

从变分不等式的投影收缩算法到凸优化的分裂收缩算法

— 我主导的主要研究工作 maths.nju.edu.cn/~hebma 何炳生

1 变分不等式的投影收缩算法

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. 考虑单调变分不等式

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

我们说变分不等式单调, 是指其中的算子 F 满足 $(u - v)^\top (F(u) - F(v)) \geq 0$. 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 $\beta_k > 0$, 我们利用投影

$$\tilde{u}^k = P_\Omega[u^k - \beta_k F(u^k)] \quad (\text{也即 } \tilde{u}^k = \text{Arg min} \{ \frac{1}{2} \|u - [u^k - \beta_k F(u^k)]\|^2 \mid u \in \Omega \})$$

生成一个预测点 \tilde{u}^k . 对任意的 $\beta_k > 0$, 假如 $\tilde{u}^k = u^k$, u^k 就是 (1.1) 的解. 否则, 我们假设选取的 β_k 满足

$$\beta_k \|F(u^k) - F(\tilde{u}^k)\| \leq \nu \|u^k - \tilde{u}^k\|, \quad \nu \in (0, 1). \quad (1.2)$$

由于 \tilde{u}^k 是问题 $\min \{ \frac{1}{2} \|u - [u^k - \beta_k F(u^k)]\|^2 \mid u \in \Omega \}$ 的解. 根据极小化问题的最优性条件(与“瞎子爬山”类似, 只是这里是探“底”), 可行方向和下降方向的交集是空集, 就有

$$\tilde{u}^k \in \Omega, \quad (u - \tilde{u}^k)^\top \{ \tilde{u}^k - [u^k - \beta_k F(u^k)] \} \geq 0, \quad \forall u \in \Omega. \quad (1.3)$$

上式两边都加上 $(u - \tilde{u}^k)^\top d(u^k, \tilde{u}^k)$, 其中

$$d(u^k, \tilde{u}^k) = (u^k - \tilde{u}^k) - \beta_k [F(u^k) - F(\tilde{u}^k)]. \quad (1.4)$$

由此得到我们需要的预测公式

$$\text{[预测]} \quad \tilde{u}^k \in \Omega, \quad (u - \tilde{u}^k)^\top \beta_k F(\tilde{u}^k) \geq (u - \tilde{u}^k)^\top d(u^k, \tilde{u}^k), \quad \forall u \in \Omega. \quad (1.5)$$

将 (1.5) 中任意的 $u \in \Omega$ 选成 u^* , 就有 $(\tilde{u}^k - u^*)^\top d(u^k, \tilde{u}^k) \geq 0$, 随后得到

$$(u^k - u^*)^\top d(u^k, \tilde{u}^k) \geq (u^k - \tilde{u}^k)^\top d(u^k, \tilde{u}^k). \quad (1.6)$$

由假设 (1.2), 容易推得

$$(u^k - \tilde{u}^k)^\top d(u^k, \tilde{u}^k) \geq (1 - \nu) \|u^k - \tilde{u}^k\|^2. \quad (1.7)$$

当 u^k 不是 (1.1) 的解时, 不等式 (1.6) 右端为正, 说明 (1.4) 中定义的 $d(u^k, \tilde{u}^k)$ 是未知函数 $\frac{1}{2} \|u - u^*\|^2$ 在 u^k 处欧氏模下的一个上升方向. 因此, 可以

$$\text{[校正]} \quad \text{用 } u^{k+1} = u^k - \alpha_k^* d(u^k, \tilde{u}^k) \quad \text{产生离 } u^* \text{ 更近的迭代点.} \quad (1.8)$$

$$\text{其中步长 } \alpha_k^* \text{ 由 } \alpha_k^* = (u^k - \tilde{u}^k)^\top d(u^k, \tilde{u}^k) / \|d(u^k, \tilde{u}^k)\|^2 \text{ 给出.} \quad (1.9)$$

由 (1.2) 和 (1.4), 可得 $2(u^k - \tilde{u}^k)^\top d(u^k, \tilde{u}^k) > \|d(u^k, \tilde{u}^k)\|^2$, 因而 $\alpha_k^* > \frac{1}{2}$. 接着就有

$$\begin{aligned} \|u^k - u^*\|^2 - \|u^{k+1} - u^*\|^2 & \quad (\text{利用 (1.8), (1.6), (1.9) 和 (1.7)}) \\ & \geq \alpha_k^* (u^k - \tilde{u}^k)^\top d(u^k, \tilde{u}^k) \geq \frac{1}{2} (1 - \nu) \|u^k - \tilde{u}^k\|^2. \end{aligned} \quad (1.10)$$

这是证明算法收敛的关键不等式. 分处不等式 (1.5) 两端的 $\beta_k F(\tilde{u}^k)$ 和 $d(u^k, \tilde{u}^k)$ 称为一对孪生方向. 这里最美妙的是: 采用方向 $\beta_k F(\tilde{u}^k)$ 和 (1.9) 中给出的步长 α_k^* , 用

$$\text{[投影校正]} \quad u^{k+1} = P_\Omega[u^k - \alpha_k^* \beta_k F(\tilde{u}^k)] \quad \text{与方法 (1.8) 具有同样的收敛性质 (1.10).}$$

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

2 凸优化的分裂收缩算法

$$\text{我们以可分离凸优化} \quad \min\{\theta_1(x) + \theta_2(y) \mid Ax + By = b, x \in \mathcal{X}, y \in \mathcal{Y}\} \quad (2.1)$$

为例, 它的拉格朗日函数可以写成 $L(x, y, \lambda) = \theta_1(x) + \theta_2(y) - \lambda^\top (Ax + By - b)$.
拉格朗日函数 $L(x, y, \lambda)$ 的鞍点 $((x^*, y^*), \lambda^*)$ 满足

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

利用鞍点 $w^* = ((x^*, y^*), \lambda^*)$ 的上述极大极小性质, 它可以表述为以下的变分不等式:

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

上面的变分不等式中, $\Omega = \mathcal{X} \times \mathcal{Y} \times \mathbb{R}^m$, $\theta(u) = \theta_1(x) + \theta_2(y)$, 并且

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

注意到, (2.3) 中的 $F(w)$, 恰有 $(w - \tilde{w})^\top (F(w) - F(\tilde{w})) = 0$, 所以也是单调的.

求解 (2.2) 这样的变分不等式问题, ADMM 类方法都属于一个 **预测-校正的统一框架**.

[预测]. 对给定的 v^k ($v = w$ 或是 w 的部分分量), 求得预测点 \tilde{w}^k , 使其满足

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

其中矩阵 Q 不一定对称, 但 $Q^\top + Q$ (本质上) 正定. 实现预测, 只要能求解子问题

$$\min\{\theta_1(x) + r\|Ax - p\|^2 \mid x \in \mathcal{X}\} \quad \text{和} \quad \min\{\theta_2(y) + s\|By - q\|^2 \mid y \in \mathcal{Y}\}. \quad (2.5)$$

剩下的事情就是将 (2.4) 中任意的 $w \in \Omega$ 选成 w^* , 得到 $(\tilde{v}^k - v^*)^\top Q(v^k - \tilde{v}^k) \geq 0$ 和

$$[H(v^k - v^*)]^\top [H^{-1}Q(v^k - \tilde{v}^k)] \geq (v^k - \tilde{v}^k)^\top Q(v^k - \tilde{v}^k). \quad (2.6)$$

这里 H 为任意正定矩阵(可以是单位阵). 由 (2.6) 和 $Q^\top + Q$ 正定, $H^{-1}Q(v^k - \tilde{v}^k)$ 是未知函数 $\frac{1}{2}\|v - v^*\|_H^2$ 在 v^k 处 H -模下的一个上升方向, 据此用余弦公式求离解集更近的点.

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

$$v^{k+1} = v^k - \alpha_k^* M(v^k - \tilde{v}^k), \quad \text{其中} \quad M = H^{-1}Q, \quad \alpha_k^* = \frac{(v^k - \tilde{v}^k)^\top Q(v^k - \tilde{v}^k)}{\|M(v^k - \tilde{v}^k)\|_H^2}. \quad (2.7)$$

[固定步长的校正]. 对上面提到的矩阵 M , 也可以取固定步长的校正公式

$$v^{k+1} = v^k - \alpha M(v^k - \tilde{v}^k), \quad \text{其中步长} \quad \alpha > 0 \quad (2.8)$$

$$\text{使得} \quad G = Q^\top + Q - \alpha M^\top H M \succ 0, \quad (\text{正定}) \quad (2.9)$$

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

因此, 生成的序列 $\{v^k\}$ 具有收缩性质 $\|v^{k+1} - v^*\|_H^2 \leq \|v^k - v^*\|_H^2 - \alpha \|v^k - \tilde{v}^k\|_G^2$.

✂ 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, 一脉相承! ✂