

基于自适应稀疏表达的并行磁共振重建方法

谭 莎^{1,2} 王珊珊² 彭 玺² 梁 栋²

¹(广东工业大学 广州 510000)

²(中国科学院深圳先进技术研究院 深圳 518055)

摘 要 为精确地进行并行磁共振成像, 文章利用字典学习的强大捕捉细节和稀疏开发能力, 提出了一种基于自适应稀疏表达的重建方法。该方法将并行磁共振重建问题转化为最小化由字典学习和数据拟合项构成的目标函数, 并采用了分而治之的方案求解未知变量。为验证其有效性, 将该方法与目前主流的两种方法在人体实际磁共振数据上进行了测试。测试结果显示, 文章提出的方法能在抑制图像噪声的同时较好地保存图像细节。

关键词 并行成像; 字典学习; 压缩感知; 磁共振成像

中图分类号 R 445.2 **文献标志码** A

Parallel Magnetic Resonance Imaging Reconstruction via Adaptive Sparse Representation

TAN Sha^{1,2} WANG Shanshan² PENG Xi² LIANG Dong²

¹(Guangdong University of Technology, Guangzhou 510000, China)

²(Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)

Abstract An adaptive sparse representation regularized reconstruction method for accurate parallel imaging was proposed by exploring the strength of dictionary learning in capturing image fine structures while promoting sparsity. The reconstruction was formulated as a minimization problem, which consisted of a data-fidelity term and a dictionary learning term and was solved by the “divide and conquer” strategy. The comparative results of the proposed method with respect to two popular approaches on an in-vivo dataset demonstrated that the proposed method preserves more image fine details while suppressing noise.

Keywords parallel imaging; dictionary learning; compressed sensing; magnetic resonance imaging

收稿日期: 2015-09-14 修回日期: 2016-03-10

基金项目: 国家自然科学基金(61471350、11301508、61401449); 广东省自然科学基金(2015A030310314); 深圳市基础研究(JCYJ20140610152828678); 深圳先进技术院优秀青年创新基金资助项目(201403)

作者简介: 谭莎, 硕士研究生, 研究方向为快速磁共振成像方法和字典学习; 王珊珊, 博士, 助理研究员, 研究方向为快速磁共振成像方法、字典学习和图像恢复; 彭玺, 博士, 副研究员, 研究方向为快速磁共振成像方法、参数估计和信号处理; 梁栋(通讯作者), 博士, 研究员, 研究方向为快速磁共振成像方法、压缩感知和机器学习, E-mail: dong.liang@siat.ac.cn.

1 引言

并行成像是利用多个接收线圈不同的空间灵敏度减少傅里叶编码的步骤、加速傅里叶成像的方法。因它可减少扫描时间而被广泛应用于磁共振成像系统及临床应用, 如快速动态成像、有效诊断、定期复查、体内研究等。目前, 有两种方法被广泛应用于从获取的部分并行数据中重构图像。一种方法是利用线圈灵敏度信息, 如 SENSE (Sensitivity Encoding)^[1]; 另一种则利用多通道 k 空间数据之间的相关性, 如 SMASH (Simultaneous Acquisition of Spatial Harmonics)^[2]、GRAPPA (Generalized Auto-calibrating Partially Parallel Acquisitions)^[3]、SPIRiT (iterative Self-consistent Parallel Imaging Reconstruction)^[4]。然而, 由于严重病态的系统矩阵和重构算法的性能局限, 并行磁共振的加速因子仍然受到限制^[5-7]。

压缩感知 (Compressed Sensing, CS) 理论是加快磁共振成像的一个重要理论^[8-10], 它的出现具有革命性意义。它利用图像的主要成分进行图像重构, 如信号稀疏、不相干采样, 在保证磁共振重构精确度下, 同时消除了欠采下的伪影现象^[11]。此外, 众所周知, 提高信号的稀疏性对促进加速度因子变大和改善重构质量非常重要。因此, 已有很多学者开始致力研究更好的稀疏变换, 从而得到更佳的稀疏信号。目前, CS 与并行成像 (Parallel Imaging, PI) 结合比较流行的方法有: L1-SPIRiT^[4]、SPARSE-SENSE^[12,13]、CS-GRAPPA^[14]、CS-SENSE^[15]、PI-CS^[16]、SENSE-TV^[6]。这些方法集成了多通道的灵敏度和信号的稀疏性, 一定程度上加速了磁共振成像^[17]。但這些方法也存在不足, 它们使用固定的变换域开发图像的稀疏性, 不能自适应地捕捉图像结构^[18]。

近年来, 字典学习在研究领域中受到很高的重视。它能促进信号稀疏, 并能自适应捕捉结构

信息, 同时也有利消除伪影和噪声^[19]。在这之前, 我们已研发了一系列的字典学习算法^[20-22], 并已成功应用于单线圈压缩感知磁共振成像重构中^[23]。因此, 把字典学习应用到并行磁共振成像的想法油然而生。然而, 相对于其他比较流行的求逆过程, 并行重构的求逆矩阵计算量大, 且更病态^[6,24,25]。

为了克服这些困难, 本文对基于字典学习稀疏表示的并行成像提出了一种自适应的重构方法。该方法将并行磁共振重建问题转化为最小化由字典学习和数据拟合项构成的目标函数, 并采用了分而治之的方案求解未知变量。最后, 该方法与目前主流的两种方法 SBB (Splitting Barzilai-Borwein)^[24]、TVL2ADM (Total Variation and l_2 data fidelity Alternating Direction Method of Multipliers (ADMM))^[25]进行了对比。测试结果显示, 文章提出的方法能在抑制图像噪声的同时较好地保存图像细节。

2 原理

在利用 l_2 范数约束数据保真度误差, 字典学习规范重构图像的条件下, 并行成像重构问题的数学表达式如下所示:

$$\arg \min_x \left\{ \frac{\mu}{2} \|Ex - y\|_2^2 + \arg \min_{D, \Gamma} f_{DL} \right\} \quad (1)$$

其中, $f_{DL} = \sum_{l=1}^L \left[\frac{\lambda}{2} \|R_l x - Da_l\|_2^2 + \|a_l\|_1 \right]$; $E \triangleq (PFS_1; \dots; PFS_J) \in \mathbb{C}^{p^J \times N}$, E 为编码矩阵, 由掩模 P 、傅里叶编码 F 和灵敏度权重 S 构成; y 是所有通道获得的数据; $R_l \in \mathbb{R}^{M \times N}$ 代表从图像 x 中提取样本矩阵的操作; $D \in \mathbb{C}^{M \times N}$ 为自适应字典, 它的每个原子模被规范化为 1; $a_l \in \mathbb{C}^N$ 是对于第 l 个采样 $R_l x \in \mathbb{C}^M$ 和 $\Gamma = [a_1, \dots, a_L] \in \mathbb{R}^{N \times L}$ 的稀疏系数; μ 和 λ 为数据拟合项的正则化参数。为了解决最终重构问题, 我们通过利用 Bregman 迭代技

术进行以下的迭代:

$$\begin{cases} x^{k+1} = \arg \min_x \left\{ \frac{\mu}{2} \|Ex - y^k\|_2^2 + \arg \min_{D, \Gamma} f_{DL} \right\} \\ y^{k+1} = y^k + y - Ex^{k+1} \end{cases} \quad (2)$$

2.1 稀疏表示的子问题

重构图像和 k 空间数据定义为 x^k 和 y^k , 我们再通过另一个辅助变量 z_l 来解决内部自适应稀疏代表的子问题。

$$\arg \min_{D, \Gamma} \sum_{l=1}^L \left[\frac{\lambda}{2} \|z_l\|_2^2 + \|\alpha_l\|_1 \right] \quad (3)$$

$$st. R_l x^k - Da_l = z_l, \quad l=1, 2, 3, \dots, L$$

外部迭代为 k , 并重复利用 Bregman 迭代, 而内部迭代如下式所示:

$$\begin{cases} a_l^{k, m+1}, z_l^{k, m+1}, D^{k, m+1} = \arg \min_{\Gamma, Z, D} f_b \\ c_l^{k, m+1} = c_l^{k, m} + \beta (R_l x^k - Da_l - z_l) \end{cases} \quad (4)$$

其中, m 表示自适应稀疏表示内部循环的迭代次数; c_l 代表 Bregman 参数; β 代表步长; $f_b =$

$$\sum_{l=1}^L \left[\frac{\lambda}{2} \|z_l\|_2^2 + \|\alpha_l\|_1 + \frac{\beta}{2} \left\| D\alpha_l + z_l - R_l x^k - \frac{c_l^{k, m}}{\beta} \right\|_2^2 \right].$$

2.2 稀疏编码

为了更新稀疏系数, 需要一个嵌套循环, i 是其迭代指数。通过 $z_l = \frac{\beta}{\lambda + \beta} (R_l x^k + \frac{c_l}{\beta} - Da_l)$ 来更新 z_l , 从而加快算法速度。此外, 我们应用以前论文中的一个方案, 如 c_l 被迭代收缩/阈值算法的最新状态的内部迭代 a_l 代替^[26]。

$$\begin{aligned} c_l^{k, m, i+1} &= c_l^{k, m-1, I_{Tot}} + \beta (R_l x^k - D^{k, m} a_l^{k, m, i} - z_l^{k, m, i}) \\ &= \frac{\lambda \beta}{\lambda + \beta} \left(-D^{k, m} a_l^{k, m, i} + R_l x^k + \frac{c_l^{k, m-1, I_{Tot}}}{\beta} \right) \end{aligned} \quad (5)$$

然后根据下式最小化更新 a_l :

$$a_l^{k, m, i+1} = SHRINK \left(a_l^{k, m, i} + \frac{(\lambda + \beta) (D^{k, m})^T c_l^{k, m, i+1}}{\gamma \lambda \beta}, \frac{\lambda + \beta}{\gamma \lambda \beta} \right) \quad (6)$$

其中, $SHRINK(\dots, \dots)$ 是重要的元素操作, 第一个输入可以是标量、向量或矩阵, 第二个输入是一个标量。 $SHRINK(\dots, \dots)$ 输出的维数与输入的一样; γ 是压缩的辅助标量; I_{Tot} 是内部迭代最大次数。

接着根据梯度更新原则, 有:

$$D^{k, m+1} = D^{k, m} + \varepsilon C^{k, m+1} (\Gamma^{k, m, I_{Tot}})^T \quad (7)$$

其中, $Da_l + z_l - R_l x^k$ 设置为 0; ε 为学习率; $C = [c_1, \dots, c_L]$; $\Gamma = [a_1, \dots, a_L]$ 。

2.3 更新重构图像的子问题

$$x^{k+1} = \arg \min_x \left\{ \underbrace{\frac{\mu}{2} \|Ex - y^k\|_2^2}_{H(x)} + f_{DL} \left(D^{k, M_{Tot}}, a_l^{k, M_{Tot}, I_{Tot}} \right) \right\} \quad (8)$$

式中编码矩阵 E 不能对角化, 为了避免其严重病态的计算, 我们使用一阶泰勒展开近似 $H(x)$ 。这个泰勒展开只有当 x 接近 x^k 时, 才能得到更好的性能。另一个 ℓ_2 范数需加上惩罚项来近似它们俩, 即:

$$H(x) \approx H(x^k) + \langle x - x^k, \nabla H(x^k) \rangle + \frac{\eta}{2} \|x - x^k\|_2^2 \quad (9)$$

其中, η 为数据拟合项正则化参数; $\nabla H(x) = \mu E^T (Ex - y^k)$ 。因此有:

$$x^{k+1} = \arg \min_x \left\{ \langle x, E^T (Ex^k - y^k) \rangle + \frac{\lambda}{2} \sum_{l=1}^L \|R_l x - Da_l\|_2^2 + \frac{\eta}{2} \|x - x^k\|_2^2 \right\} \quad (10)$$

λ 由 β 约束, 最后的解析函数:

$$x^{k+1} = \frac{\lambda \sum_{l=1}^L R_l^T Da_l + \mu E^T (y^k - Ex^k) + \eta x^k}{\lambda \omega + \eta} \quad (11)$$

其中, ω 为提取图像特征的滑动距离。最终, 整个算法的描述在**算法 1**中显示。

算法 1: 算法的详细描述

1. 目标: 从部分并行 k 空间数据中重建磁共振图像
2. 初始化: $x^0 = E^T y, y^0 = y, \Gamma^0 = 0, C^0 = 0, D^0$
3. While $\frac{\|x^k - x^{k-1}\|_2}{\|x^k\|} > Error_{Tol}$, do
4. While $m \leq M_{Tol}$, do
5. While $i \leq I_{Tol}$, do
6. Update $c_i^{k,m,i+1} = \frac{\lambda\beta}{\lambda+\beta} (-D^{k,m} \alpha_i^{k,m,i} + R_i x^k + \frac{c_i^{k,m-1,i_{Tol}}}{\beta}), \forall i$
7. Update
- $\alpha_i^{k,m,i+1} = SHRINK(\alpha_i^{k,m,i} + \frac{(\lambda+\beta)(D^{k,m})^T c_i^{k,m,i+1}}{\gamma\lambda\beta}, \frac{\lambda+\beta}{\gamma\lambda\beta})$
8. End while
9. Update $D^{k,m+1} = D^{k,m} + \varepsilon C^{k,m+1} (\Gamma^{k,m,i_{Tol}})^T$
10. Update $x^{k+1} = \frac{\lambda \sum_{i=1}^L R_i^T D \alpha_i + \mu E^T (y^k - E x^k) + \eta x^k}{\lambda \omega + \eta}$
11. End while
12. Update $y^{k+1} = y^k + y - E x^{k+1}$
13. End while

3 实验与结果

我们在一个配置 12 通道颅脑线圈 3T 磁共振系统 (SIEMENS MAGNETOM Trio) 中利用 T2 加权的自旋回波序列 (Turbo Spin Echo) (回波时间 (TE) 为 91.0 ms, 重复时间 (TR) 为 5 000 ms, 视野 (FOV) 为 20 cm × 20 cm, 矩阵大小 (Matrix) 为 256 × 270, 层厚 (Slice thickness) 为 3 mm) 获得一

组全采样的横向大脑数据, 用于评估本文提出的方法。实验志愿者已签署依据影像学机构审查委员会政策获得的知情同意书。欠采样数据使用一维的变密度随机采样获得, 灵敏度从预扫描中得到。同时, 还用 SBB 和 TVL2ADM 方法进行对比实验。为了公平比较, 相对变换的 x 使用相同的停止标准, 每个通道全采样数据的平方求和再开方的数据被用作参考图像。


TVL2ADM、SBB 和所提出方法在加速因子分别为 2、3、4、5、6 的情况下重建横向大脑图像。标准化的均方根误差结果在表 1 中列出, 在每个加速因子下, 效果最好的已用黑体标出。从实验结果可以得出, 我们提出的方法相对于其他方法的误差都是最小的。

表 1 TVL2ADM、SBB 和本文所提出算法在不同加速因子下图像重建的数值对比

Table 1 Numerical results of reconstructions by TVL2ADM, SBB and the proposed algorithms when the imaging process was accelerated with different rates

加速因子	归一化均方误差值 (%)		
	TVL2ADM	SBB	本文方法
2	5.443 7	3.890 4	2.397 4
3	8.988 5	7.481 6	5.018 5
4	12.181 2	10.673 1	7.164 1
5	14.158 6	12.722 2	9.372 5
6	15.651 9	14.351 7	10.423

我们除了从数值上对这三种方法进行了对比



(a) 参考图像

(b) TVL2ADM 方法重建的图像

(c) SBB 方法重建的图像

(d) 并行字典重建的图像

图 1 不同算法的重建图像对比

Fig. 1 Reconstruction image contrast of different algorithms

之外, 还从图像上进行了对比。图 1 分别给出了加速因子为 4 时三种方法的重建图像。由图可以明显地看到, 本文提出的算法对磁共振成像的细节结构信息的保留能力更好。另外, TVL2ADM 和 SBB 重建的图像较模糊, 而文章所提算法的结果较清晰。由此可知, 对同一区域的图像放大再与原始图像进行对比, 相对于其他两种算法, 本文提出的算法重建的图像更贴近于原始图像。

4 结 论

为了更好地从部分并行傅里叶数据中重建磁共振图像, 本文提出了一种新的方法, 把字典学习应用到图像域的并行成像重建中。该方法是一种自适应重构方法, 它将并行磁共振重建问题转化为最小化由字典学习和数据拟合项组成的目标函数, 并采用了分而治之的方案求解未知变量。为验证所提方法的有效性, 本文将该方法与目前主流的两种方法在人体实际磁共振数据上进行了测试。测试结果显示, 文章提出的方法能在抑制图像噪声的同时较好地保存图像细节。

参 考 文 献

- [1] Pruessmann KP, Weiger M, Scheidegger MB, et al. SENSE: sensitivity encoding for fast MRI [J]. *Magnetic Resonance in Medicine*, 1999, 42(5): 952-962.
- [2] Sodickson DK, Manning WJ. Simultaneous acquisition of spatial harmonics (SMASH): fast imaging with radiofrequency coil arrays [J]. *Magnetic Resonance in Medicine*, 1997, 38(4): 591-603.
- [3] Griswold MA, Jakob PM, Heidemann RM, et al. Generalized autocalibrating partially parallel acquisitions (GRAPPA) [J]. *Magnetic Resonance in Medicine*, 2002, 47(6): 1202-1210.
- [4] Michael L, Pauly JM. SPIRiT: iterative self-consistent parallel imaging reconstruction from arbitrary k -space [J]. *Magnetic Resonance in Medicine*, 2010, 64(2): 457-471.
- [5] Florian K, Christian C, Kristian B, et al. Parallel imaging with nonlinear reconstruction using variational penalties [J]. *Magnetic Resonance in Medicine*, 2012, 67(1): 34-41.
- [6] Chen Y, Hager W, Huang F, et al. Fast algorithms for image reconstruction with application to partially parallel MR imaging [J]. *SIAM Journal on Imaging Science*, 2012, 5(1): 90-118.
- [7] Zhang X, Burger M, Bresson X, et al. Bregmanized nonlocal regularization for deconvolution and sparse reconstruction [J]. *SIAM Journal on Imaging Science*, 2010, 3(3): 253-276.
- [8] Vasanaawala SS, Alley MT, Hargreaves BA, et al. Improved pediatric MR imaging with compressed sensing [J]. *Radiology*, 2010, 256(2): 607-616.
- [9] Otazo R, Kim D, Axel L, et al. Combination of compressed sensing and parallel imaging for highly accelerated first-pass cardiac perfusion MRI [J]. *Magnetic Resonance in Medicine*, 2010, 64(3): 767-776.
- [10] Park I, Hu S, Bok R, et al. Evaluation of heterogeneous metabolic profile in an orthotopic human glioblastoma xenograft model using compressed sensing hyperpolarized 3D ^{13}C magnetic resonance spectroscopic imaging [J]. *Magnetic Resonance in Medicine*, 2013, 70(1): 33-39.
- [11] Donoho DL. Compressed sensing [J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306.
- [12] Liu B, Seibert FM, Zou Y, et al. SparseSENSE: randomly-sampled parallel imaging using compressed sensing [C] // *Proceeding of the 16th Annual Meeting of ISMRM*, 2008: 3154.
- [13] King KF. Combining compressed sensing and parallel imaging [C] // *Proceedings of Annual Meeting of ISMRM*, 2008: 1488.
- [14] Fischer A, Seiberlich N, Blaimer M, et al. A combination of nonconvex compressed sensing and GRAPPA (CS-GRAPPA) [C] // *Proceedings of the International Society of Magnetic Resonance in*

- Medicine, 2009: 2813.
- [15] Liang D, Liu B, Wang J, et al. Accelerating SENSE using compressed sensing [J]. Magnetic Resonance in Medicine, 2009, 62(6): 1574-1584.
- [16] Beatty PJ, King KF, Marinelli L. Sequential application of parallel imaging and compressed sensing [C] // Proceedings of the International Society of Magnetic Resonance in Medicine, 2009: 2824.
- [17] Peng X, Ying L, Liu Q, et al. Incorporating reference in parallel imaging and compressed sensing [J]. Magnetic Resonance in Medicine, 2015, 73(4): 1490-1504.
- [18] Caballero J, Price AN, Rueckert D, et al. Patch-based dictionaries for parallel MRI reconstruction [C] // Proceedings of the International Society of Magnetic Resonance in Medicine, 2014: 1560.
- [19] Bhave S, Lingala SG, Jacob M. A variable splitting based algorithm for fast multi-coil blind compressed sensing MRI reconstruction [C] // The 36th Annual International Conference of IEEE on Engineering in Medicine and Biology Society, 2014: 2400-2403.
- [20] Wang SS, Xia Y, Liu QG, et al. Fenchel duality based dictionary learning for restoration of noisy images [J]. IEEE Transactions on Image Processing, 2013, 22(12): 5214-5225.
- [21] Wang SS, Liu QG, Xia Y, et al. Dictionary learning based impulse noise removal via L1-L1 minimization [J]. Signal Processing, 2013, 93(9): 2696-2708.
- [22] Liu QG, Wang SS, Luo JH. A novel pre-dual dictionary learning algorithm [J]. Journal of Visual Communication and Image Representation, 2012, 23(1): 182-193.
- [23] Liu QG, Wang SS, Kun Y, et al. Highly under-sampled magnetic resonance image reconstruction using two-level Bregman method with dictionary updating [J]. IEEE Transactions on Medical Imaging, 2013, 32(7): 1290-1301.
- [24] Ye XJ, Chen YM, Huang F. Computational acceleration for MR image reconstruction in partially parallel imaging [J]. IEEE Transactions on Medical Imaging, 2011, 30(5): 1055-1063.
- [25] Ye XJ, Chen YM, Lin W, et al. Fast MR image reconstruction for partially parallel imaging arbitrary k-space trajectories [J]. IEEE Transactions on Medical Imaging, 2011, 30(3): 575-585.
- [26] Yin BW, Osher S, Goldfarb D, et al. Bregman iterative algorithms for ℓ_1 -minimization with applications to compressed sensing [J]. SIAM Journal of Imaging Science, 2008, 1(1): 143-168.