

一些典型凸优化问题的分裂收缩算法

基于变分不等式和邻近点算法的统一框架

南师大数科院系列讲座 2022年元月4-9日

何炳生

Homepage: maths.nju.edu.cn/~hebma

三. 从增广拉格朗日乘子法(ALM)到交替方向法(ADMM)

现在我们关心如何求解两个可分离块的凸优化问题

$$\min \{\theta_1(x) + \theta_2(y) \mid Ax + By = b, x \in \mathcal{X}, y \in \mathcal{Y}\}. \quad (0.1)$$

1 从增广拉格朗日乘子法

我们先从等式约束凸优化问题

$$\min \{\theta(u) \mid \mathcal{A}u = b, u \in \mathcal{U}\} \quad (1.1)$$

的增广拉格朗日乘子法谈起.

问题(1.1)的Lagrange函数的鞍点等价于变分不等式

$$w^* \in \Omega, \quad \theta(u) - \theta(u^*) + (w - w^*)^T F(w^*) \geq 0, \quad \forall w \in \Omega, \quad (1.2a)$$

的解点, 其中

$$w = \begin{pmatrix} u \\ \lambda \end{pmatrix}, \quad F(w) = \begin{pmatrix} -\mathcal{A}^T \lambda \\ \mathcal{A}u - b \end{pmatrix}, \quad \Omega = \mathcal{U} \times \Lambda. \quad (1.2b)$$

我们先从等式约束凸优化问题(1.1)的经典的增广拉格朗日乘子法(ALM) [10, 11] 谈起.

问题(1.1)的增广拉格朗日函数是在Lagrange函数后面加一项 $\frac{\beta}{2} \|\mathcal{A}u - b\|^2$, 其中 $\beta > 0$ 是给定的常数, 也就是说

$$\mathcal{L}_\beta(u, \lambda) = \theta(u) - \lambda^T (\mathcal{A}u - b) + \frac{\beta}{2} \|\mathcal{A}u - b\|^2. \quad (1.3)$$

求解等式约束凸优化问题(1.1) 的增广拉格朗日乘子法(ALM):

对给定的 $\beta > 0$, k 次迭代从给定的 λ^k 开始, 通过

$$\begin{cases} u^{k+1} \in \arg \min \{ \mathcal{L}_\beta(u, \lambda^k) \mid u \in \mathcal{U} \}, & (1.4a) \\ \lambda^{k+1} = \lambda^k - \beta(\mathcal{A}u^{k+1} - b), & (1.4b) \end{cases}$$

得到新的 λ^{k+1} .

在(1.4)中, u^{k+1} 是根据 λ^k 计算得来的结果. 因此, 我们称

u 为算法的中间变量 (intermediate variable), λ 为核心变量 (essential variable).

根据优化问题的最优性条件的基本引理, 方法(1.4)提供的 $w^{k+1} = (u^{k+1}, \lambda^{k+1}) \in \Omega$ 满足

$$\begin{cases} \theta(u) - \theta(u^{k+1}) + (u - u^{k+1})^T \{-\mathcal{A}^T \lambda^k + \beta \mathcal{A}^T (\mathcal{A}u^{k+1} - b)\} \geq 0, \quad \forall u \in \mathcal{U}, \\ (\lambda - \lambda^{k+1})^T \{(\mathcal{A}u^{k+1} - b) + \frac{1}{\beta}(\lambda^{k+1} - \lambda^k)\} \geq 0, \quad \forall \lambda \in \mathbb{R}^m. \end{cases}$$

进一步利用关系式 $\lambda^{k+1} = \lambda^k - \beta(\mathcal{A}u^{k+1} - b)$, 上式可以改写成: $w^{k+1} \in \Omega$,

$$\theta(u) - \theta(u^{k+1}) + \begin{pmatrix} u - u^{k+1} \\ \lambda - \lambda^{k+1} \end{pmatrix}^T \begin{pmatrix} -\mathcal{A}^T \lambda^{k+1} \\ (\mathcal{A}u^{k+1} - b) + \frac{1}{\beta}(\lambda^{k+1} - \lambda^k) \end{pmatrix} \geq 0, \quad \forall w \in \Omega.$$

接着利用(1.2)的记号, 可以把上式写成更紧凑的式子:

$$\begin{aligned} w^{k+1} \in \Omega, \quad \theta(u) - \theta(u^{k+1}) + (w - w^{k+1})^T F(w^{k+1}) \\ \geq (\lambda - \lambda^{k+1})^T \frac{1}{\beta} (\lambda^k - \lambda^{k+1}), \quad \forall w \in \Omega. \end{aligned} \quad (1.5)$$

变分不等式(1.5)中, 如果 $\lambda^k = \lambda^{k+1}$, 那么 w^{k+1} 就是变分不等式(1.2)的解. 将(1.5)中的任意 $w \in \Omega$ 设成任意一个固定的解点 $w^* \in \Omega^*$, 我们得到

$$(\lambda^{k+1} - \lambda^*)^T \frac{1}{\beta} (\lambda^k - \lambda^{k+1}) \geq \theta(u^{k+1}) - \theta(u^*) + (w^{k+1} - w^*)^T F(w^{k+1}).$$

利用前面强调过的 $(w^{k+1} - w^*)^T F(w^{k+1}) = (w^{k+1} - w^*)^T F(w^*)$, 就有

$$(\lambda^k - \lambda^*)^T \frac{1}{\beta} (\lambda^k - \lambda^{k+1}) \geq \theta(u^{k+1}) - \theta(u^*) + (w^{k+1} - w^*)^T F(w^*).$$

由 $w^{k+1} \in \Omega$ 和 w^* 的最优性, 根据(1.2), 有 $\theta(u^{k+1}) - \theta(u^*) + (w^{k+1} - w^*)^T F(w^*) \geq 0$, 上式右端非负, 所以有

$$(\lambda^{k+1} - \lambda^*)^T (\lambda^k - \lambda^{k+1}) \geq 0. \quad (1.6)$$

令 $a = \lambda^k - \lambda^*$, $b = \lambda^{k+1} - \lambda^*$, 上面的不等式就相当于 $b^T(a - b) \geq 0$,

$$\|\lambda^{k+1} - \lambda^*\|^2 \leq \|\lambda^k - \lambda^*\|^2 - \|\lambda^k - \lambda^{k+1}\|^2.$$

求解问题 (1.1) 的另一个方法是二次罚函数法, 简称罚函数法. 设 $\{r_k\}$ 是一个严格单调递增的正数序列. 罚函数法的第 k 次迭代通过

$$u^{k+1} \in \operatorname{argmin}\{\theta(u) + \frac{r_k}{2}\|Au - b\|^2 \mid u \in \mathcal{U}\} \quad (1.7)$$

得到 u^{k+1} . 在求解子问题 (1.7) 时往往以上一步迭代的解 u^k 当做初始点. 求解问题 (1.1), 增广 Lagrange 乘子法和罚函数法每步迭代要求解的子问题难度相当, 而后者数值表现远没有前者好, 对此 Nocedal 和 Wright 在他们的专著 Numerical Optimization [9] 的第 17 章中说的很清楚.

2 交替方向法

我们要求解的问题是 (0.1). 虽然用罚函数法 (1.7) 求解 (0.1) 也可以松弛成交替极小化方法—Alternating Minimization Method (AMA):

$$\begin{cases} x^{k+1} \in \operatorname{argmin}\{\theta_1(x) + \frac{\beta}{2}\|Ax + By^k - b\|^2 \mid x \in \mathcal{X}\}, \\ y^{k+1} \in \operatorname{argmin}\{\theta_2(y) + \frac{\beta}{2}\|Ax^{k+1} + By - b\|^2 \mid y \in \mathcal{Y}\}. \end{cases}$$

由于增广拉格朗日乘子法优于罚函数方法 [9], 而乘子交替方向法 (ADMM) 和交替极小化方法 (AMA) 分别由增广拉格朗日乘子法和罚函数方法松弛而来的, 因此 ADMM 优于 AMA 已成共识.

假如用经典的增广 Lagrange 乘子法 (1.4) 求解, 方法可以描述为

求解等式约束凸优化问题 (0.1) 的增广拉格朗日乘子法 (ALM):

对给定的 $\beta > 0$, k 次迭代从给定的 λ^k 开始, 通过

$$\begin{cases} (x^{k+1}, y^{k+1}) \in \operatorname{argmin}\left\{ \begin{array}{l} \theta_1(x) + \theta_2(y) - (\lambda^k)^T(Ax + By - b) \\ + \frac{\beta}{2}\|Ax + By - b\|^2 \end{array} \mid \begin{array}{l} x \in \mathcal{X} \\ y \in \mathcal{Y} \end{array} \right\}, & (2.1a) \\ \lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} - b). & (2.1b) \end{cases}$$

得到新的 λ^{k+1} .

上面直接用增广 Lagrange 乘子法求解, 缺点是没有利用问题 (0.1) 的可分离结构. 为了克服 ALM 在求解问题 (0.1) 中的缺点, 人们考虑采用乘子交替方向法 (ADMM). 主要思想是将子问题分裂成两部分. 中间变量只是 $u = (x, y)$ 中的一部分 x . 核心变量为 $v = (y, \lambda)$. 我们设迭代初始值为 $v^0 = (y^0, \lambda^0)$.

求解问题 (0.1) 的松弛的增广拉格朗日乘子法– ADMM 选定 $\beta > 0$.

第 k 步迭代从给定的 (y^k, λ^k) 开始

1. 首先, 对于给定的 (y^k, λ^k) , 求 x^{k+1} 使得

$$x^{k+1} \in \arg \min \left\{ \begin{array}{l} \theta_1(x) - (\lambda^k)^T (Ax + By^k - b) \\ + \frac{\beta}{2} \|Ax + By^k - b\|^2 \end{array} \middle| x \in \mathcal{X} \right\}. \quad (2.2a)$$

2. 利用 λ^k 和已经求得的 x^{k+1} , 求 y^{k+1} 使得

$$y^{k+1} \in \operatorname{argmin} \left\{ \begin{array}{l} \theta_2(y) - (\lambda^k)^T (Ax^{k+1} + By - b) \\ + \frac{\beta}{2} \|Ax^{k+1} + By - b\|^2 \end{array} \middle| y \in \mathcal{Y} \right\}. \quad (2.2b)$$

3. 最后, 更新Lagrange乘子

$$\lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} - b). \quad (2.2c)$$

使用凸优化问题 (0.1) 的增广 Lagrange 函数

$$\mathcal{L}_\beta^{[2]}(x, y, \lambda) = \theta_1(x) + \theta_2(y) - \lambda^T (Ax + By - b) + \frac{\beta}{2} \|Ax + By - b\|^2, \quad (2.3)$$

乘子交替方向法可以简单地表示成:

求解问题 (0.1) 的 ADMM 方法 选定 $\beta > 0$.

第 k 次迭代从给定的 (y^k, λ^k) 开始

$$\text{(ADMM)} \begin{cases} x^{k+1} = \arg \min \{ \mathcal{L}_\beta^{[2]}(x, y^k, \lambda^k) \mid x \in \mathcal{X} \}, & (2.4a) \\ y^{k+1} = \arg \min \{ \mathcal{L}_\beta^{[2]}(x^{k+1}, y, \lambda^k) \mid y \in \mathcal{Y} \}, & (2.4b) \\ \lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} - b), & (2.4c) \end{cases}$$

求得 $w^{k+1} = (x^{k+1}, y^{k+1}, \lambda^{k+1})$.

由于变动目标函数中的常数项对问题的解没有影响, 乘子交替方向法 (2.4) 的第 k 次迭代可以表述成从 (y^k, λ^k) 开始:

$$\text{(ADMM)} \begin{cases} x^{k+1} \in \operatorname{argmin} \{ \theta_1(x) - x^T A^T \lambda^k + \frac{\beta}{2} \|Ax + By^k - b\|^2 \mid x \in \mathcal{X} \} & (2.5a) \\ y^{k+1} \in \operatorname{argmin} \{ \theta_2(y) - y^T B^T \lambda^k + \frac{\beta}{2} \|Ax^{k+1} + By - b\|^2 \mid y \in \mathcal{Y} \}, & (2.5b) \\ \lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} - b). & (2.5c) \end{cases}$$

采用 ADMM 求解 (0.1) 的好处是子问题 (2.2a) 和 (2.2b) 分别只含有自变量 x 和 y , 使子问题得到简化. 譬如说下面的问题:

$$\min \left\{ \frac{1}{2} \|X - C\|_F^2 \mid X \in S_+^n \cap S_B \right\}, \quad (2.6)$$

其中集合 S_+^n 和 S_B 分别为

$$S_+^n = \{H \in R^{n \times n} \mid H^T = H, H \succeq 0\}$$

和

$$S_B = \{H \in R^{n \times n} \mid H^T = H, H_L \leq H \leq H_U\}.$$

H_L 和 H_U 都是给定的对称矩阵. 问题可以转换成等价的

$$\begin{aligned} \min \quad & \frac{1}{2}\|X - C\|^2 + \frac{1}{2}\|Y - C\|^2 \\ \text{s.t.} \quad & X - Y = 0, \\ & X \in S_+^n, Y \in S_B. \end{aligned} \tag{2.7}$$

直接用 ALM 求解 (2.6) 和 (2.7) 都无从下手. 问题 (2.7) 的等式约束的 Lagrange 乘子也是一个矩阵, 我们记它为 Z . 用 ADMM (2.2) 求解 (2.7), 只要按下面的步骤来实施:

- 对给定的 Y^k 和 Z^k ,

$$X^{k+1} = \arg \min \left\{ \frac{1}{2}\|X - C\|_F^2 - \text{Tr}(Z^k X) + \frac{\beta}{2}\|X - Y^k\|_F^2 \mid X \in S_+^n \right\}.$$

这样的 X^{k+1} 可以由

$$X^{k+1} = P_{S_+^n} \left\{ \frac{1}{1+\beta}(\beta Y^k + Z^k + C) \right\}$$

直接得到. 如何在半正定矩阵的集合上投影, 在预备知识一章已经做了介绍.

- 有了 X^{k+1} , 用 ADMM 求 Y^{k+1} 就是

$$Y^{k+1} = \arg \min \left\{ \frac{1}{2}\|Y - C\|_F^2 + \text{Tr}(Z^k Y) + \frac{\beta}{2}\|\tilde{X}^k - Y\|_F^2 \mid Y \in S_B \right\}$$

这个 Y^{k+1} 通过

$$Y^{k+1} = P_{S_B} \left\{ \frac{1}{1+\beta}(\beta X^{k+1} - Z^k + C) \right\}$$

得到, 矩阵在 A 在 $S_B = \{H \mid H_L \leq H \leq H_U\}$ 上投影,

$$P_{S_B}(A) = \min(\max(H_L, A), H_U).$$

- 最后,

$$z^{k+1} = z^k - \beta(X^{k+1} - Y^{k+1})$$

就完成了迭代.

参考文献

- [1] X.J. Cai, G.Y. Gu, B.S. He and X.M. Yuan, A proximal point algorithms revisit on the alternating direction method of multipliers, *Science China Mathematics*, 56 (2013), 2179-2186.
- [2] R. Glowinski, *Numerical Methods for Nonlinear Variational Problems*, Springer-Verlag, New York, Berlin, Heidelberg, Tokyo, 1984.
- [3] Gu G Y, He B S and Yuan X M. Customized proximal point algorithms for linearly constrained convex minimization and saddle-point problems: a unified approach. *Comput. Optim. Appl.*, 2014, 59: 135-161.
- [4] B. S. He, PPA-like contraction methods for convex optimization: a framework using variational inequality approach. *J. Oper. Res. Soc. China* 3 (2015) 391 - 420.
- [5] B. S. He, M. Tao and X.M. Yuan, Alternating direction method with Gaussian back substitution for separable convex programming, *SIAM Journal on Optimization* 22(2012), 313-340.
- [6] B.S. He, M. Tao and X.M. Yuan, A splitting method for separable convex programming, *IMA Journal of Numerical Analysis*, 31, 394-426, 2015.
- [7] B.S. He and X. M. Yuan, Convergence analysis of primal-dual algorithms for a saddle-point problem: From contraction perspective, *SIAM Journal on Imaging Science*, 5, 119-149, 2012.
- [8] B. Martinet, Regularisation, d'inéquations variationnelles par approximations successives, *Rev. Francaise d'Inform. Recherche Oper.*, 4, 154-159, 1970.
- [9] J. Nocedal and S. J. Wright, *Numerical Optimization*, Springer Verlag, New York, 1999.
- [10] M. R. Hestenes, Multiplier and gradient methods, *JOTA* 4, 303-320, 1969.
- [11] M. J. D. Powell, A method for nonlinear constraints in minimization problems, in *Optimization*, R. Fletcher, ed., Academic Press, New York, NY, pp. 283-298, 1969.
- [12] R.T. Rockafellar, Monotone operators and the proximal point algorithm, *SIAM J. Cont. Optim.*, 14, 877-898, 1976.
- [13] 何炳生. 从变分不等式的统一收缩算法到凸优化的分裂收缩算法, *高等学校计算数学学报*, 2016, 38: 74-96.
- [14] 何炳生. 凸优化的一阶分裂算法-变分不等式为工具的统一框架, 见 <http://maths.nju.edu.cn/~hebma> 中的《My Talk》.
- [15] 何炳生. 凸优化和单调变分不等式的收缩算法, 见 <http://maths.nju.edu.cn/~hebma> 中的系列讲义.