

A Projection Algorithm for Compressive Sensing

Lichao Yu*, Biao Qu

School of Management, Qufu Normal University, Rizhao Shandong
Email: 1002218442@qq.com

Received: Jan. 23rd, 2015; accepted: Feb. 4th, 2015; published: Feb. 11th, 2015

Copyright © 2015 by authors and Hans Publishers Inc.
This work is licensed under the Creative Commons Attribution International License (CC BY).
<http://creativecommons.org/licenses/by/4.0/>



Open Access

Abstract

In the paper, we first transform the optimization problem of compressed sensing into a convex feasibility problem. Then, a projection method is presented to solve it.

Keywords

Convex Feasibility Problem, Compressed Sensing, Projection Method

求解压缩传感问题的一种投影算法

于丽超*, 屈 彪

曲阜师范大学管理学院, 山东 日照
Email: 1002218442@qq.com

收稿日期: 2015年1月23日; 录用日期: 2015年2月4日; 发布日期: 2015年2月11日

摘 要

本文在将压缩传感的最优化问题转化为凸可行问题的基础上, 设计了一种投影算法来求解凸可行问题, 进而求解压缩传感问题。

*通讯作者。

关键词

凸可行问题, 压缩传感, 投影算法

1. 引言

近年来, Donoho、Candes 及 Tao 等人[1] [2]提出了一种新的信息获取指导理论——压缩传感(Compressive Sensing or Compressed Sensing, 简称为 CS)。该理论表明: 如果原始信号具有稀疏先验性, 通过选取适当的优化算法, 在获取少量测量值的基础上, 对原始信号进行恢复重建。区别于传统的奈奎斯特采样定理, 这种新颖的信号处理方式可以认为是一种全局采样, 它将采样与压缩同时进行, 用极少的观测值拾取足够多的原始信号的信息, 有效地减少采样的数据复杂度, 同时也节约了信号采样所需花费的时间, 在实际应用当中可以降低采集系统的成本, 选择适当的重构算法还可以加快图像的重建速度, 提升图像的重建质量[3]。

压缩传感理论的提出, 为信号采样领域注入了新鲜血液, 引起信号处理领域的研究热潮, 具有广阔的应用前景。目前, 压缩传感理论被应用于许多领域, 例如: 压缩成像、生物传感、医学成像、模数信息转换以及地球地理数据分析等[4]。

从信号重构的角度出发, 利用具备某种分布特性的测量矩阵 $H \in \mathfrak{R}^{m \times n}$, 对原始信号 $x \in \mathfrak{R}^n$ 进行测量, 在该测量矩阵的线性测量值为 $y \in \mathfrak{R}^m$, 其表达式为:

$$y = Hx$$

在上式中, 测量值 y 也可以认为是原始信号 x 在 H 上的线性投影, 我们要求解一个逆问题, 通过测量值 y 对 x 进行重构。理论证明[2], 在 y 与 H 满足一定条件的前提下, 我们可以通过求解最优 l_0 范数达到精确重构原始信号的目的:

$$\begin{aligned} \min_x \|x\|_0 \\ \text{s.t. } y = Hx \end{aligned}$$

其中, $\|x\|_0$ 表示向量 x 的 l_0 范数, 即 x 中非零分量的个数。

但是, 对于 l_0 范数的最优化问题而言, 其本质是 NP 问题, 很难在多项式时间内求解, 甚至对于解的可靠性都无法给出证明。所以, 通常我们都将 l_0 最优化问题转换成 l_1 最优化问题来求解。即考虑如下问题:

$$\begin{aligned} \min_x \|x\|_1 \\ \text{s.t. } y = Hx \end{aligned} \quad (1)$$

其中, $\|x\|_1$ 表示向量 x 的 l_1 范数。

我们在本文中, 我们通过求解如下问题来求解问题(1):

$$\text{求 } x^* \in \mathfrak{R}^n, \text{ 使得 } y = Hx^* \text{ 且 } \|x^*\|_1 \leq \varepsilon, \quad (2)$$

其中 $\varepsilon > 0$ 是可任意选择的。

受文献[5]的启发, 我们将问题(2)转化为一个凸可行问题, 通过设计投影算法来求解该凸可行问题, 从而得到问题(1)的最优解。

本文组织如下: 在第二部分提出了问题的转化过程, 第三部分提出了投影算法求解凸可行问题, 并给出算法的收敛性分析。

2. 问题的转化形式

定义:

$$Q_j = \{x \in \mathfrak{R}^n \mid y_j = \langle h^j, x \rangle\}, \quad j = 1, \dots, m, \quad (3)$$

$$Q_{m+1} = \{x \in \mathfrak{R}^n \mid \|x\|_1 - \varepsilon \leq 0\}, \quad (4)$$

其中 $\langle \cdot, \cdot \rangle$ 表示内积, h^j 是矩阵 H^T 的第 j 列, y_j 表示 y 的第 j 个分量。

则问题(2)可等价地转化为如下凸可行问题:

$$\text{找 } x^* \in \left(\bigcap_{j=1}^m Q_j \right) \cap Q_{m+1}. \quad (5)$$

注: 由定义可知, $Q_1, Q_2, \dots, Q_m \subseteq \mathfrak{R}^n$ 均为超平面, 从而为闭凸集, Q_{m+1} 为闭凸集。

3. 算法及收敛性分析

设 $\Omega \subseteq \mathfrak{R}^n$ 为非空闭凸集, 对任意 $x \in \mathfrak{R}^n$, 定义:

$$P_\Omega(x) = \arg \min \{ \|x - y\| \mid y \in \Omega \},$$

并称其为 x 到 Ω 上的投影。 $P_\Omega(\cdot)$ 称为从 \mathfrak{R}^n 到 Ω 上的投影算子。

当 Ω 是某些特殊的闭凸集时, 求 x 在 Ω 上的投影是很好求的, 能够用显式表达出来。如, 当 Ω 是 \mathfrak{R}^n 中的超平面 $\{x \mid p^T x = \alpha\}$ (其中 $p \in \mathfrak{R}^n$ 为非零向量, $\alpha \in \mathfrak{R}$) 时, 我们有如下结果:

引理 3.1 [6] 令 $\Omega = \{x \mid p^T x = \alpha\}$ (其中 $p \in \mathfrak{R}^n$ 为非零向量, $\alpha \in \mathfrak{R}$), 则对任意的 $x^0 \in \mathfrak{R}^n$, x^0 到 Ω 上的投影 $P_\Omega(x^0)$ 为:

$$P_\Omega(x^0) = x^0 + \frac{\alpha - p^T x^0}{\|p\|^2} p.$$

关于投影算子, 有如下性质:

引理 3.2 [7] 令 $\Omega \subseteq \mathfrak{R}^n$ 是非空闭凸集, 则对 $\forall x, y \in \mathfrak{R}^n$, $z \in \Omega$, 有:

- 1) $\langle P_\Omega(x) - x, z - P_\Omega(x) \rangle \geq 0$;
- 2) $\|P_\Omega(x) - P_\Omega(y)\| \leq \|x - y\|$;
- 3) $\|P_\Omega(x) - z\|^2 \leq \|x - z\|^2 - \|P_\Omega(x) - x\|^2$;
- 4) $\|P_\Omega(x) - P_\Omega(y)\|^2 \leq \|x - y\|^2 - \|P_\Omega(x) - x + y - P_\Omega(y)\|^2$.

下面, 我们给出我们的投影算法:

算法 3.1:

任取 $x^0 \in \mathfrak{R}^n$, $0 < \underline{w} \leq w_k \leq \bar{w} < 2$, 对 $k = 1, 2, \dots$,

计算: $\bar{d}_j^k = P_{Q_j}(x^k) - x^k$, $j = 1, 2, \dots, m$.

令: $d_k = \sum_{j=1}^m \bar{d}_j^k$; $r_k = \frac{\sum_{j=1}^m \|\bar{d}_j^k\|^2}{\|d_k\|^2}$.

计算: $x^{k+1} = P_{Q_{m+1}}(x^k + w_k r_k d_k)$.

其中: Q_j ($j=1,2,\dots,m$) 和 Q_{m+1} 分别由(3)、(4)定义。

注: 由引理 3.1 知, x^k 到 Q_j ($j=1,2,\dots,m$) 上的投影 $P_{Q_j}(x^k)$ 是好求的。

我们分析算法 3.1 的收敛性:

引理 3.3 令 x^* 是问题(2)的一个解, $\{x^k\}$ 是由算法 3.1 产生的点列, 则

$$\|x^{k+1} - x^*\|^2 \leq \|x^k - x^*\|^2 - 2w_k r_k \sum_{j=1}^m \|\bar{d}_j^k\|^2 + w_k^2 r_k^2 \|d_k\|^2.$$

证明: 因为 x^* 是问题(2)的一个解, 所以 x^* 也满足问题(5), 即 $x^* \in Q_{m+1}$ 且 $x^* \in \bigcap_{j=1}^m Q_j$, 结合引理 3.2,

有:

$$\begin{aligned} \langle x^* - x^k, d_k \rangle &= \sum_{j=1}^m \langle x^* - x^k, \bar{d}_j^k \rangle = \sum_{j=1}^m \langle x^* + P_{Q_j}(x^k) - P_{Q_j}(x^k) - x^k, \bar{d}_j^k \rangle \\ &= \sum_{j=1}^m \|\bar{d}_j^k\|^2 + \sum_{j=1}^m \langle x^* - P_{Q_j}(x^k), P_{Q_j}(x^k) - x^k \rangle \geq \sum_{j=1}^m \|\bar{d}_j^k\|^2. \end{aligned}$$

从而可得:

$$\begin{aligned} \|x^{k+1} - x^*\|^2 &= \|P_{Q_{m+1}}(x^k + w_k r_k d_k) - x^*\|^2 \leq \|x^k + w_k r_k d_k - x^*\|^2 \\ &= \|x^k - x^*\|^2 - 2\langle x^* - x^k, w_k r_k d_k \rangle + w_k^2 r_k^2 \|d_k\|^2 \\ &\leq \|x^k - x^*\|^2 - 2w_k r_k \sum_{j=1}^m \|\bar{d}_j^k\|^2 + w_k^2 r_k^2 \|d_k\|^2. \end{aligned}$$

定理 3.1 若 $\{x^k\}$ 是由算法 3.1 产生的点列, 则它收敛到问题(2)的一个解。

证明: 令 x^* 是问题(2)的一个解, 则 x^* 也满足问题(5)。因为 $0 < \underline{w} \leq w_k \leq \bar{w} < 2, k=1,2,\dots$, 故:

$$\underline{w} r_k^2 \|d_k\|^2 (2 - \bar{w}) \geq 0,$$

由引理 3.3 得:

$$\|x^{k+1} - x^*\|^2 \leq \|x^k - x^*\|^2 - \underline{w} r_k^2 \|d_k\|^2 (2 - \bar{w}),$$

由此知 $\{\|x^k - x^*\|\}$ 是单调递减的, 从而 $\{\|x^k - x^*\|\}$ 是收敛的, 且 $\{x^k\}$, $\{d_k\}$ 均是有界的。且由此可得:

$\lim_{k \rightarrow \infty} r_k^2 \|d_k\|^2 = 0$, 从而有:

$$\lim_{k \rightarrow \infty} r_k^2 \|d_k\|^4 = 0. \quad (6)$$

又因为 $r_k = \frac{\sum_{j=1}^m \|\bar{d}_j^k\|^2}{\|d_k\|^2}$ 和 $\bar{d}_j^k = P_{Q_j}(x^k) - x^k$, 由(6)可得,

$$\lim_{k \rightarrow \infty} (P_{Q_j}(x^k) - x^k) = 0, \quad j=1,2,\dots,m. \quad (7)$$

假设 \bar{x} 是 $\{x^k\}$ 的一个聚点, 则存在 $\{x^k\}$ 的一个子列 $\{x^{k_j}\}$ 收敛到 \bar{x} , 下证 \bar{x} 是问题(5)的一个解。

首先证明: $\bar{x} \in \bigcap_{j=1}^m Q_j$ 。

事实上, 由(7)得

$$\lim_{k_j \rightarrow \infty} (P_{Q_j}(x^{k_j}) - x^{k_j}) = 0, \quad j = 1, 2, \dots, m.$$

从而得, $P_{Q_j}(\bar{x}) = \bar{x}, j = 1, \dots, m$ 。则 $\bar{x} \in \bigcap_{j=1}^m Q_j$ 。

其次证明: $\bar{x} \in Q_{m+1}$ 。

因为 $x^{k+1} = P_{Q_{m+1}}(x^k + w_k r_k d_k)$, 故

$$x^{k_j+1} = P_{Q_{m+1}}(x^{k_j} + w_{k_j} r_{k_j} d_{k_j}) \quad (8)$$

先证 $\{x^{k_j+1}\}$ 收敛。事实上, 因为 $\{x^k\}$ 是有界的, 所以 $\{x^{k_j+1}\}$ 也是有界的, 故存在收敛子列。假设 $\{x^{k_i+1}\}$ 为 $\{x^{k_j+1}\}$ 的任意一个收敛子列且 $\lim_{k_i \rightarrow \infty} x^{k_i+1} = \bar{x}$, 又因为 $\{\|x^k - x^*\|\}$ 收敛, 故 $\{\|x^{k_i+1} - x^*\|\}$ 收敛, 从而有

$$\|\bar{x} - x^*\| = \|\bar{x} - x^*\|. \quad (9)$$

由(8), 有 $\bar{x} = P_{Q_{m+1}}(\bar{x})$, 由引理 3.2 得:

$$\|\bar{x} - x^*\|^2 \leq \|\bar{x} - x^*\|^2 - \|\bar{x} - \bar{x}\|^2,$$

又由(9), 得 $\bar{x} = x^*$ 。综上所述, $\{x^{k_j+1}\}$ 收敛且收敛到 \bar{x} , 由于 Q_{m+1} 为闭凸集, 故有 $\bar{x} \in Q_{m+1}$ 。

这样, \bar{x} 为问题(5)的一个解, 从而 \bar{x} 也是问题(2)的一个解。用 \bar{x} 代替上述证明中的 x^* , 则得 $\{\|x^k - \bar{x}\|\}$ 是收敛的。而 $\{\|x^{k_j} - \bar{x}\|\}$ 收敛到 0, 故整个点列 $\{\|x^k - \bar{x}\|\}$ 是收敛到 0 的, 即 $\{x^k\}$ 收敛到 \bar{x} 。

基金项目

本文为国家自然科学基金(11271226)和山东省优秀中青年科学家科研奖励基金(BS2012SF027)资助项目。

参考文献 (References)

- [1] Donoho, D.L. (2006) Compressed sensing. *IEEE Transactions on Information Theory*, **52**, 1289-1306.
- [2] Candes, E., Romberg, J. and Tao, T. (2006) Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information. *IEEE Transactions on Information Theory*, **52**, 489-509.
- [3] 杨凡 (2010) 压缩传感图像重建的研究. 硕士论文, 江西科技师范学院, 南昌.
- [4] Gamper, U., Boesiger, P. and Kozerke, S. (2008) Compressed sensing in dynamic MRI. *Magnetic Resonance in Medicine*, **59**, 365-373.
- [5] Carmi, A., Censor, Y. and Gurfil, P. (2012) Convex feasibility modeling and projection methods for sparse signal recovery. *Journal of Computational and Applied Mathematics*, **236**, 4318-4335.
- [6] Boyd, S. and Vandenberghe, L. (2009) Convex optimization. Cambridge University Press, New York.
- [7] Zarantonello, E.H. (1971) Projections on convex sets in Hilbert space and spectral theory. In: Zarantonello, E.H., Ed., *Contributions to Nonlinear Functional Analysis*, Academic Press, New York, 237-424.

汉斯出版社为全球科研工作者搭建开放的网络学术中文交流平台。自2011年创办以来，汉斯一直保持着稳健快速发展。随着国内外知名高校学者的陆续加入，汉斯电子期刊已被450多所大中华地区高校图书馆的电子资源采用，并被中国知网全文收录，被学术界广为认同。

汉斯出版社是国内开源（Open Access）电子期刊模式的先行者，其创办的所有期刊全部开放阅读，即读者可以通过互联网免费获取期刊内容，在非商业性使用的前提下，读者不支付任何费用就可引用、复制、传播期刊的部分或全部内容。

