

# A-从变分不等式的投影收缩算法到凸优化的分裂收缩算法

2013年前总结的主要研究工作 [maths.nju.edu.cn/~hebma](http://maths.nju.edu.cn/~hebma) 何炳生


## 1 变分不等式的投影收缩算法 (变分不等式应用与算法建议参阅本人主页系列讲义前三讲)

设  $\Omega \subset \mathbb{R}^n$  是一个非空闭凸集,  $F$  是  $\mathbb{R}^n \rightarrow \mathbb{R}^n$  的一个映射. 考虑求解单调变分不等式

$$(VI) \quad u^* \in \Omega, \quad (u - u^*)^T F(u^*) \geq 0, \quad \forall u \in \Omega. \quad (1.1)$$

当  $\Omega = \mathbb{R}^n$ , 问题(1.1)就退化成非线性方程组  $F(u) = 0$ . 我们说一个变分不等式单调, 是指其中的算子  $F$  满足  $(u - v)^T (F(u) - F(v)) \geq 0$ . 在求解变分不等式(1.1)的投影收缩算法中, 对给定的当前点  $u^k$  和常数  $\beta_k > 0$ , 利用投影

$$\tilde{u}^k = P_\Omega[u^k - \beta_k F(u^k)] \quad (1.2)$$



生成一个预测点  $\tilde{u}^k$ . 同时假设用投影(1.2)产生  $\tilde{u}^k$  时选取的  $\beta_k$  能使得预测点  $\tilde{u}^k$  满足

$$\beta_k \|F(u^k) - F(\tilde{u}^k)\| \leq \nu \|u^k - \tilde{u}^k\|, \quad \nu \in (0, 1). \quad (1.3)$$

假如  $\tilde{u}^k = u^k$ ,  $u^k$  就是(1.1)的解(该结论证明见系列讲义第二讲). 否则, 就基于以下的分析进行新的迭代. 首先, 凸集上投影有如右上图所示的重要性质: 对任意的  $v \in \mathbb{R}^n$ , 用  $P_\Omega(v)$  表示  $v$  到  $\Omega$  上的投影, 有

$$(v - P_\Omega(v))^T (u - P_\Omega(v)) \leq 0, \quad \forall u \in \Omega. \quad (1.4)$$

在(1.4)中令  $v = u^k - \beta_k F(u^k)$ , 那么由(1.2)得到  $\tilde{u}^k = P_\Omega(v)$ , 并从(1.4)得到

$$\tilde{u}^k \in \Omega, \quad (u - \tilde{u}^k)^T \{\tilde{u}^k - [u^k - \beta_k F(u^k)]\} \geq 0, \quad \forall u \in \Omega. \quad (1.5)$$

在上面的(1.5)式两边都加上  $(u - \tilde{u}^k)^T d(u^k, \tilde{u}^k)$ , 其中

$$d(u^k, \tilde{u}^k) = (u^k - \tilde{u}^k) - \beta_k [F(u^k) - F(\tilde{u}^k)], \quad (1.6)$$

从而由投影(1.2)得到我们需要的预测公式

$$[\text{预测}] \quad \tilde{u}^k \in \Omega, \quad (u - \tilde{u}^k)^T \beta_k F(\tilde{u}^k) \geq (u - \tilde{u}^k)^T d(u^k, \tilde{u}^k), \quad \forall u \in \Omega. \quad (1.7)$$

将(1.7)中的  $u \in \Omega$  选成  $u^*$ , 就有  $(\tilde{u}^k - u^*)^T d(u^k, \tilde{u}^k) \geq (\tilde{u}^k - u^*)^T \beta_k F(\tilde{u}^k)$ . 再由单调性和VI定义, 得到

$$(\tilde{u}^k - u^*)^T d(u^k, \tilde{u}^k) \geq 0. \quad \text{因此} \quad (u^k - u^*)^T d(u^k, \tilde{u}^k) \geq (u^k - \tilde{u}^k)^T d(u^k, \tilde{u}^k). \quad (1.8)$$

由  $d(u^k, \tilde{u}^k)$  的表达式和假设(1.3), 利用 Cauchy-Schwarz 不等式, 推得

$$(u^k - \tilde{u}^k)^T d(u^k, \tilde{u}^k) \geq (1 - \nu) \|u^k - \tilde{u}^k\|^2. \quad (1.9)$$

当  $u^k \neq \tilde{u}^k$  时, (1.8)说明  $d(u^k, \tilde{u}^k)$  是距离函数  $\frac{1}{2} \|u - u^*\|^2$  在  $u^k$  处的一个上升方向. 可以用

$$[\text{单位步长的校正}] \quad u^{k+1} = u^k - d(u^k, \tilde{u}^k) \quad \text{生成新的迭代点.} \quad (1.10)$$

$$\text{由(1.6),} \quad 2(u^k - \tilde{u}^k)^T d(u^k, \tilde{u}^k) - \|d(u^k, \tilde{u}^k)\|^2 = \|u^k - \tilde{u}^k\|^2 - \beta_k^2 \|F(u^k) - F(\tilde{u}^k)\|^2. \quad (1.11)$$

$$\text{因此,} \quad \|u^k - u^*\|^2 - \|u^{k+1} - u^*\|^2 \stackrel{(1.10)}{=} 2(u^k - u^*)^T d(u^k, \tilde{u}^k) - \|d(u^k, \tilde{u}^k)\|^2 \\ \stackrel{(1.8)}{\geq} 2(u^k - \tilde{u}^k)^T d(u^k, \tilde{u}^k) - \|d(u^k, \tilde{u}^k)\|^2 \stackrel{(1.11) \& (1.3)}{\geq} (1 - \nu^2) \|u^k - \tilde{u}^k\|^2. \quad (1.12)$$

$$[\text{计算步长的校正}] \quad u^{k+1} = u^k - \alpha_k^* d(u^k, \tilde{u}^k) \quad \text{产生离 } u^* \text{ 更近的迭代点.} \quad (1.13)$$

$$\text{其中步长 } \alpha_k^* \text{ 由 } \alpha_k^* = (u^k - \tilde{u}^k)^T d(u^k, \tilde{u}^k) / \|d(u^k, \tilde{u}^k)\|^2 \text{ 给出.} \quad (1.14)$$

注意到(1.12)中的最后一个不等式隐含了  $2(u^k - \tilde{u}^k)^T d(u^k, \tilde{u}^k) > \|d(u^k, \tilde{u}^k)\|^2$ , 因而  $\alpha_k^* > \frac{1}{2}$ . 接着就有

$$\|u^k - u^*\|^2 - \|u^{k+1} - u^*\|^2 = \|u^k - u^*\|^2 - \|u^k - u^* - \alpha_k^* d(u^k, \tilde{u}^k)\|^2 \quad (\text{利用了(1.13)}) \\ = 2\alpha_k^* (u^k - u^*)^T d(u^k, \tilde{u}^k) - (\alpha_k^*)^2 \|d(u^k, \tilde{u}^k)\|^2 \quad (\text{利用(1.8)和(1.14)}) \\ \geq \alpha_k^* (u^k - \tilde{u}^k)^T d(u^k, \tilde{u}^k) \geq \frac{1}{2} (1 - \nu) \|u^k - \tilde{u}^k\|^2. \quad (\text{利用了 } \alpha_k^* > \frac{1}{2} \text{ 和(1.9)}) \quad (1.15)$$

收缩不等式(1.12)和(1.15)是证明算法收敛的关键式子. 分处不等式(1.7)两端的  $\beta_k F(\tilde{u}^k)$  和  $d(u^k, \tilde{u}^k)$  称为一对孪生方向. 将在B中证明的美妙之处是: 采用方向  $\beta_k F(\tilde{u}^k)$  和(1.14)中给出的步长  $\alpha_k^*$ , 用

$$[\text{投影校正}] \quad u^{k+1} = P_\Omega[u^k - \alpha_k^* \beta_k F(\tilde{u}^k)] \quad \text{与方法(1.13)具有同样的收敛性质(1.15), 详见B.}$$

✧ 孪生方向, 相同步长. 姊妹方法, 投影校正效果更好! 真所谓 兄弟齐心, 其利断金! ✧

## 2 线性约束凸优化分裂收缩算法的统一框架 (参见何炳生 2015, 2018 运筹学报文章)

我们在变分不等式框架下讨论线性约束凸优化的分裂收缩算法, 以三块可分离凸优化问题

$$\min\{\theta_1(x) + \theta_2(y) + \theta_3(z) \mid Ax + By + Cz = b, x \in \mathcal{X}, y \in \mathcal{Y}, z \in \mathcal{Z}\} \quad (2.1)$$

为例做介绍. 问题 (2.1) 的拉格朗日函数是  $L(x, y, z, \lambda) = \theta_1(x) + \theta_2(y) + \theta_3(z) - \lambda^T(Ax + By + Cz - b)$ .

拉格朗日函数的鞍点  $(x^*, y^*, z^*, \lambda^*)$  (其中  $(x, y, z)$  为原始变量,  $\lambda$  为对偶变量) 满足

$$L_{\lambda \in \mathfrak{R}^m}(x^*, y^*, z^*, \lambda) \leq L(x^*, y^*, z^*, \lambda^*) \leq L_{x \in \mathcal{X}, y \in \mathcal{Y}, z \in \mathcal{Z}}(x, y, z, \lambda^*).$$

利用鞍点  $w^* = (x^*, y^*, z^*, \lambda^*)$  的极大极小性质 (推导可参见 C 或 D), 它可以表述为如下的变分不等式:

$$(VI) \quad w^* \in \Omega, \quad \theta(u) - \theta(u^*) + (w - w^*)^T F(w^*) \geq 0, \quad \forall w \in \Omega, \quad (2.2)$$

其中,  $\Omega = \mathcal{X} \times \mathcal{Y} \times \mathcal{Z} \times \mathfrak{R}^m$ ,  $\theta(u) = \theta_1(x) + \theta_2(y) + \theta_3(z)$ , 并且

$$u = \begin{pmatrix} x \\ y \\ z \end{pmatrix}, \quad w = \begin{pmatrix} x \\ y \\ z \\ \lambda \end{pmatrix}, \quad F(w) = \begin{pmatrix} -A^T \lambda \\ -B^T \lambda \\ -C^T \lambda \\ Ax + By + Cz - b \end{pmatrix}. \quad (2.3)$$

注意到, (2.3) 中的  $F(w)$  恰有  $(w - \tilde{w})^T (F(w) - F(\tilde{w})) \equiv 0$ .

加之  $\theta(u)$  是凸函数 (不一定可微), 我们称 (2.2) 为单调 (混合) 变分不等式, 简称单调变分不等式.

我们首先介绍与投影收缩算法类似的求解单调变分不等式问题 (2.2) 的**预测-校正收缩算法**.

**[预测]** 对给定的  $v^k$  (在两块可分离问题的 ADMM 中  $v = (y, \lambda)$ , 有些算法中  $v = w$ ), 求得点  $\tilde{w}^k$ , 使得

$$\tilde{w}^k \in \Omega, \quad \theta(u) - \theta(\tilde{u}^k) + (w - \tilde{w}^k)^T F(\tilde{w}^k) \geq (v - \tilde{v}^k)^T Q(v^k - \tilde{v}^k), \quad \forall w \in \Omega, \quad (2.4)$$

如果矩阵  $Q^T + Q$  正定 ( $Q$  不一定对称), 我们称 (2.4) 为合格的预测. 例见短篇 F 的 (4.2)

利用预测 (2.4), 可以建立求解单调变分不等式 (2.2) 的**预测-校正的统一框架**. (ADMM 为其一个特例).

**[单位步长的校正]** 采用单位步长, 新迭代点的校正公式为 例见短篇 F 的 (4.3)

$$v^{k+1} = v^k - M(v^k - \tilde{v}^k). \quad (2.5)$$

由合格预测 (2.4) 和单位步长的校正 (2.5), 组成一个预测-校正算法框架, 其收敛性条件是:

**[收敛性条件]** 要求存在正定矩阵  $H$ , 能够使得 例见短篇 F 的 (4.4)-(4.6)

$$HM = Q \quad \text{并且} \quad G = Q^T + Q - M^T H M \succ 0. \quad (\text{正定}) \quad (2.6)$$

将 (2.4) 中任意的  $w \in \Omega$  选成某个解点  $w^*$ , 利用  $(\tilde{w} - w^*)^T F(\tilde{w}) = (\tilde{w} - w^*)^T F(w^*)$  和  $w^*$  是解这一事实,

$$\text{得到} \quad (\tilde{v}^k - v^*)^T Q(v^k - \tilde{v}^k) \geq 0. \quad \text{进而有} \quad (v^k - v^*)^T Q(v^k - \tilde{v}^k) \geq (v^k - \tilde{v}^k)^T Q(v^k - \tilde{v}^k). \quad (2.7)$$

$$\begin{aligned} \|v^k - v^*\|_H^2 - \|v^{k+1} - v^*\|_H^2 &= \|v^k - v^*\|_H^2 - \|(v^k - v^*) - M(v^k - \tilde{v}^k)\|_H^2 \quad (\text{利用 } HM = Q) \\ &\geq (v^k - \tilde{v}^k)^T (Q^T + Q)(v^k - \tilde{v}^k) - \|M(v^k - \tilde{v}^k)\|_H^2 \stackrel{(2.6)}{=} \|v^k - \tilde{v}^k\|_G^2. \end{aligned} \quad (2.8)$$

不等式 (2.8) 说明统一框架算法在条件 (2.6) 满足的情况下, 迭代方法生成的序列  $\{v^k\}$  具有收缩性质

$$\|v^{k+1} - v^*\|_H^2 \leq \|v^k - v^*\|_H^2 - \|v^k - \tilde{v}^k\|_G^2. \quad (\text{这是证明方法收敛性的关键不等式}) \quad (2.9)$$

结论: 由预测 (2.4) 和校正 (2.5) 构成的求解 VI 问题 (2.2) 的算法统一框架, 条件 (2.6) 满足时方法就收敛.

根据 (2.4), 也可以如同 §1 中考虑  $H$ -模下计算步长的校正, 这里的  $H$  为任意的正定矩阵 (也可以是单位阵). 由 (2.7) 得知, 只要  $(v^k - \tilde{v}^k)^T Q(v^k - \tilde{v}^k) > 0$  (请注意这是一个比  $Q^T + Q \succ 0$  宽松的条件), 向量  $H^{-1}Q(v^k - \tilde{v}^k)$  是距离函数  $\frac{1}{2}\|v - v^*\|_H^2$  在  $v^k$  处的一个上升方向. 如同 §1 的投影收缩算法中有了 (1.8), 可以用 (1.13)-(1.14) 进行计算步长的校正. 此时我们可以在  $H$  模下利用 (2.7) 实行计算步长的校正:

**[计算步长的校正]** 对选定的正定矩阵  $H$ , 由以下法则生成新的迭代点:

$$v^{k+1} = v^k - \alpha_k^* M(v^k - \tilde{v}^k), \quad \text{其中} \quad M = H^{-1}Q, \quad (2.10a)$$

$$\text{步长 } \alpha_k^* \quad \text{由} \quad \alpha_k^* = (v^k - \tilde{v}^k)^T Q(v^k - \tilde{v}^k) / \|M(v^k - \tilde{v}^k)\|_H^2 \quad \text{给出.} \quad (2.10b)$$

$$\begin{aligned} \|v^k - v^*\|_H^2 - \|v^{k+1} - v^*\|_H^2 &\stackrel{(2.10a)}{=} \|v^k - v^*\|_H^2 - \|(v^k - v^*) - \alpha_k^* M(v^k - \tilde{v}^k)\|_H^2 \quad (\text{利用 } HM = Q) \\ &\geq \alpha_k^* (v^k - \tilde{v}^k)^T (Q^T + Q)(v^k - \tilde{v}^k) - \alpha_k^* (\alpha_k^* \|M(v^k - \tilde{v}^k)\|_H^2) \stackrel{(2.10b)}{=} \frac{1}{2} \alpha_k^* \|v^k - \tilde{v}^k\|_{(Q^T + Q)}^2. \end{aligned} \quad (2.11)$$

✧ 从 变分不等式的投影收缩算法 到 凸优化的分裂收缩算法, 一条主线, 一个模式! ✧