中恢复出目标图像的低分辨率图像; 最后本文方法和 CS+Bicubic 方法分别采用 TV_SR 算法和 Bicubic_SR 算法从低分辨率图像中恢复出目标图像的高分辨率图像.

3.1.1 平滑图像的重建结果

图 4 是 House 图像在不同 MR 下 3 种方法的重建实验结果. 从图 4 可以看到, 本文方法的图像重建性能

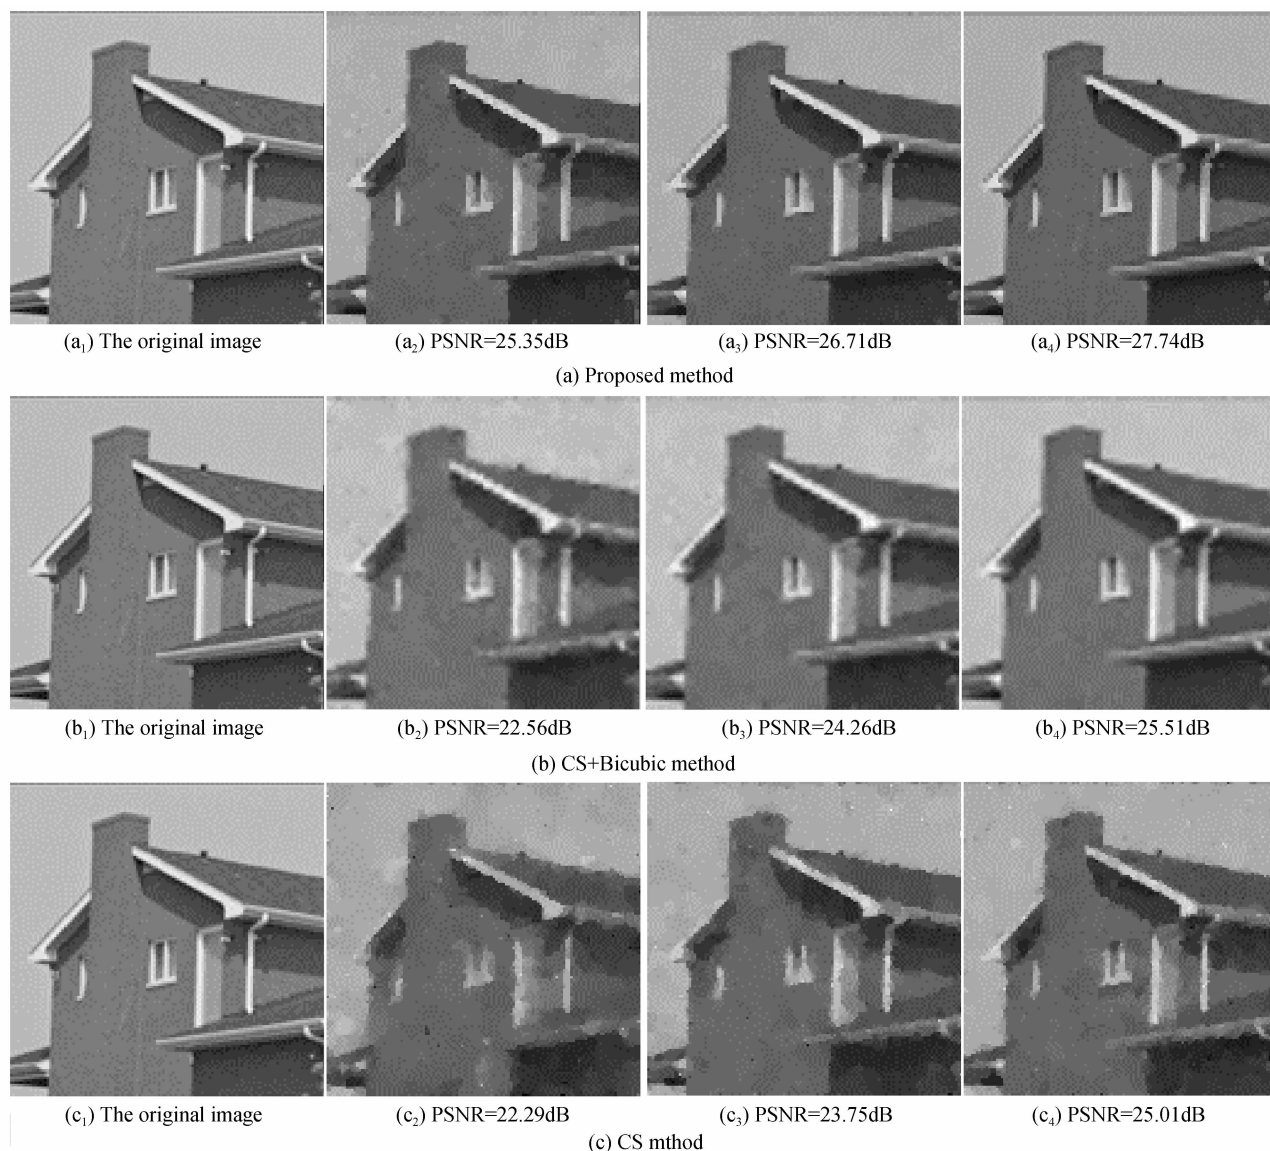



图 4 House 图像的重建结果, 从左到右依次为: 原图像, MR=7.5% 时的重建图像, MR=10% 时的重建图像, MR=12.5% 时的重建图像

Fig. 4 Recovery results of the House image, from left to right is the original image, recovered images when MR=7.5%, 10%, and 12.5%


明显优于 CS+Bicubic 和 CS 方法. 本文方法的重建图像的细节最清晰, 在 MR = 12.5% 时, 峰值信噪比 (Peak Signal to Noise Ratio, PSNR) 达到 27.74 dB, 而 CS+Bicubic 方法由于 Bicubic_SR 算法固有的过平滑效应, 容易造成重建图像模糊, PSNR 仅为 25.51 dB, 与本文方法相比, 减少了 2.23 dB; CS 方法的重建图像的细节恢复效果最差, PSNR 仅为 25.01 dB, 比本文方法少了 2.73 dB. 这是因为在相同采样率下, 本文方法采用 DMD 分区控制方法增强了信息获取的准确性, 获得了场景 X 更多的低频信息 (即获得更清晰的低分辨率图像 X_1), 同时 TV_SR 可以恢复场景 X 的高频信息, 两者结合即可获得更高质量的重建图像. 表明在相同成像质量下, 本文方法可以有效减少采样量, 缩短成像时间.

3.1.2 纹理复杂图像的重建结果

图 5 是纹理丰富的医学图像 (Bone, Chest 和 Vessels 图像) 在不同 MR 下 3 种方法的 PSNR 性能. 从图 5 可以看出, 对于纹理复杂的图像, 本文方法的图像重建性能仍然优于其它两种方法. 与 CS 方法相比, 本文方法关于 Bone, Chest 和 Vessels 图像的 PSNR 分别提高了大约 1.2~2.61 dB, 1.32~2.83 dB 和 1.38~2.98 dB; 特别是在 MR 较低情况下, 提高更加明显. 同时也看到, 本文方法的 PSNR 性能要优于 CS+Bicubic 方法, 并且随着 MR 的增大, 差距进一步加大. 此外, 虽然在较低 MR 时, CS+Bicubic 方法的 PSNR 高于 CS 方法, 但是在较高 MR 时, CS+Bicubic



(b) The chest image

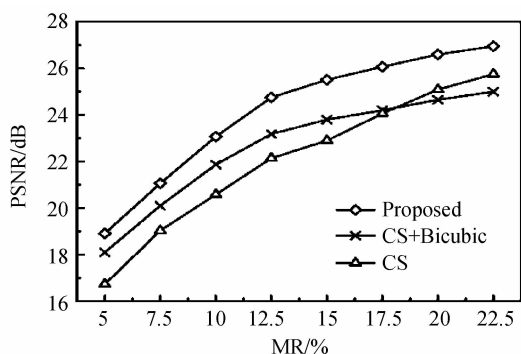


(c) The vessels image

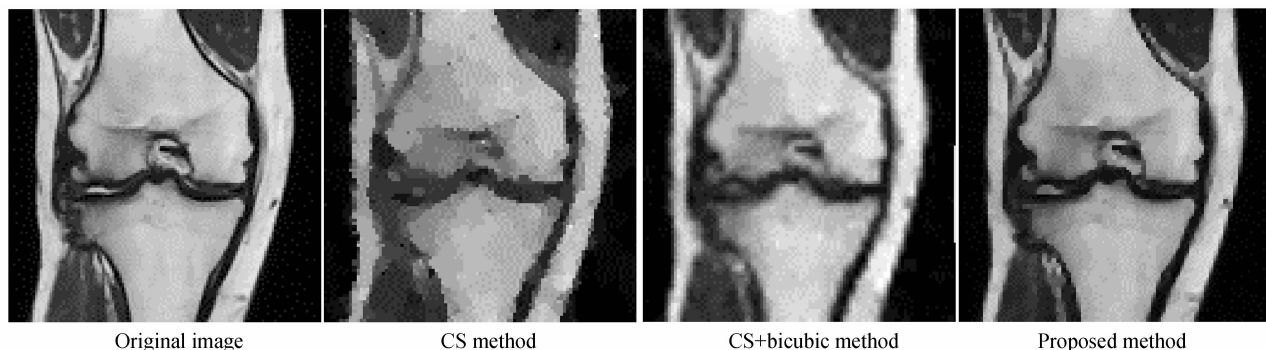
图 5 Bone, Chest 和 Vessels 医学图像的重建结果

Fig. 5 Recovery results of the Bone, Chest and Vessels images 方法的 PSNR 却低于 CS 方法. 这是由于纹理复杂的 Bone, Chest 和 Vessels 图像具有丰富的高频信息, 而 CS+Bicubic 方法中采用的 Bicubic_SR 算法由于固有的过平滑效应, 不能很好地恢复出图像的高频信息, 在较高 MR 时, 此缺点愈加突出. 而本文方法中采用的 TV_SR 算法由于可以有效恢复图像的高频信息, 所以获得了最优的 PSNR 性能.

为了更直观地比较图像的重建质量, 图 6 给出了 Bone, Chest 和 Vessels 图像分别由 3 种方法在 MR = 12.5% 时的重建图像. 从图 6 也可以看出, 本文方法的重建图像的细节恢复最好, Bone, Chest 和 Vessels 图像的 PSNR 分别达到 24.75 dB, 25.71 dB 和 25.52 dB; 而 CS+Bicubic 方法的重建图像比较模糊, 细节不清晰, PSNR 分别仅有 23.18 dB, 24.58 dB 和 24.25 dB,



(a) The bone image



Original image

CS method

CS+bicubic method

Proposed method

(a) The bone image




图 6 Bone, Chest 和 Vessels 图像的重建实验结果(MR=12.5%)

Fig. 6 Recovery results of the Bone, Chest and Vessels images when MR=12.5%

比本文方法分别降低了 1.57 dB、1.13 dB 和 1.27 dB; CS 方法的重建图像质量最差, PSNR 分别仅有 22.14 dB、23.23 dB 和 22.54 dB, 与本文方法相比, 分别降低了 2.61 dB、2.48 dB 和 2.98 dB.

3.2 计算复杂度对比

为了测试本方案的计算复杂度, 在相同计算平台下, 以 MATLAB 中的 etime 函数测量 3 种方法在不同 MR 下重建 House 图像的时间 t , 单位为秒(s), 如图 7 所示. 从图 7 可以看出, 与 CS 方法相比, 本文方法与 CS+Bicubic 方法都具有很低的计算复杂度. 当 MR 提高时, CS 方法的计算量呈指数级增长, 即使是常见的图像尺寸(180×180), 其计算量都是非常大的, 而本文方法和 CS+Bicubic 方法的计算量始终维持在较低水平. 说明本文中提出的 DMD 分区控制方法可以有效降低系统的整体计算复杂度. 需要指出的是, 本文方法与 CS+Bicubic 方法的计算时间主要由两部分组成: 重构低分辨率图像的时间和从低分辨率图像恢复高分辨率图像的时间. 这两种方法用于重构低分辨率图像的时间一样, 区别仅在于恢复高分辨率图像的时间, 即取决于所采用的超分辨重建算法的计算复杂度. 图 8 给出本文方法中的 TV_SR 与 CS+Bicubic 方法中的 Bicubic_SR 两种超分辨重建算法在恢复高分辨率 House 图像时的计算时间 t . 从图 8 可以看到, 由于 TV_SR 算法中的投影矩阵 L 是一个非常稀疏的矩阵, 虽然采用复杂度较高的 TV 算法求解超分辨重建问题,

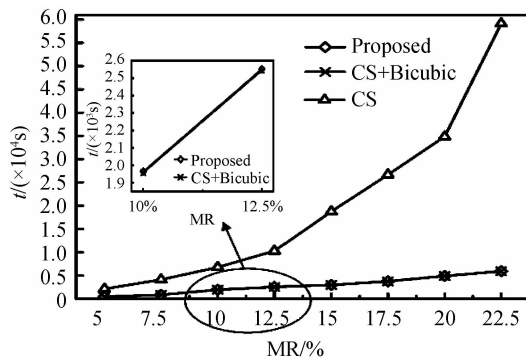


图 7 系统计算时间

Fig. 7 Recovery time of the system

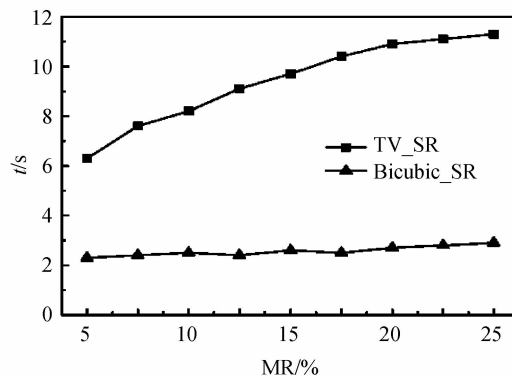


图 8 超分辨重建时间

Fig. 8 Recovery time of super-resolution
其计算量还是很低的, 与简单的 Bicubic_SR 算法相比,

计算时间稍长一些. 从图 8 可以看到, 在不同的 MR 下, TV_SR 算法的计算时间比 Bicubic_SR 算法仅高出 4~8.3 s, 也就是说本文方法的整体计算时间比 CS+Bicubic 方法高出 4~8.3 s, 与整体计算时间相比这个差别是非常小的, 可以忽略不计. 但是如果是在对计算时间有严格要求但对图像质量不高的应用场合, 采用 CS+Bicubic 方法会比本文方法更为适合.

4 结论

针对现有的压缩感知成像系统成像时间长和计算量大的问题, 本文提出一种新的压缩感知成像框架结构. 该方法在采样端用新建的采样矩阵实现 DMD 分区控制, 增强信息获取的准确性, 测量一组与新 DMD 对应的压缩采样值, 大大缩短成像时间; 重构端用很少的计算量由压缩采样值优化重构出低分辨率目标图像后, 根据 DMD 分区控制过程建立压缩感知理论框架下的超分辨率重建模型, 并从数学上证明其合理性; 利用梯度稀疏约束优化算法进行求解, 恢复出原高分辨率图像. 实验表明本文方法可以大大缩短压缩感知成像系统的成像时间和降低计算复杂度, 并且具有较高的图像重构质量. 同时本文方法给出了一种由低分辨率 DMD 获得高分辨率图像的新思路, 达到降低硬件采样成本的目的.

参考文献

- [1] CANDES E J, WAKIN M B. An introduction to compressive sampling[J]. *IEEE Signal Processing*, 2008, **25**(2): 21-30.
- [2] DONOHO D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, **52**(4): 1289-1306.
- [3] CANDES E J. The restricted isometry property and its implications for compressed sensing [J]. *Comptes Rendus Mathematique*, 2008, **346**(9-10): 589-592.
- [4] CANDES E J, TAO T. Decoding by linear programming[J]. *IEEE Transactions on Information Theory*, 2005, **51**(12): 4203-4215.
- [5] SUN Xi-long, YU An-si, DONG Zhen, *et al.* Three-dimensional SAR focusing via compressive sensing: the case study of angel stadium [J]. *IEEE Geoscience and Remote Sensing Letters*, 2012, **9**(4): 759-763.
- [6] YANG Jun-gang, THOMPSON J, HUANG Xiao-tao, *et al.* Random-frequency SAR imaging based on compressed sensing [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, **51**(2): 983-994.
- [7] CHEN Jian-wen, CONG J, VESE L A, *et al.* A hybrid architecture for compressive sensing 3-D CT reconstruction [J]. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 2012, **2**(3): 616-625.
- [8] LINGALA S G, JACOB M. Blind compressive sensing dynamic MRI[J]. *IEEE Transactions on Medical Imaging*, 2013, **32**(6): 1132-1145.
- [9] LI Cheng-bo, SUN Ting, KELLY K, *et al.* A compressive sensing and unmixing scheme for hyperspectral data processing [J]. *IEEE Transactions on Image Processing*, 2012, **21**(3): 1200-1210.
- [10] MA Jian-wei. Single-pixel remote sensing [J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, **6**(2): 199-203.
- [11] AUGUST Y, VACHMAN C, RIVENSON Y, *et al.* Stern. Compressive hyperspectral imaging by random separable projections in both the spatial and the spectral domains[J]. *Applied Optics*, 2013, **52**(10): D46-D54.
- [12] TAKHAR D, LASKA J N, WAKIN M B, *et al.* A new compressive imaging camera architecture using optical-domain compression [C]. Proceedings of SPIE: Computational Imaging IV, San Jose, CA, 2006: 43-52.
- [13] DUARTE M F, DAVENPOET M A, TAKHAR D, *et al.* Single-pixel imaging via compressive sampling [J]. *IEEE Signal Processing Magazine*, [83-91], March 2008.
- [14] CHAN Wai-lam, CHARAN K, TAKHAR D, *et al.* A single-pixel terahertz imaging systems based on compressed sensing [J]. *Applied Physics Letters*, 2008, **93**(12): 121105-121105-3.
- [15] CANDES E J, ROMBERG J. Sparsity and incoherence in compressive sampling[J]. *Inverse Problems*, 2007, **23**(3): 969-986.
- [16] WANG J, SHIM B. On recovery limit of orthogonal matching pursuit using restricted isometry property [J]. *IEEE Transactions on Signal Processing*, 2012, **60**(9): 4973-4976.
- [17] NEEDELL D, WARD R. Stable image reconstruction using total variation minimization[C/OL]. <http://arxiv.org/pdf/1202.6429v9.pdf>(2013.05.12).
- [18] WU Xiao-lin, DONG Wei-sheng, ZHANG Xian-jun, *et al.* Model-assisted adaptive recovery of compressed sensing with imaging applications [J]. *IEEE Transactions on Signal Processing*, 2012, **21**(2): 451-458.
- [19] LIN Zhou-chen, HE Jun-feng, TANG Xiao-ou, *et al.* Limits of learning based superresolution algorithms[C]. Proceedings of ICCV, 2007: 1-8.
- [20] YAND Jian-chao, WRIGHT J, HUANG T S, *et al.* Image super-resolution via sparse representation [J]. *IEEE Transactions on Image Processing*, 2010, **19**(11): 2861-2873.