

最优化理论与方法笔记

叶胥达

2021 年 1 月 11 日

目录

1	无约束优化基本理论	2
1.1	基本概念	2
1.2	收敛速度	3
2	线搜索准则	5
2.1	精确线搜索准则	5
2.2	插值法	8
2.3	单调非精确线搜索方法	9
3	Newton 型方法	12
3.1	基本 Newton 方法	12
3.2	修正 Newton 方法	14
3.2.1	特征值修正方法	14
3.2.2	修正 Cholesky 分解	14
3.3	非精确 Newton 算法	17
3.4	全局非精确 Newton 方法	18
4	拟 Newton 算法	21
4.1	拟 Newton 算法简介	21
4.2	有限内存 BFGS 方法	23
4.2.1	Two-Loop Recursion	24
4.2.2	Compact Representation	24

5 信赖域方法	26
5.1 信赖域方法的基本框架	26
5.2 Cauchy 点及性质	28
5.3 信赖域方法的收敛性	28
5.4 Levenberg-Marquardt 方法	31
5.5 信赖域子问题的最优解分析	34
5.6 数值求解信赖域子问题的算法	37
5.6.1 Hebden 方法	38
5.6.2 More-Sorensen 方法	39
5.6.3 Dogleg 方法	40
5.6.4 二维子空间极小化方法	40
6 约束优化理论	42
6.1 约束优化的基本概念	42
6.2 一阶必要条件	43
6.3 一阶充分条件	51
6.4 二阶最优化条件	54
6.5 鞍点理论	56
6.6 对偶问题	57
7 可行方向法	62
7.1 可行方向法的一般性质	62
7.2 变量消去法	63
7.3 Rosen 投影梯度法	66
7.3.1 投影矩阵及其性质	66
7.3.2 投影梯度矩阵构造可行下降方向	68
7.4 Zoutendijk 可行方向	71

1 无约束优化基本理论

1.1 基本概念

考虑无约束最优化问题

$$\min_{x \in \mathbb{R}^n} f(x)$$

- 一阶必要条件: $\nabla f(x^*) = 0$
- 二阶必要条件: $\nabla^2 f(x^*)$ 半正定
- 二阶充分条件: $\nabla^2 f(x^*)$ 正定

我们一般使用迭代格式求解最优化问题:

$$x_{k+1} = x_k + \alpha_k d_k \quad (1.1)$$

其中 x_k 为迭代点, d_k 为下降方向, α_k 为步长. 下降方向选取的最基本准则是: 沿着方向 d_k 应当使得目标函数值下降, 即

$$g_k^T d_k < 0 \quad (1.2)$$

于是 $f(x_k + \alpha d_k)$ 在 α 很小时是关于步长 α 的减函数.

1.2 收敛速度

收敛速度是用于刻画算法效率的重要指标.

定义 1.1 (Q 收敛速度) 设存在 $p \geq 1$ 和 $q > 0$ 使得

$$\lim_{k \rightarrow \infty} \frac{\|x_{k+1} - x^*\|}{\|x_k - x^*\|^p} = q = Q_p\{x_k\}$$

则称 $\{x_k\}$ 具有 p 阶收敛速度.

收敛速度的一些例子:

- $p = 1, q \in (0, 1)$, 线性收敛:

$$x_k = 1 + \frac{1}{2^k}$$

- $p = 1, q = 0$, 超线性收敛:

$$x_k = k^{-k}$$

- $p = 1, q = 1$, 次线性收敛:

$$x_k = \frac{1}{k}$$

- $p > 1, q < +\infty$, 超线性收敛

定理 1.1 (超线性收敛的刻画) 设 $x_k \rightarrow x^*$, 记 $h_k = x_k - x^*$ 且 $s_k = x_{k+1} - x_k$, 则 $\{x_k\}$ 超线性收敛等价于下列四式中任意一个:

- (i) $h_{k+1} = o(\|h_k\|)$;
- (ii) $h_{k+1} = o(\|s_k\|)$;
- (iii) $s_k = -h_k + o(\|h_k\|)$;
- (iv) $s_k = -h_k + o(\|s_k\|)$

定义 1.2 (R 收敛速度) 给定 $p \geq 1$, 设迭代点序列 $\{x_k\}$ 满足

$$R_p\{x_k\} = \begin{cases} \overline{\lim}_{k \rightarrow \infty} \|x_k - x^*\|^{\frac{1}{k}} \\ \overline{\lim}_{k \rightarrow \infty} \|x_k - x^*\|^{\frac{1}{p^k}} \end{cases}$$

R 收敛速度不依赖于范数的选取.

定理 1.2 若 $\{x_k\}$ 具有 p 阶 Q 收敛速度, 则它也有 p 阶 R 收敛速度. 特别地, 若 $p = 1$, 则

$$Q_1\{x_k\} \geq R_1\{x_k\}$$

设 $q = Q_1\{x_k\}$, 则对任意 $\varepsilon > 0$, 当 k 充分大时总有

$$\|x_{k+1} - x^*\| \leq (q + \varepsilon) \|x_k - x^*\|^p$$

当 $p = 1$ 时, 有

$$\|x_k - x^*\| \leq (q + \varepsilon)^{k-k_0} \|x_{k_0} - x^*\|$$

因此

$$\|x_k - x^*\|^{\frac{1}{k}} \leq (q + \varepsilon)^{1-\frac{k_0}{k}} \|x_{k_0} - x^*\|^{\frac{1}{k}}$$

令 $k \rightarrow \infty$, 有

$$R_1\{x_k\} = \lim_{k \rightarrow \infty} \|x_k - x^*\|^{\frac{1}{k}} \leq q + \varepsilon$$

令 $\varepsilon \rightarrow 0$, 得到 $R_1\{x_k\} \leq Q_1\{x_k\}$. 在 $p > 1$ 时, 类似可以得到

$$\|x_k - x^*\| \leq (q + \varepsilon)^{s(k-k_0)} \|x_{k_0} - x^*\|^{p^{k-k_0}}$$

其中

$$s(m) = \sum_{i=0}^{m-1} p^i = \frac{p^m - 1}{p - 1}$$

于是

$$\|x_k - x^*\|^{\frac{1}{p^k}} \leq (q + \varepsilon)^{\frac{p^{-k_0} - p^{-k}}{p-1}} \|x_{k_0} - x^*\|^{-p^{k_0}}$$

令 $k \rightarrow \infty$, 有

$$R_p\{x_k\} = \lim_{k \rightarrow \infty} \|x_k - x^*\|^{\frac{1}{p^k}} \leq (q + \varepsilon)^{\frac{p^{-k_0}}{p-1}} \|x_{k_0} - x^*\|^{-p^{k_0}}$$

即 $R_p\{x_k\}$ 是一个有限值.

2 线搜索准则

在得到下降方向 d_k 后, 一个关键的步骤是在 d_k 上求步长 α , 使得目标函数

$$f(x_k + \alpha d_k)$$

下降到较低的水平. 为简单起见, 我们去掉下标 k 并讨论 $f(x + \alpha d)$ 的优化问题. [进退法](#)是用来确定搜索区间的一种简单策略, 它输出一个区间 $[a, b]$, 使得一定有极小点位于此区间中.

关于 $f(x + \alpha d)$ 的优化问题可以简化为关于一维函数

$$\varphi(\alpha) = f(x + \alpha d) \tag{2.1}$$

的优化, 此时

$$\varphi'(\alpha) = d^T g(x + \alpha d) \tag{2.2}$$

2.1 精确线搜索准则

所谓的精确线搜索就是求 $\varphi(\alpha)$ 在指定区间上的最小值, 即求步长 α_k 使得

$$\alpha_k = \arg \min_{\alpha} \varphi(\alpha) \tag{2.3}$$

黄金分割 (0.618 方法) 可以方便地求单峰函数的最小值.

Algorithm 1: 0.618 方法

```

输入: 初始区间  $[a, b]$ 
输出: 极小点  $\theta \in [a, b]$ 
给定一个小常数  $\varepsilon_0$ , 计算常数  $\tau = \frac{\sqrt{5}-1}{2}$ 
while true do
    计算试探函数点  $\lambda = a + (1 - \tau)(b - a)$ ,  $\mu = a + \tau(b - a)$ 
    if  $\varphi(\lambda) > \varphi(\mu)$  then
        (左边函数值大, 极小点在  $[\lambda, b]$ )
         $a = \lambda$ ,  $\lambda = \mu$ ,  $\mu = a + \tau(b - a)$ 
        if  $b - a < \varepsilon_0$  then
             $\theta = \mu$ 
            return
        end
    else
        (右边函数值大, 极小点在  $[a, \mu]$ )
         $b = \mu$ ,  $\mu = \lambda$ ,  $\lambda = a + (1 - \tau)(b - a)$ 
        if  $b - a < \varepsilon_0$  then
             $\theta = \lambda$ 
            return
        end
    end
end

```

黄金分割法仅利用了函数值的信息, 没有用到导数信息, 具有一阶收敛速度.

精确线搜索方法的收敛性分析:

定理 2.1 (下降量的估计) 设步长 α_k 由精确线搜索得到, 且

$$\|\nabla^2 f(x_k + \alpha d_k)\| \leq M$$

对一切 $\alpha > 0$ 成立. 则有

$$f_k - f_{k+1} \geq \frac{1}{2M} \|g_k\|^2 \cos^2 \theta_k$$

其中 θ_k 是下降方向 d_k 和负梯度方向 $-g_k$ 的夹角.

定理 2.2 (精确线搜索的收敛性) 设 $\nabla f(x)$ 在水平集 $L = \{x \in \mathbb{R}^n : f(x) \leq f(x_0)\}$ 上存在且

一致连续. 若精确线搜索产生的迭代序列满足

$$\theta_k \leq \frac{\pi}{2} - \mu, \quad \text{对某个 } \mu > 0$$

则或者对某个 k 有 $g_k = 0$, 或者 $f_k \rightarrow -\infty$, 或者 $g_k \rightarrow 0$.

[Proof: 袁亚湘 p63-64]

反证法, 若结论不成立, 则存在一个无穷集 K 使得

$$\|g_k\| \geq \varepsilon, \quad \forall k \in K$$

因此利用夹角条件可以给出 $-g_k^T d_k$ 的下界估计:

$$-g_k^T d_k = \cos \theta_k \|g_k\| \|d_k\| \geq \varepsilon_1 \|d_k\|, \quad \forall k \in K$$

下面利用 Taylor 展开对每步下降量 $f_k - f_{k+1}$ 作出估计: 对任何 $\alpha \geq 0$, 有

$$f(x_k + \alpha d_k) = f(x_k) + \alpha d_k^T g(\xi_k)$$

其中 $\xi_k \in [x_k, x_k + \alpha d_k]$. 因此

$$\begin{aligned} f_{k+1} - f_k &\leq f(x_k + \alpha d_k) - f_k \\ &= \alpha d_k^T g(\xi_k) \\ &= \alpha d_k^T g_k + \alpha d_k^T [g(\xi_k) - g_k] \\ &\leq -\alpha \varepsilon_1 \|d_k\| + \alpha d_k^T [g(\xi_k) - g_k] \end{aligned}$$

由于 $g(x) = \nabla f(x)$ 一致连续, 故存在 $\bar{\alpha} > 0$ 使得

$$\alpha \|d_k\| \leq \bar{\alpha} \implies |g(\xi_k) - g_k| \leq \frac{\varepsilon_1}{2}$$

此时

$$f_{k+1} - f_k \leq -\alpha \varepsilon_1 \|d_k\| + \alpha \|d_k\| \frac{\varepsilon_1}{2} = -\frac{\alpha}{2} \varepsilon_1 \|d_k\|$$

特别地, 我们可以取 $\alpha \|d_k\| = \bar{\alpha}$, 从而得到

$$f_{k+1} - f_k \leq -\frac{\bar{\alpha}}{2} \varepsilon_1, \quad \forall k \in K$$

即每一步函数的下降量都至少是一个常数. 但 $\sum_{k=1}^{\infty} (f_k - f_{k+1})$ 为有限值, 矛盾!

精确线搜索的特点是比任何其它步长选择都更好.

2.2 插值法

插值法的基本思想是用一个简单的函数 $q(\alpha)$ (常常是多项式函数) 对目标函数 $\varphi(\alpha)$ 进行逼近, 然后用 $q(\alpha)$ 的极小点对 $\varphi(\alpha)$ 的极小点进行近似. 由于 $q(\alpha)$ 要用来刻画 $\varphi(\alpha)$ 的极小点, 应当至少使用二次多项式, 即

$$q(\alpha) = a\alpha^2 + b\alpha + c \quad (2.4)$$

来逼近 $\varphi(\alpha)$. 该函数的极小点为

$$\alpha^* \approx \bar{\alpha} = -\frac{b}{2a} \quad (2.5)$$

一点二次插值法 在给定的点 α_1 处, 使用 $\varphi(\alpha_1), \varphi'(\alpha_1), \varphi''(\alpha_1)$ 对 $\varphi(\alpha)$ 进行插值, 得到

$$a = \frac{1}{2}\varphi''(\alpha_1), \quad b = \varphi'(\alpha_1) - \varphi''(\alpha_1)\alpha_1$$

因此计算所得 $q(\alpha)$ 的极小点为

$$\bar{\alpha} = -\frac{b}{2a} = \alpha_1 - \frac{\varphi'(\alpha_1)}{\varphi''(\alpha_1)}$$

相应的迭代格式为

$$\alpha_{k+1} = \alpha_k - \frac{\varphi'(\alpha_k)}{\varphi''(\alpha_k)}$$

两点二次插值 I 在区间 $[\alpha_1, \alpha_2]$ 上给定 $\varphi(\alpha_1), \varphi'(\alpha_1), \varphi(\alpha_2)$ 的值, 则 $q(\alpha)$ 的参数为

$$a = \frac{\varphi_1 - \varphi_2 - \varphi'_1(\alpha_1 - \alpha_2)}{-(\alpha_1 - \alpha_2)^2}$$

$$b = \varphi'_1 + 2 \cdot \frac{\varphi_1 - \varphi_2 - \varphi'_1(\alpha_1 - \alpha_2)}{(\alpha_1 - \alpha_2)^2} \cdot \alpha_1$$

计算所得 $q(\alpha)$ 的极小点为

$$\bar{\alpha} = \alpha_1 - \frac{(\alpha_1 - \alpha_2)\varphi'_1}{2[\varphi'_1 - \frac{\varphi_1 - \varphi_2}{\alpha_1 - \alpha_2}]}$$

相应的迭代格式为

$$\alpha_{k+1} = \alpha_k - \frac{(\alpha_k - \alpha_{k-1})\varphi'_k}{2[\varphi'_k - \frac{\varphi_k - \varphi_{k+1}}{\alpha_k - \alpha_{k+1}}]}$$

两点二次插值 II 在区间 $[\alpha_1, \alpha_2]$ 上给定 $\varphi'(\alpha_1), \varphi'(\alpha_2)$ 的值, 极小点为

$$\bar{\alpha} = \alpha_1 - \frac{\alpha_1 - \alpha_2}{\varphi'_1 - \varphi'_2} \varphi'_1$$

相应的迭代格式为

$$\alpha_{k+1} = \alpha_k - \frac{\alpha_k - \alpha_{k-1}}{\varphi'_k - \varphi'_{k-1}} \varphi'_{k-1}$$

2.3 单调非精确线搜索方法

我们在本节介绍单调非精确线搜索方法, 这里单调的含义是保证目标函数在每步迭代之后单调下降, 即 $f(x_k + \alpha_k d_k) \leq f(x_k)$. 非精确意味着步长 α_k 不需要被精确计算, 只需满足特定的不等式条件即可. 我们仍然记 $\varphi(\alpha) = f(x_k + \alpha d_k)$, 则 $\varphi(0) = f_k$, $\varphi'(0) = g_k^T d_k$.

Armijo 准则

$$\varphi(\alpha) \leq \varphi(0) + \rho \varphi'(0)\alpha$$

其中 $\rho \in (0, 1)$.

Goldstein 准则

$$\varphi(\alpha) \leq \varphi(0) + \rho \varphi'(0)\alpha$$

$$\varphi(\alpha) \geq \varphi(0) + (1 - \rho) \varphi'(0)\alpha$$

其中 $\rho \in (0, \frac{1}{2})$.

Wolfe 准则

$$\varphi(\alpha) \leq \varphi(0) + \rho \varphi'(0)\alpha$$

$$\varphi'(\alpha) \geq \sigma \varphi'(0)$$

其中 $1 > \sigma > \rho > 0$.

强 Wolfe 准则

$$\varphi(\alpha) \leq \varphi(0) + \rho \varphi'(0)\alpha$$

$$|\varphi'(\alpha)| \leq -\sigma \varphi'(0)$$

当 $\sigma \rightarrow 0$ 时, 强 Wolfe 准则接近精确线搜索. 是当 $\sigma \leq \rho$ 时, 满足 Wolfe 准则的点可能不存在.

引理 2.1 (非精确线搜索的性质) 假设 $\varphi'(0) < 0$, 则

- (1) 当 α 充分小时, Armijo 成立; Goldstein(2) 和 Wolfe(2) 不成立.
- (2) 若 $\varphi(\alpha)$ 有下界, 则 α 充分大时, Goldstein(2) 成立; Armijo 不成立.

定理 2.3 (非精确线搜索步长的存在性) 假设 $\varphi'(0) < 0$ 且 $\varphi(\alpha)$ 有下界, 则存在 $\alpha > 0$ 满足 Goldstein 或强 Wolfe 准则.

由于 α 充分小时 Armijo 准则成立, 故可设 α_0 是使得 Armijo 准则成立的最大 α . 下面证明, 存在 $\alpha \in (0, \alpha_0]$ 使得 Goldstein(2) 或 Wolfe(2) 成立.

Goldstein 准则 若 $\forall \alpha \in (0, \alpha_0]$ 都有

$$\varphi(\alpha) < \varphi(0) + (1 - \rho)\varphi'(0)\alpha$$

取 $\alpha = \alpha_0$, 有

$$\varphi(\alpha_0) - \varphi(0) = \rho\varphi'(0)\alpha_0 < (1 - \rho)\varphi'(0)\alpha_0$$

这与 $\rho \in (0, \frac{1}{2})$ 矛盾!

强 Wolfe 准则 若 $\forall \alpha \in (0, \alpha_0]$ 都有

$$|\varphi'(\alpha)| > -\sigma\varphi'(0)$$

由 Armijo 准则和 Lagrange 中值定理, 存在 $\alpha \in (0, \alpha_0]$ 使得

$$\rho\varphi'(0)\alpha_0 = \varphi(\alpha_0) - \varphi(0) = \varphi'(\alpha)\alpha_0$$

故 $\varphi'(\alpha) = \rho\varphi'(0) \geq \sigma\varphi'(0)$. 矛盾!

定理 2.4 ($f(x)$ 下降量的下界估计) 设 $f(x)$ 连续可微, 且 $g(x)$ 满足 Lipschitz 条件

$$\|g(x) - g(y)\| \leq L\|x - y\| \quad (2.6)$$

若 $f(x_k + \alpha d_k)$ 在 $\alpha > 0$ 时有下界, 则对满足 Wolfe 准则的 α_k , 有

$$f(x_k) - f(x_k + \alpha_k d_k) \geq \frac{\rho(1 - \sigma)}{L} \|g_k\|^2 \cos^2 \theta_k \quad (2.7)$$

证明 令 $s_k = \alpha_k d_k$ 为下降步, 则只需证明:

$$f(x_k) - f(x_k + s_k) \geq \frac{\rho(1 - \sigma)}{L} \|g_k\|^2 \cos^2 \theta_k$$

由 Wolfe 准则有

$$s_k^T g(x_k + s_k) \geq \sigma s_k^T g_k$$

因此

$$(\sigma - 1)s_k^T g_k \leq s_k^T (g(x_k + s_k) - g_k) \leq L\|s_k\|^2$$

而夹角条件给出

$$(\sigma - 1)s_k^T g_k \geq (1 - \sigma)\|s_k\|\|g_k\| \cos \theta_k$$

因此

$$\|s_k\| \geq \frac{1-\sigma}{L} \|g_k\| \cos \theta_k$$

由 Armijo 准则,

$$f(x_k) - f(x_k + s_k) \geq -\rho g_k^T s_k \geq \rho \|g_k\| \|s_k\| \cos \theta_k \geq \frac{\rho(1-\sigma)}{L} \|g_k\|^2 \cos^2 \theta_k$$

定理 2.5 (非精确线搜索的收敛性: Wolfe) 设 $g(x)$ 在水平集 $L(x_0) := \{x : f(x) \leq f(x_0)\}$ 上满足 Lipschitz 条件, 且 d_k 与 $-g_k$ 的夹角 θ_k 满足

$$0 \leq \theta_k \leq \frac{\pi}{2} - \mu$$

则对于 Wolfe 准则, 或者对某个 k 有 $g_k = 0$, 或者 $f_k \rightarrow -\infty$, 或者 $g_k \rightarrow 0$.

[Proof: 袁亚湘 p105-106]

定理 2.6 (非精确线搜索的收敛性: Goldstein) 设 $g(x)$ 在水平集 $L(x_0) := \{x : f(x) \leq f(x_0)\}$ 一致连续, 且 d_k 与 $-g_k$ 的夹角 θ_k 满足

$$0 \leq \theta_k \leq \frac{\pi}{2} - \mu$$

则对于 Goldstein 准则, 或者对某个 k 有 $g_k = 0$, 或者 $f_k \rightarrow -\infty$, 或者 $g_k \rightarrow 0$.

[Proof: 袁亚湘 p103-104]

如果在某个无穷集 K 上有 $\|g_k\| \geq \varepsilon_1$, 则由夹角条件可以得到

$$-g_k^T s_k = \|g_k\| \|s_k\| \cos \theta_k \geq \varepsilon_1 \|s_k\|$$

由 Armijo 准则,

$$f_{k+1} \leq f_k + \rho g_k^T s_k$$

故单步下降量满足

$$f_k - f_{k+1} \geq -\rho g_k^T s_k \geq \rho \varepsilon_1 \|s_k\|, \quad \forall k \in K$$

由于 $\lim_{k \rightarrow \infty} (f_k - f_{k+1}) = 0$, 故

$$\lim_{k \in K} \|s_k\| = 0$$

即相邻迭代点的间距会在 $k \in K$ 时收敛到 0. 因此当 $k \in K$ 且 k 充分大时, 可以进行 Taylor 展开([进行更精细的估计](#))

$$f_{k+1} - f_k = s_k^T g(\xi_k) = s_k^T g_k + o(\|s_k\|)$$

由 Goldstein 准则,

$$f_{k+1} - f_k \geq (1 - \rho)g_k^T s_k$$

因此

$$\rho g_k^T s_k \geq o(\|s_k\|)$$

矛盾! 因此 Goldstein 线搜索准则在夹角条件下必定收敛.

关于证明的评注: 在上面的证明中, 一个关键的步骤是利用 Taylor 展开进行更精细的估计. 由于所有非精确线搜索方法都需要用到 $f(x)$ 的一阶导数信息, 因此进行 Taylor 展开是必要的.

3 Newton 型方法

3.1 基本 Newton 方法

基本 Newton 方法的下降方向 d_k^N 由方程

$$G_k d_k^N = -g_k \quad (3.1)$$

给出. 当迭代格式由

$$x_{k+1} = x_k + d_k^N \quad (3.2)$$

给出时, 相应的方法称为基本 Newton 方法. 关于基本 Newton 方法的评注:

- 基本 Newton 方法可以看作是在每个点 x_k 处用一个二次函数

$$m_k(p) = f_k + g_k^T p + p^T G_k p \quad (3.3)$$

来近似, 因此上述函数的极小点在 $p^* = -G_k^{-1} g_k$ 处取到. 因此下降方向取为

$$d_k^N = -G_k^{-1} g_k \quad (3.4)$$

- Newton 方法的一大优势是可以达到二阶收敛速度.

定理 3.1 (基本 Newton 方法的收敛性) 设 $f \in C^2$, 且 f 的 Hesse 矩阵满足 Lipschitz 条件. 若 x_0 充分接近 x^* , 且 G^* 正定, 则基本 Newton 方法具有 2 阶收敛速度.

直观上, 上述结果可以使用 Taylor 展开证明. 要证明 2 阶收敛, 只需证明

$$\|x_{k+1} - x^*\| \leq C \|x_k - x^*\|^2 \quad (3.5)$$

对某个常数 $C > 0$ 成立. 由于 $x_{k+1} = x_k + d_k^N$, 且 $d_k^N = -G_k^{-1}g_k$, 故

$$x_{k+1} - x^* = x_k - x^* - G_k^{-1}g_k \quad (3.6)$$

而

$$\begin{aligned} -g_k &= g(x^*) - g(x_k) \\ &= G_k(x^* - x_k) + O(\|x_k - x^*\|^2) \end{aligned}$$

故

$$-G_k^{-1}g_k = x^* - x_k + O(\|x_k - x^*\|^2) \quad (3.7)$$

故

$$\|x_{k+1} - x^*\| = O(\|x_k - x^*\|^2) \quad (3.8)$$

在实际中, 也可以把 Newton 方向与线搜索方法 (精确线搜索, Wolfe 准则) 结合起来使用. Newton 方法的优缺点:

1. 优点: 二次终止性, 二阶收敛速度
2. 缺点: 全局收敛性不好, 每步需要求解线性方程组

当 Hesse 矩阵 G 不是正定的情况下, Newton 方向 $d_k^N = -G_k^{-1}g_k$ 不一定是下降方向.

取定 $\eta > 0$ 是一个小常数, θ_k 为 d_k^N 与 $-g_k$ 的夹角, 我们可以使用下面的策略选择下降方向:

$$d_k = \begin{cases} d_k^N, & \cos \theta_k \geq \eta \\ -d_k^N, & \cos \theta_k \leq -\eta \\ -g_k, & \text{else} \end{cases}$$

当 d_k^N 不是下降方向时, 选取 $-d_k^N$ 下降即可. 基本 Newton 方法也可以收敛到鞍点.

定理 3.2 (基本 Newton 方法的鞍点收敛性) 考虑迭代格式 $x_{k+1} = x_k + \alpha_k d_k^N$, 其中 G_k 非奇异, $\alpha_k = \text{sgn}[g_k^T G_k^{-1} g_k]$. 假定

- (1) $\{x_k\}$ 收敛到 x^* ;
- (2) $g_k^T d_k \neq 0$

则 x^* 是 $f(x)$ 的稳定点, 且非局部极小点.

在上面的定理中, α_k 的取法是使得方向 $d_k = \alpha_k d_k^N$ 一定是下降方向, 即 $g_k^T d_k^N < 0$. 若 x^* 是局部极大点, 则在 x^* 恒有

$$y^T G(x) y < 0, \quad \forall x \in B(x^*), \quad y \neq 0$$

因此存在 $\eta > 0$, 使得

$$\lambda_{\max}(G(x)) \leq -\eta, \quad \forall x \in B(x^*)$$

因此

$$\begin{aligned} f(x_k - d_k^N) &\leq f(x_k) - g_k^T d_k^N + \frac{1}{2}(d_k^N)^T G_k d_k^N + o(\|d_k^N\|^2) \\ &= f_k + \frac{3}{2}(d_k^N)^T G_k d_k^N + o(\|d_k^N\|^2) \\ &\leq f_k - \frac{3}{2}\eta \|d_k^N\|^2 + o(\|d_k^N\|^2) \end{aligned}$$

因此当 k 充分大时, 应有 $f(x_{k+1}) \leq f(x_k)$, 因此其收敛点 x^* 不可能是局部极大点, 矛盾!

Newton 方法是可能使得迭代收敛到鞍点的.

3.2 修正 Newton 方法

在实际应用 Newton 方法时, Hesse 矩阵 G 可能不是正定的, 给实际应用带来了很大的困难. 我们可以将其做一定的修正, 使其成为正定的矩阵.

3.2.1 特征值修正方法

设 G 的所有特征值为 $\lambda_1, \dots, \lambda_n$, 特征向量为 u_1, \dots, u_n , 则 G 可以表示为

$$G = \sum_{i=1}^n \lambda_i u_i u_i^T \tag{3.9}$$

若取 $\beta_i = \min(|\lambda_i|, \delta)$, 则一个合理的对 G 进行修正的方式是

$$\bar{G} = \sum_{i=1}^n \beta_i u_i u_i^T \tag{3.10}$$

然而, 在实际计算中求解每步迭代矩阵 G 的特征值既困难也不稳定, 因此一般不会被采用.

3.2.2 修正 Cholesky 分解

在本节我们考虑对一般的对称矩阵 $G \in \mathbb{R}^{n \times n}$ 的修正 Cholesky 分解. 对于正定对称的情形, Cholesky 分解一般由下式给出:

$$G = LDL^T \tag{3.11}$$

但是当 G 不正定时, 上述算法可能数值不稳定, 因此我们考虑修正 Cholesky 分解

$$G + E = L^T D L$$

其中 L 为单位下三角矩阵, D 为正定对角矩阵, E 为对角修正矩阵. $L, D, E \in \mathbb{R}^{n \times n}$ 的计算由以下算法给出:

Algorithm 2: 修正 Cholesky 分解

输入: 对称矩阵 $G \in \mathbb{R}^{n \times n}$, 参数 $\delta, \beta > 0$

输出: $L, D \in \mathbb{R}^{n \times n}$

for $j = 1, \dots, n$ **do**

for $i = j + 1, \dots, n$ **do**

$| g_{ij} = g_{ij} - \sum_{s=1}^{j-1} d_s l_{is} l_{js}$

end

$\theta_j = \max_{j < i \leq n} |g_{ij}|$

$d_j = \max(|g_{jj}|, \theta_j^2 / \beta^2, \delta)$

for $i = j + 1, \dots, n$ **do**

$| l_{ij} = g_{ij} / d_j$

$| g_{ii} = g_{ii} - d_j l_{ij}^2$

end

end

上述算法的关键在于 d_{jj} 的选取保证 D 是对称正定的, 因此计算 $l_{ij} = g_{ij} / d_j$ 时不会发生数值不稳定性. 参数 β 应当选取满足

$$\beta^2 = \max\{\gamma, \xi / \sqrt{n^2 - 1}\}$$

其中 γ 是矩阵 $A \in \mathbb{R}^{n \times n}$ 的对角元的最大模, ξ 是 A 的非对角元的最大模. 将修正 Cholesky 分解应用于 Hessian 矩阵 G , 得到

$$G + E = LDL^T$$

于是下降方向由

$$d_k = -(LDL^T)^{-1} g_k = -L^{-T} D^{-1} L^{-1} g_k$$

给出. 为了避免算法收敛到鞍点, 引入如下的负曲率方法. 设对角矩阵 D, E 由

$$D = \text{diag}(d_1, \dots, d_n), \quad E = \text{diag}(e_1, \dots, e_n)$$

给出.

Algorithm 3: Gill-Murray 负曲率方向

输入: 修正 Cholesky 分解 $G + E = LDL^T$

输出: 负曲率方向 $d \in \mathbb{R}^n$

计算 $\psi_j = d_j - e_j, j = 1, \dots, n$

求下标 t 使得 $\psi_t = \min_{1 \leq j \leq n} \psi_j$

if $\psi_t < 0$ **then**

 令 1_t 是仅有第 t 个元素为 1 的单位向量

 令 d 为 $L^T d = 1_t$ 的解

 输出负曲率方向 $d \in \mathbb{R}^n$

else

 | 不输出结果

end

可以证明上述算法的输出一定是一个负曲率方向. 事实上, 容易计算

$$d^T G d + e_t = d^T L D L^T d = 1_t^T D 1_t = d_t$$

因此

$$d^T G d = d_t - e_t = \psi_t < 0$$

即 $d \in \mathbb{R}^n$ 是负曲率方向.

根据, 在 β 的选取方式下, 若 G 有负特征值, 则一定存在一个 t 是的 $\psi_t < 0$.

最后, 我们使用如下的稳定 Newton 算法来实现对 Hesse 矩阵 $G \in \mathbb{R}^{n \times n}$ 的修正:

Algorithm 4: Gill-Murray 稳定 Newton 方法

输入: 梯度 $g \in \mathbb{R}^n$, Hesse 矩阵 $G \in \mathbb{R}^{n \times n}$, 允许误差 $\varepsilon > 0$

输出: 下降方向 $d \in \mathbb{R}^n$

对 G 进行修正 Cholesky 分解 $G + E = LDL^T$

(用于判断使用 Newton 方向还是负曲率方向)

令 $c = true$

if $\|g_k\| \leq \varepsilon$ **then**

 求解 Gill-Murray 负曲率方向 d_k

 如果不输出结果, 令 $c = true$

 (输出负曲率方向)

 如果成功输出, 令 $c = false$. 令 $g^T d > 0$, 令 $d = -d$

end

if c **then**

 (输出 Newton 方向)

 求解下降方向 $LDL^T d = -g$ 得到下降方向 d .

end

3.3 非精确 Newton 算法

基本 Newton 算法要求在每一步求解方程

$$G_k d_k^N = -g_k \quad (3.12)$$

如果 G_k 的维数太大, 那么线性方程组的求解会变得困难. 在实际中我们可以对该方程进行近似求解. 如果近似的下降方向为 d_k , 那么 d_k 对 Newton 方向 d_k^N 的逼近程度可以用残量

$$r_k = G_k d_k + g_k \quad (3.13)$$

来刻画. 如果残量满足

$$\|r_k\| \leq \eta_k \|g_k\| \quad (3.14)$$

对某个小的常数 η_k 成立, 则收敛速度可以得到保证.

定理 3.3 (非精确 Newton 局部收敛) 设 G^* 正定, 且下降方向 d_k 满足残量

$$r_k = G_k d_k + g_k, \quad \|r_k\| \leq \eta_k \|g_k\|$$

且 $\eta_k \leq \eta$, $\eta \in (0, 1)$. 则对于迭代更新格式

$$x_{k+1} = x_k + d_k$$

若 x_0 充分接近 x^* , 则 x_k 线性收敛到 x^* .

我们从 $g(x)$ 的 Taylor 展开计算 g_{k+1} 的估计.

$$\begin{aligned} g_{k+1} - g_k &= G_k(x_{k+1} - x_k) + O(\|x_{k+1} - x_k\|^2) \\ &= G_k d_k + O(\|d_k\|^2) \\ &= r_k - g_k + O(\|d_k\|^2) \end{aligned}$$

因此

$$g_{k+1} = r_k + O(\|d_k\|^2) \quad (3.15)$$

由于

$$d_k = G_k^{-1}(r_k - g_k) \quad (3.16)$$

因此 $d_k = O(\|g_k\|)$. 因此我们得到

$$\|g_{k+1}\| \leq \eta \|g_k\| + o(\|g_k\|) \quad (3.17)$$

最后, 我们注意到从 g_k 的线性收敛速度可以得到 x_k 的收敛性. 由于

$$g_k - g^* = G^*(x_k - x^*) + O(\|g_k\|) \quad (3.18)$$

因此 $\|x_k - x^*\| = O(\|g_k\|)$. 故迭代序列 x_k 具有线性收敛速度. 由上面的定理证明也可以得到

定理 3.4 (非精确 Newton 超线性收敛) 若非精确 Newton 方法产生的迭代序列 x_k 收敛到 x^* , 并且 $\eta_k \rightarrow 0$, 则该方法具有超线性收敛速度, 即

$$\lim_{k \rightarrow \infty} \frac{\|g_{k+1}\|}{\|g_k\|} = 0 \quad (3.19)$$

事实上, 上述极限结果可以由不等式

$$\|g_{k+1}\| \leq \eta_k \|g_k\| + o(\|g_k\|) \quad (3.20)$$

直接得到.

3.4 全局非精确 Newton 方法

在全局非精确 Newton 方法中, 除了基本的判定准则 $\|r_k\| \leq \eta_k \|g_k\|$ 之外, 我们会加上一条额外的额外的准则.

定义 3.1 (全局非精确 Newton 方向) 给定常数 $t \in (0, 1)$ 并考虑迭代格式 $x_{k+1} = x_k + d_k$, 则 d_k 称为非精确 Newton 方向, 如果

$$\begin{cases} \|r_k\| \leq \eta_k \|g_k\| \\ \|g_{k+1}\| \leq (1 - t(1 - \eta_k)) \|g_k\| \end{cases} \quad (3.21)$$

容易看出, 满足上述条件的下降步 d_k 是存在的. 事实上, 当 k 充分大时, 有

$$\|g_{k+1}\| \leq \eta_k \|g_k\| + o(\|g_k\|) \quad (3.22)$$

因此 (3.21) 对一切 $t < 1$ 都存在解. 来使得

$$ared_k(d_k) \geq t \cdot pred_k(d_k) \quad (3.23)$$

定义 3.2 设当前迭代点为 x_k , 下降步为 $d \in \mathbb{R}^n$, 则实际下降量 (actual reduction) 定义为

$$ared_k(d) = \|g_k\| - \|g(x_k + d)\| \quad (3.24)$$

而预计下降量 (predicted reduction) 定义为

$$pred_k(d) = \|g_k\| - \|g_k + G_k d\| \quad (3.25)$$

当条件 (3.21) 满足, 即 d 是全局非精确 Newton 方向时,

$$pred_k(d) \geq (1 - \eta_k) \|g_k\| \quad (3.26)$$

$$ared_k(d) \geq t(1 - \eta_k) \|g_k\| \quad (3.27)$$

因此全局非精确 Newton 方法对实际和预计的下降量都提出了要求.

在非精确 Newton 方法中, 对参数 $\{\eta_k\}$ 的一些评注:

1. η_k 是刻画求解线性方程组 $G_k d_k = -g_k$ 的精度. η_k 越小, 线性方程组的求解误差就越小.
2. 如果 η_k 取得太小, 则不仅会增加求解线性方程组的复杂度, 还会降低数值解的有效性.
3. 增加一条对 d_k 的约束主要是为了保证 $ared_k(d)$ 有有效的下降.

我们考虑 2 种选择 η_k 的方式.

1. 选择

$$\eta_k = \frac{\|g_k - g_{k-1} - G_{k-1} d_{k-1}\|}{\|g_{k-1}\|} \quad (3.28)$$

或

$$\eta_k = \frac{\|g_k\| - \|g_{k-1} + G_{k-1} d_{k-1}\|}{\|g_{k-1}\|} \quad (3.29)$$

注意到有不等式

$$|\|a\| - \|b\|| \leq \|a - b\|$$

故第一种方式得到的 η_k 更大. η_k 描述了 $g_{k-1} + G_{k-1}d_{k-1}$ 对 g_k 的近似程度. 使用第一种方式可以得到很好的局部收敛性:

定理 3.5 若 x_0 充分接近 x^* , 且 $\{\eta_k\}$ 由上面的式子决定, 则 $x_k \rightarrow x^*$, 且

$$\|x_{k+1} - x^*\| \leq \beta \|x_k - x^*\| \|x_{k-1} - x^*\| \quad (3.30)$$

这一定理意味着 $\{x_k\}$ 具有超线性的收敛速度, 且收敛阶为

$$\frac{\sqrt{5} + 1}{2} \approx 1.618 > 1$$

2. 设 $\gamma \in [0, 1]$ 且 $\alpha \in (1, 2]$, 选择

$$\eta_k = \gamma \left(\frac{\|g_k\|}{\|g_{k-1}\|} \right)^\alpha, \quad k = 1, 2, \dots$$

它反映了 $\|g_k\|$ 的下降的速度.

在实际更新 $\{\eta_k\}$ 时, 我们也会对 η_k 添加一些安全保护机制, 以防止 η_k 的减小速度太快.

$$\eta_k = \max\{\eta_k, \eta_{k-1}^{\frac{\sqrt{5}+1}{2}}\}, \quad \eta_k = \max\{\eta_k, \gamma \eta_{k-1}^\alpha\}$$

Algorithm 5: Inexact Newton Backtracking Method

输入: $x_0, \eta_{\max} \in [0, 1], t \in (0, 1), 0 < \theta_{\min} < \theta_{\max} < 1$

输出: 迭代点序列 $\{x_k\}$

for $k = 1, 2, \dots$ **do**

选择初始 η_k , 并选择下降步 d_k 满足

$$\|g_k + G_k d_k\| \leq \eta_k \|g_k\|$$

while $\|g(x_k + d_k)\| > (1 - t(1 - \eta_k)) \|g_k\|$ **do**

选择 $\theta \in [\theta_{\min}, \theta_{\max}]$

令 $d_k = \theta_k d_k, \eta_k = 1 - \theta(1 - \eta_k)$

end

令 $x_{k+1} = x_k + d_k$

end

4 拟 Newton 算法

4.1 拟 Newton 算法简介

拟 Newton 算法的主要目标是将 Newton 方法的思想用于求解大规模的无约束优化问题. 修正 Newton 算法和拟 Newton 算法的区别在于:

- 修正 Newton 算法主要处理 Hesse 矩阵 $G \in \mathbb{R}^{n \times n}$ 不正定的情形, 它通过在 G 上加入额外的正数项以使得 G 正定, 从而在求解线性方程组时不会产生数值不稳定. 由于修正 Newton 算法本质上仍然需要求解线性方程组, 因此只适用于中小规模的优化问题. 通过合适的迭代格式可以到达超线性甚至二阶收敛.
- 拟 Newton 算法主要考虑将类似于 Newton 算法的思想应用于大规模的优化问题中, 本质上不需要利用二阶导数, 和基本 Newton 方法的步骤差别较大. 只能达到一阶收敛速度.

在拟 Newton 算法中, 我们希望用一个低秩或容易计算的矩阵近似 Hesse 矩阵 G_k . 例如, 可以用矩阵 B_k 对 G_k 进行近似, 或用 H_k 对 G_k^{-1} 进行近似, 即

$$G_k \approx B_k, \quad G_k^{-1} \approx B_k^{-1}$$

按照 Newton 算法的思想, 我们在每个迭代点 x_k 处用二次函数

$$m_k(p) = f_k + g_k^T p + \frac{1}{2} p^T B_k p \tag{4.1}$$

来近似目标函数, 则我们希望 $\nabla m_{k+1}(-s_k) = g_k$, 即上一步的梯度为 g_k . 它给出

$$g_{k+1} - B_{k+1}s_k = g_k \implies B_{k+1}s_k = y_k \tag{4.2}$$

其中 $s_k = x_{k+1} - x_k$, $y_{k+1} - y_k$.

定理 4.1 (割线方程) 在 x_{k+1} 处选择的拟 Newton 矩阵 $B_{k+1}(H_{k+1}) \in \mathbb{R}^{n \times n}$ 应当满足

$$B_{k+1}s_k = y_k \iff H_{k+1}y_k = s_k \tag{4.3}$$

其中 $s_k = x_{k+1} - x_k$, $y_{k+1} - y_k$.

割线方程是拟 Newton 算法应满足的最基本的准则. 具有代表性的拟 Newton 算法包括:

1. DFP 算法:

$$B_{k+1} = (I - \rho_k y_k s_k^T) B_k (I - \rho_k s_k y_k^T) + \rho_k y_k y_k^T$$

其中 $\rho_k = 1/y_k^T s_k$. 可以等价写为

$$H_{k+1} = H_k - \frac{H_k y_k y_k^T H_k}{y_k^T H_k y_k} + \frac{s_k s_k^T}{y_k^T s_k}$$

2. BFGS 算法:

$$H_{k+1} = (I - \rho_k s_k y_k^T) H_k (I - \rho_k y_k s_k^T) + \rho_k s_k s_k^T$$

可以等价写为

$$B_{k+1} = B_k - \frac{B_k s_k s_k^T B_k}{s_k^T B_k s_k} + \frac{y_k y_k^T}{y_k^T s_k}$$

DFP 算法可以由下面的最优化问题得到:

定理 4.2 (DFP 的推导) 给定对称矩阵 $B_0 \in \mathbb{R}^{n \times n}$ 和向量 $s, y \in \mathbb{R}^n$, 设对称正定矩阵 $W \in \mathbb{R}^{n \times n}$ 满足 $Wy = s$. 则约束优化问题

$$\begin{aligned} & \min_B \|B - B_0\|_W \\ & \text{s.t. } B = B^T, \quad Bs = y \end{aligned}$$

有唯一的最优解

$$B = (I - \rho y s^T) B_0 (I - \rho s y^T) + \rho y y^T$$

其中 $\rho = 1/y^T s$, 而 $\|\cdot\|_W$ 是加权的 Frobenius 范数:

$$\|A\|_W = \left\| W^{\frac{1}{2}} A W^{\frac{1}{2}} \right\|_F, \quad \forall A \in \mathbb{R}^{n \times n}$$

由于此问题为凸优化问题, 因此 B 是约束优化问题的局部极小点当且仅当 B 是 KKT 点. 容易计算问题的 Lagrange 函数为

$$L(B, \lambda, \Lambda) = \left\| W^{\frac{1}{2}} (B - B_0) W^{\frac{1}{2}} \right\|_F^2 - \lambda^T (Bs - y) - \text{Tr}[\Lambda, (B - B^T)]$$

因此

$$\frac{\partial L}{\partial B} = W(B - B_0)W - \lambda s^T - (\Lambda - \Lambda^T) = 0$$

即 KKT 条件转化为

$$W(B - B_0)W = \lambda s^T + (\Lambda - \Lambda^T)$$

因此

$$2W(B - B_0)W = \lambda s^T + s \lambda^T$$

代入 $\lambda = W\mu$, $s = Wy$, 得到

$$2(B - B_0) = \mu y^T + y \mu^T \tag{4.4}$$

下面我们通过 (4.4) 来得到 B 的表达式. 在 (4.4) 两边同乘 s, s^T , 得到

$$\mu = \rho(2I - \rho y s^T)(y - B_0 s) \tag{4.5}$$

故

$$\frac{1}{2}(\mu y^T + y\mu^T) = -\rho B_0 s y^T - \rho y s^T B_0 + \rho^2 y s^T B_0 s y^T + \rho y y^T \quad (4.6)$$

因此

$$B = B_0 + \frac{1}{2}(\mu y^T + y\mu^T) = (I - \rho y s^T)B_0(I - \rho s y^T) + \rho y y^T$$

原命题成立. 利用 Sherman-Morrison 公式可以得到对应的 H_k 的更新公式.

类似地, 可以得到 BFGS 公式的推导公式:

定理 4.3 (BFGS 的推导) 给定对称矩阵 $H_0 \in \mathbb{R}^{n \times n}$ 和向量 $s, y \in \mathbb{R}^n$, 设对称正定矩阵 $G \in \mathbb{R}^{n \times n}$ 满足 $Gs = y$. 则约束优化问题

$$\begin{aligned} & \min_H \|H - H_0\|_G \\ & \text{s.t. } H = H^T, \quad Hy = s \end{aligned}$$

有唯一的最优解

$$H = (I - \rho s y^T)H_0(I - \rho y s^T) + \rho s s^T$$

其中 $\rho = 1/y^T s$, 而 $\|\cdot\|_W$ 是加权的 Frobenius 范数:

$$\|A\|_G = \left\| G^{\frac{1}{2}} A G^{\frac{1}{2}} \right\|_F, \quad \forall A \in \mathbb{R}^{n \times n}$$

由 BFGS 方法得到的矩阵 H_{k+1} 可以保持正定性.

4.2 有限内存 BFGS 方法

有限内存 BFGS 方法 (L-BFGS) 主要依赖于下面的 H_k 的更新公式:

$$H_{k+1} = (I - \rho_k s_k y_k^T)H_k(I - \rho_k y_k s_k^T) + \rho_k s_k s_k^T \quad (4.7)$$

若定义 $V_k = I - \rho_k y_k s_k^T$, 则更新公式成为

$$H_{k+1} = V_k^T H_k V_k + \rho_k s_k s_k^T \quad (4.8)$$

有限内存 BFGS 方法的思想是仅使用前几步的信息估计第 k 步的矩阵 H_k . 简单来说, L-BFGS 可归结为如下问题:

定义 4.1 (L-BFGS) 给定 $H_0 \in \mathbb{R}^{n \times n}$, $g \in \mathbb{R}^n$, 向量 $\{s_0, s_1, \dots, s_{k-1}\}$ 和 $\{y_0, y_1, \dots, y_{k-1}\}$, $g \in \mathbb{R}^n$, 希望计算 $H_k g$.

即用前 k 步的向量 s_i, y_i 估计矩阵-向量乘积 $H_k g$. 实际中, 初始矩阵可以取为 $H_0 = \gamma_0 I$,

$$\gamma_0 = \frac{s_0^T y_0}{y_0^T y_0}$$

4.2.1 Two-Loop Recursion

定义 $\{q_i\}_{i=0}^k \subset \mathbb{R}^n$ 如下:

$$q_k = g, \quad q_i = (I - \rho_i y_i s_i^T) q_{i+1}, \quad i = k-1, \dots, 0$$

则由更新公式 (4.8) 可以得到

$$H_{i+1} q_{i+1} = V_i^T H_i V_i q_{i+1} + \rho_i s_i s_i^T q_{i+1} = V_i^T H_i q_i + \alpha_i s_i$$

其中我们定义 $\alpha_i = \rho_i s_i^T q_{i+1}$, $i = 0, 1, \dots, k-1$. 再定义 $\{z_i\}_{i=0}^k \subset \mathbb{R}^n$ 如下:

$$z_i = H_i q_i, \quad i = 0, 1, \dots, k$$

则

$$z_{i+1} = (I - \rho_i s_i y_i^T) z_i + \alpha_i s_i = z_i + s_i (\alpha_i - \beta_i)$$

其中我们定义 $\beta_i = \rho_i y_i^T z_i$. 因此我们可以用如下的算法计算 $H_k g$:

Algorithm 6: Two-loop recursion for $H_k g$

输入: $H_0 \in \mathbb{R}^n$, $g \in \mathbb{R}^n$, $s_0, \dots, s_{k-1}, y_0, \dots, y_{k-1} \in \mathbb{R}^n$

输出: $H_k g \in \mathbb{R}^n$

令 $q_k = g$

for $i = k-1, \dots, 0$ **do**

$$\left| \begin{array}{l} \alpha_i = \rho_i s_i^T q_{i+1} \\ q_i = q_{i+1} - \alpha_i y_i \end{array} \right.$$

end

$$z_0 = H_0 q_0$$

for $i = 0, 1, \dots, k-1$ **do**

$$\left| \begin{array}{l} \beta_i = \rho_i y_i^T z_i \\ z_{i+1} = z_i + s_i (\alpha_i - \beta_i) \end{array} \right.$$

end

$$\text{输出 } z_k = H_k g$$

4.2.2 Compact Representation

我们将导出 BFGS 更新公式的压缩表示. 定义矩阵

$$S_k = [s_0, \dots, s_{k-1}] \in \mathbb{R}^{n \times k}, \quad Y_k = [y_0, \dots, y_{k-1}] \in \mathbb{R}^{n \times k}$$

以及 $R_k \in \mathbb{R}^{k \times k}$ 满足

$$(R_k)_{i,j} = \begin{cases} s_{i-1}^T y_{j-1}, & i \leq j \\ 0, & \text{else} \end{cases}$$

则有如下引理成立:

引理 4.1 对于 $V_i = I - \rho_i y_i s_i^T$ ($i = 0, 1, \dots, k-1$), 有

$$V_0 V_1 \cdots V_{k-1} = I - Y_k R_k^{-1} S_k^T \quad (4.9)$$

该引理的证明可以直接由数学归纳法得到. 当 $k=1$ 时, 结论显然成立. 设结论对 k 成立, 则只需证明 $k+1$ 的情形, 即

$$(I - Y_k R_k^{-1} S_k^T) V_k = I - Y_{k+1} R_{k+1}^{-1} S_{k+1}^T \quad (4.10)$$

这等价于

$$Y_{k+1} R_{k+1}^{-1} S_{k+1}^T = Y_k R_k^{-1} S_k^T - \rho_k Y_k R_k^{-1} S_k^T y_k s_k^T + \rho_k y_k s_k^T \quad (4.11)$$

下面我们只需证明 (4.11). 注意到 R_{k+1} 具有分块矩阵的形式

$$R_{k+1} = \begin{bmatrix} R_k & S_k^T y_k \\ 0 & s_k^T y_k \end{bmatrix} \quad (4.12)$$

因此 R_{k+1}^{-1} 也是分块对角矩阵

$$R_{k+1}^{-1} = \begin{bmatrix} R_k^{-1} & -\rho_k R_k^{-1} s_k^T y_k \\ 0 & \rho_k \end{bmatrix} \quad (4.13)$$

故

$$\begin{aligned} Y_{k+1} R_{k+1}^{-1} S_{k+1}^T &= \begin{bmatrix} Y_k & y_k \end{bmatrix} \begin{bmatrix} R_k^{-1} & -\rho_k R_k^{-1} s_k^T y_k \\ 0 & \rho_k \end{bmatrix} \begin{bmatrix} S_k^T \\ s_k^T \end{bmatrix} \\ &= Y_k R_k^{-1} S_k^T - \rho_k Y_k R_k^{-1} S_k^T y_k s_k^T + \rho_k y_k s_k^T \end{aligned}$$

故 (4.11) 成立. 由数学归纳法, 命题得证.

定理 4.4 设 H_0 对称正定且 $\{s_i, y_i\}_{i=0}^{k-1}$ 满足 $s_i^T y_i > 0$, 则 BFGS 更新的第 k 步由下式给出:

$$H_k = H_0 + \begin{bmatrix} S_k & H_0 Y_k \end{bmatrix} \begin{bmatrix} R_k^{-T} (D_k + Y_k^T H_0 Y_k) R_k^{-1} & -R_k^{-T} \\ -R_k^{-1} & 0 \end{bmatrix} \begin{bmatrix} S_k^T \\ Y_k^T H_0 \end{bmatrix} \quad (4.14)$$

定理的证明参考文献. B_k 的更新也有相应的压缩表示:

定理 4.5 设 B_0 对称正定且 $\{s_i, y_i\}_{i=0}^{k-1}$ 满足 $s_i^T y_i > 0$, 则 BFGS 更新的第 k 步由下式给出:

$$B_k = B_0 - \begin{bmatrix} B_0 S_k & Y_k \end{bmatrix} \begin{bmatrix} S_k^T B_0 S_k & L_k \\ L_k^T & -D_k \end{bmatrix}^{-1} \begin{bmatrix} S_k^T B_0 \\ Y_k^T \end{bmatrix} \quad (4.15)$$

其中 $L_k \in \mathbb{R}^{k \times k}$ 由下式给出:

$$(L_k)_{i,j} = \begin{cases} s_{i-1}^T y_{j-1}, & i > j \\ 0, & \text{else} \end{cases}$$

5 信赖域方法

信赖域方法 (trust region) 主要用于求解无约束问题

$$\min_{x \in \mathbb{R}^n} f(x) \quad (5.1)$$

信赖域方法在迭代点 x_k 处用二次函数 $m_k(p)$ 对目标函数 $f(x_k + p)$ 进行近似. 根据 $f(x)$ 在 x_k 处的 Taylor 展开,

$$f(x_k + p) = f_k + g_k^T p + \frac{1}{2} p^T \nabla^2 f(x_k) p + o(\|p\|^2) \quad (5.2)$$

其中 $f_k = f(x_k)$, $g_k = \nabla f(x_k)$, $p \in \mathbb{R}^n$ 表示该步信赖域的下降步. 因此 $m_k(x)$ 可取为

$$m_k(p) = f_k + g_k^T p + \frac{1}{2} p^T G_k p \quad (5.3)$$

其中 $G_k \in \mathbb{R}^{n \times n}$ 是 Hesse 矩阵 $\nabla^2 f(x_k)$.

5.1 信赖域方法的基本框架

信赖域方法通过求解一系列信赖域子问题来解原优化问题. 在每个 x_k 处, 信赖域子问题形如

$$\min_{p \in \mathbb{R}^n} m_k(p) = f_k + g_k^T p + \frac{1}{2} p^T G_k p \quad (5.4)$$

$$\text{s.t. } \|p\| \leq \Delta_k \quad (5.5)$$

其中 $\Delta_k > 0$ 为信赖域半径, 它刻画了二次函数 $m_k(p)$ 对目标函数 $f(x_k + p)$ 的逼近有多精确. 我们用下面的**实际下降量** (actual reduction) 和**预测下降量** (predicted reduction) 的比值 ρ_k 来定量的刻画逼近的精确性:

$$\rho_k = \frac{f(x_k) - f(x_k + p)}{m_k(0) - m_k(p)} \quad (5.6)$$

我们可以利用 ρ_k 的大小来决定信赖域半径 Δ_k 的更新方式:

- 若 $\rho_k \approx 1$, 则上述逼近是精确的, 可以增大信赖域半径.
- 若 ρ_k 接近 0 或为负值, 则应该减少 Δ_k 的值.
- 若 $\rho_k < 0$, 则该步的结果应当被舍弃.

注意: 老师的讲稿上使用的符号是

$$g_k(d) = f_k + g_k^T d + \frac{1}{2} d^T G_k d$$

其中 $G_k \in \mathbb{R}^{n \times n}$ 是 Hesse 矩阵, $d \in \mathbb{R}^n$ 是下降步.

Algorithm 7: 信赖域方法

输入: 最大半径 $\hat{\Delta} > 0$, 初始半径 $\Delta_0 > 0$, $\eta \in [0, 1/4)$

输出: 迭代点序列 $\{x_k\}_{k \geq 0}$

for $k = 1, 2, \dots$ **do**

近似求解信赖域子问题 (5.5) 得到下降步 p_k ;

按照 (5.6) 计算下降量比值 ρ_k ;

if $\rho_k < \frac{1}{4}$ **then**

$\Delta_{k+1} = \frac{1}{4}\Delta_k$

else

if $\rho_k > \frac{3}{4}$ 且 $\|p_k\| = \Delta_k$ **then**

$\Delta_{k+1} = \min(2\Delta_k, \hat{\Delta})$

else

$\Delta_{k+1} = \Delta_k$

end

end

if $\rho_k > 0$ **then**

$x_{k+1} = x_k + p_k$

else

$x_{k+1} = x_k$

end

end

关于此算法的一些评注:

- 在上述算法中, 信赖域半径 Δ_k 增加当且仅当 p_k 达到了边界 $B(0, \Delta_k)$.
- 信赖域算法可以保证每一步目标函数值至少是下降的. 如果目标函数上升, 即 $\rho_k \leq 0$, 则该步会被直接拒绝掉.
- 算法对常数 $\frac{1}{4}, \frac{3}{4}$ 不敏感.

5.2 Cauchy 点及性质

去掉子问题中的下标 k 得到子问题

$$\min_{p \in \mathbb{R}^n} m(p) = p + g^T p + \frac{1}{2} p^T G p, \quad \text{s.t. } \|p\| \leq \Delta \quad (5.7)$$

一种简单的下降步 p 的取法是, 在负梯度方向 g 极小化 $m(p)$, 所得的结果即为 Cauchy 点 p^C .

定义 5.1 (Cauchy 点) 对于信赖域子问题 (5.7), Cauchy 点定义为

$$p^C \equiv -\tau \frac{\Delta}{\|g\|} g \quad (5.8)$$

其中 τ 的取法是

$$\tau = \begin{cases} 1, & \text{如果 } g^T G g \leq 0 \\ \min\left(\frac{\|g\|^3}{\Delta g^T G g}, 1\right), & \text{其它} \end{cases}$$

Cauchy 点是信赖域子问题在一维子空间 (负梯度方向) 上的最优解. 使用 Cauchy 点可以为 $m(p)$ 带来一定的下降量:

引理 5.1 (Cauchy 点的下降量) Cauchy 点 p^C 满足

$$m(0) - m(p^C) \geq \frac{1}{2} \|g\| \min\left(\Delta, \frac{\|g\|}{\|G\|}\right) \quad (5.9)$$

该引理的证明可参见 Nocedal 的 Lemma 4.3. 在实际设计线搜索方法时, 我们希望方法达到的下降量应当至少不比 Cauchy 点少.

5.3 信赖域方法的收敛性

信赖域方法的一大好处从它可以得到好的全局收敛性, 而这种收敛性主要

定理 5.1 (信赖域方法的全局收敛性) 设 $\Omega \subset \mathbb{R}^n$ 是有界集, 且 $x_k \in \Omega, \forall k \in B$. 若 $f \in C^2$ 且在迭代过程中 $\|G_k\| \leq M$, 则信赖域算法产生一个满足一阶和二阶必要条件的聚点 x^∞ .

关于此定理的评注:

- 此定理首先要求算法是稳定的: 即迭代点稳定在一个有界的区间当中.
- 对于无约束问题, 一阶必要条件意味着 $g(x^*) = 0$, 二阶必要条件意味着 $G(x^*)$ 半正定.

分 2 种情形讨论: $\inf_k \Delta_k = 0$ 或 $\inf_k \Delta_k > 0$.

- 在第一种情形中, 可以取一个子列 $\{k_i\}$, 使得存在无穷 i , 满足

$$\Delta_{k_i+1} = \frac{1}{4}\Delta_{k_i}, \quad \Delta_{k_i+1} < \frac{1}{2}\Delta_{k_{i-1}+1}$$

因此存在一个子序列 $K \subset \mathbb{N}$, 使得

$$\rho_k < \frac{1}{4}, \quad \Delta_{k+1} \rightarrow 0, \quad k \in K \quad (5.10)$$

由于 $\Delta_{k+1} = \frac{1}{4}\Delta_k$, 故 $\Delta_k \rightarrow 0$. 由于每一步的下降步 p_k 满足 $\|p_k\| \leq \Delta_k$, 故

$$\|p_k\| \rightarrow 0, \quad k \in K \quad (5.11)$$

取 x^∞ 为序列 $\{x_k\}_{k \in K}$ 的聚点. 我们来证明 $g^\infty = 0$ 以及 G^∞ 半正定.

反设 $g^\infty \neq 0$. 由于每一步的下降量至少为 Cauchy 点的下降量, 故当 $k \in K$ 时,

$$m_k(0) - m_k(p_k) \geq \frac{1}{2}\|g_k\| \min\left(\Delta_k, \frac{\|g_k\|}{M}\right) \quad (5.12)$$

当 k 充分大时, $g_k \rightarrow g^\infty$, 而 $\Delta_k \rightarrow 0$, 故

$$m_k(0) - m_k(p_k) \geq \frac{1}{2}\|g_k\|\Delta_k \quad (5.13)$$

从而

$$\frac{\|p_k\|^2}{m_k(0) - m_k(p_k)} \leq \frac{2\|p_k\|^2}{\Delta_k\|g_k\|} \leq \frac{2\|p_k\|}{\|g_k\|} \quad (5.14)$$

当 k 充分大时, $g_k \rightarrow g^\infty$, $p_k \rightarrow 0$, 因此

$$\frac{\|p_k\|^2}{m_k(0) - m_k(p_k)} \rightarrow 0, \quad k \in K \quad (5.15)$$

但实际下降量满足

$$f(x_k + p_k) - f(x_k) = m_k(0) - m_k(p_k) + o(\|p_k\|^2)$$

故下降量的比

$$r_k = \frac{f(x_k + p_k) - f(x_k)}{m_k(0) - m_k(p_k)} = 1 + o(1), \quad k \in K$$

故 $r_k \rightarrow 1$, 这与 $\Delta_{k+1} = \frac{1}{4}\Delta_k$ 矛盾! 因此必有 $g^\infty = 0$.

再证明 G^∞ 是半正定的. 若否, 则设 G^∞ 的最小负特征值为 λ . 在第 k 步迭代时, 令 v_k 是 G^∞ 的最小负特征向量, 且适当选择 v 的方向来保证

$$v^T g_k \leq 0 \quad (5.16)$$

于是

$$m_k(0) - m_k(p_k) \geq m_k(0) - m_k(\Delta_k v_k) \geq -\frac{1}{2} \Delta_k^2 v_k^\top G_k v_k = \frac{1}{2} \Delta_k^2 (-\lambda + o(1)) \quad (5.17)$$

再次利用

$$f(x_k + p_k) - f(x_k) = m_k(0) - m_k(p_k) + o(\|p_k\|^2)$$

可以得到

$$r_k = \frac{f(x_k + p_k) - f(x_k)}{m_k(0) - m_k(p_k)} = 1 + o(1), \quad k \in K$$

矛盾! 因此 G^∞ 是半正定的.

- 在第二种情形中, 可以取一个子列 K 使得

$$\rho_k \geq 0.25, \quad h_k \geq \bar{h} > 0, \quad \forall k \in K$$

恒成立. 由于

$$f(x_1) - f(x^\infty) = \sum_{k=1}^{\infty} (f(x_k) - f(x_{k+1})) < \infty$$

故 $\lim_{k \rightarrow \infty} f(x_k) - f(x_{k+1}) = 0$. 由于当 $k \in K$ 时,

$$\rho_k = \frac{f(x_k) - f(x_k + p_k)}{m_k(0) - m_k(p_k)} \geq \frac{1}{4}$$

故

$$m_k(0) - m_k(p_k) \leq 4(f(x_k) - f(x_k + p_k)) \rightarrow 0, \quad k \in K$$

令在 x^∞ 处的极限二次函数为

$$m^\infty(p) = f^\infty + p^\top g^\infty + \frac{1}{2} p^\top G^\infty p$$

且 \bar{p} 为 $m^\infty(p)$ 的极小点, 则

$$m_k(\bar{p}) \geq m_k(p_k) \geq m_k(0) + o(1) = f(x_k) + o(1)$$

在上式中取 $k \rightarrow \infty$, 有

$$m^\infty(\bar{p}) \geq f(x^\infty) = f^\infty$$

这意味着二次函数 $m^\infty(p)$ 在 $B(0, \bar{h})$ 上的最小值就是 f^∞ . 这必然意味着 $g^\infty = 0$ 以及 G^∞ 半正定.

注: 从定理的证明可以看出, 对任何一个满足条件的聚点 x^∞ , 它都满足一阶和二阶必要条件.

定理 5.2 (信赖域方法的二阶收敛性) 若上述定理的聚点 x^∞ 满足 f 的 Hesse 矩阵 G^∞ 正定, 则对原序列 $\{x_k\}$ 有 $\rho \rightarrow 1$, $x_k \rightarrow x^\infty$, $glb(x_k) > 0$, 以及对充分大的 k , 有 $\|p_k\| \leq \Delta_k$. 此外, 收敛速度是二阶的.

上面的定理实际上说明了当二阶充分条件满足时, 收敛点 x^∞ 是唯一存在的.

5.4 Levenberg-Marquardt 方法

在介绍信赖域子问题求解的数值方法前, 我们先介绍一些理论结果. 考虑信赖域子问题 (5.7)

$$\min_{p \in \mathbb{R}^n} m(p) = f + g^T p + \frac{1}{2} p^T G p, \quad \text{s.t. } \|p\| \leq \Delta$$

关于信赖域子问题 (5.7) 的最优解, 有如下定理成立:

定理 5.3 (子问题的最优解) 向量 $p^* \in \mathbb{R}^n$ 是子问题 (5.7) 的最优解当且仅当 p^* 为可行点, 且存在 $\lambda \geq 0$, 使得

$$\begin{aligned} (G + \lambda I)p^* &= -g \\ \lambda(\Delta - \|p^*\|) &= 0 \\ (G + \lambda I) &\text{ 半正定} \end{aligned} \tag{5.18}$$

我们可以使用利用 KKT 条件对此定理进行证明. 对给定的 $\lambda \in \mathbb{R}$, 定义 Lagrange 函数

$$L(p) = f + g^T p + \frac{1}{2} p^T (G + \lambda I) p = m(p) + \frac{\lambda}{2} \|p\|^2$$

则 $L(p)$ 是关于 p 的二次函数.

- 充分性: 若条件 (5.18) 成立, 则 p^* 是 $L(p)$ 在 \mathbb{R}^n 上的极小点, 因此对任何 $p \in \mathbb{R}^n$, 有

$$L(p) \geq L(p^*) \implies m(p) + \frac{\lambda}{2} \|p\|^2 \geq m(p^*) + \frac{\lambda}{2} \|p^*\|^2$$

因此

$$m(p) \geq m(p^*) + \frac{\lambda}{2} (\|p^*\|^2 - \|p\|^2)$$

下面分 2 种情形讨论.

- 若 $\lambda = 0$, 则上式直接给出

$$m(p) \geq m(p^*), \quad \forall \|p\| \leq \Delta$$

- 若 $\lambda > 0$, 则 $\|p^*\| = \Delta$, 因此当 $\|p\| \leq \Delta$ 时,

$$m(p) \geq m(p^*) + \frac{\lambda}{2} (\|p^*\|^2 - \|p\|^2) \geq m(p^*), \quad \forall \|p\| \leq \Delta$$

在以上情形中, 均有 $m(p) \geq m(p^*)$ 对 $\|p\| \leq \Delta$ 恒成立. 因此 (5.18) 给出的 p^* 是子问题的最优解.

- 必要性: 若 p^* 是最优解, 则对任何 $\|p\| \leq \Delta$, 有 $m(p) \geq m(p^*)$. 考虑约束函数

$$c(p) = \frac{1}{2}(\Delta^2 - \|p\|^2)$$

由于约束规范条件满足, 故 p^* 也是 KKT 点, 故存在 $\lambda \geq 0$ 使得

$$\nabla m(p^*) = \lambda \nabla c(p^*) \Rightarrow (G + \lambda I)p^* = -g$$

即 $\nabla L(p^*) = 0$. 而互补性条件给出 $\lambda(\Delta - \|p^*\|) = 0$. 最后我们只需证明 $G + \lambda I$ 半正定. 事实上, 对于 Lagrange 函数 $L(p)$, 在 p^* 进行 Taylor 展开有

$$L(p) = L(p^*) + \frac{1}{2}(p - p^*)^T(G + \lambda I)(p - p^*)$$

即

$$m(p) = m(p^*) + \frac{\lambda}{2}(\|p^*\|^2 - \|p\|^2) + \frac{1}{2}(p - p^*)^T(G + \lambda I)(p - p^*)$$

根据 $m(p) \geq m(p^*)$, 有

$$\frac{\lambda}{2}(\|p^*\|^2 - \|p\|^2) + \frac{1}{2}(p - p^*)^T(G + \lambda I)(p - p^*) \geq 0, \quad \forall \|p\| \leq \Delta$$

下面分 2 种情形分析:

- 若 $\lambda = 0$, 则 $(p - p^*)^T G(p - p^*) \geq 0$, 因此在一个半空间上 $v^T G v \geq 0$, 故 G 半正定.
- 若 $\lambda \neq 0$, 则 $\|p^*\| = \Delta$, 则我们取 $\|p\| = \Delta$, 可以得到

$$\frac{1}{2}(p - p^*)^T(G + \lambda I)(p - p^*) \geq 0, \quad \forall \|p\| = \Delta$$

因此 $v^T(G + \lambda I)v \geq 0$ 在一个半空间上成立.

因此 $G + \lambda I$ 半正定.

关于上述定理的评注:

- 上述定理证明的关键是构造 Lagrange 函数 $L(p)$ 并讨论极小点处的性质. 由于 $L(p)$ 是二次函数, 故其 Taylor 展开式可以直接写出.
- 该定理的内容不完全等于 KKT 条件.

- 方程组

$$\begin{cases} (B + \lambda I)p = -g \\ \|p\| = \Delta \end{cases}$$

中有 $p \in \mathbb{R}^n$ 和 $\lambda \in \mathbb{R}$ 共 $n+1$ 个未知数和 $n+1$ 方程, 因此理论上可以显式求解.

从上述定理可以得到

推论 5.1 若 G 正定且 $\|G^{-1}g\| \leq \Delta$, 则极小点一定在 $p^* = -G^{-1}g$ 处取到. 否则, $m(p)$ 的最小值一定可以在 $\|p^*\| = \Delta$ 时取到.

下面给出基于上述定理的 Levenberg-Marquardt 方法:

Algorithm 8: Levenberg-Marquardt 方法

输入: 当前迭代点 x_k 和常数 λ_k

输出: 下步迭代点 x_{k+1} 和常数 λ_{k+1}

1. 分解 $G_k + \lambda_k I$ 并判断其是否正定. 若否, 令 $\lambda_k = 4\lambda_k$ 并重复此步.
2. 求解 LM 方程 $(G_k + \lambda_k I)p_k = -g_k$ 得到下降步 p_k
3. 计算下降量的比值

$$\rho_k = \frac{f(x_k) - f(x_k + p_k)}{m_k(0) - m_k(p_k)}$$

并利用 ρ_k 的大小决定 λ_k 的更新步骤:

- 若 $\rho_k < 0.25$, $\lambda_{k+1} = 4\lambda_k$
- 若 $\rho_k > 0.75$, $\lambda_{k+1} = \lambda_k/2$
- 其它情形: $\lambda_{k+1} = \lambda_k$

利用 ρ_k 的正负性决定 x_k 的更新步骤:

- 若 $\rho_k \leq 0$, $x_{k+1} = x_k$
 - 其它情形: $x_{k+1} = x_k + p_k$
-

最后, 我们说明

$$\|p(\lambda)\| = \|(G + \lambda I)^{-1}p\|$$

是一个关于 λ 的递减函数.

定理 5.4 设 λ_1 是 $G \in \mathbb{R}^{n \times n}$ 的最小特征值, 则当 $\lambda > -\lambda_1$ 时, $\|p(\lambda)\|$ 关于 λ 单调递减.

由于

$$(G + \lambda I)p(\lambda) = -g$$

故对 λ 求导可得

$$p(\lambda) + (G + \lambda I)p'(\lambda) = 0$$

因此

$$p'(\lambda) = -(G + \lambda I)^{-1}p(\lambda)$$

故

$$\frac{d}{d\lambda}\|p(\lambda)\| = \frac{p(\lambda)}{\|p(\lambda)\|} \cdot p'(\lambda) = -\frac{1}{\|p\|}p^T(G + \lambda I)^{-1}p$$

当 $\lambda > -\lambda_1$ 时, $G + \lambda I$ 正定, 故由 $p \neq 0$, 可得

$$\frac{d}{d\lambda}\|p(\lambda)\| < 0$$

因此 $\|p(\lambda)\|$ 在 $\lambda > -\lambda_1$ 时单调递减.

5.5 信赖域子问题的最优解分析

为简便起见, 假设对称矩阵 $G \in \mathbb{R}^{n \times n}$ 的正交对角化的形式为 $G = Q\Lambda Q^T$, 其中

$$\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$$

为 G 的所有特征值, 且 $\lambda_1 \leq \dots \leq \lambda_n$, 而

$$Q = [q_1, \dots, q_n] \in \mathbb{R}^{n \times n}$$

为正交阵, 且 q_1, \dots, q_n 为 G 的全部特征向量.

下面我们根据 $G \in \mathbb{R}^{n \times n}$ 的正定性对最优解 p^* 的性质做进一步的分析.

- 若 $G \in \mathbb{R}^{n \times n}$ 是正定的, 则对任何 $\lambda \geq 0$, 方程 $(G + \lambda I)p = -g$ 总存在解

$$p(\lambda) = -(G + \lambda I)^{-1}g$$

且 $\|p(\lambda)\|$ 在 $[0, +\infty)$ 严格单调下降. 当 $\lambda = 0$ 时, $p(0)$ 恰好为 Newton 下降步

$$p^N = -G^{-1}g$$

因此, 信赖域子问题 (5.7) 的最优解必然满足以下情形之一:

- $\|p^N\| \leq \Delta$, 最优解为 $p^* = p^N$;
- $\|p^N\| > \Delta$, 最优解由 $p^* = p(\lambda) = -(G + \lambda I)^{-1}g$, 其中 $\lambda > 0$ 使得 $\|p(\lambda)\| = \Delta$.

2. 若 $G \in \mathbb{R}^{n \times n}$ 不是正定的, 则信赖域子问题的最优解一定可以在边界上取到, 即 $\|p^*\| = \Delta$. 由于 λ 应使得 $G + \lambda I$ 半正定, 故 $\lambda \geq -\lambda_1$. 下面讨论方程 $(G + \lambda I)p = -g$ 的解的性质. 设 $I = \{i = 1, \dots, n : \lambda_i = \lambda_1\}$ 为最小特征值 λ_1 的指标集.

- 若 $q_j^T g$ 对 $j \in I$ 不全为 0, 则方程的解可表示为

$$p(\lambda) = -(G + \lambda I)^{-1}g = -\sum_{j=1}^n \frac{q_j^T g}{\lambda_j + \lambda} q_j$$

$\|p(\lambda)\|$ 在 $\lambda \rightarrow -\lambda_1$ 时取值为 $+\infty$, 即

$$p_{LS} = \sum_{j=1}^n \frac{q_j^T g}{\lambda_j - \lambda_1} q_j$$

满足 $\|p_{LS}\| = +\infty$. 由于 $\|p(\lambda)\|$ 在 $(-\lambda_1, +\infty)$ 上单调递减趋于 0, 存在唯一的 $\lambda \in (-\lambda_1, +\infty)$ 使得 $\|p(\lambda)\| = \Delta$.

- 若 $q_j^T g = 0, j \in I$ 全为 0, 则方程

$$(G - \lambda_1 I)p = -g$$

有解, 且

$$p_{LS} = -\sum_{j \notin I} \frac{q_j^T g}{\lambda_j - \lambda_1} q_j$$

是所有可能的解当中范数最小的, 即最小二乘解. 分 2 种情形讨论:

- 若 $\lambda > -\lambda_1$, 则 $G + \lambda I$ 正定, 且方程的解为

$$p(\lambda) = -\sum_{j \notin I} \frac{q_j^T g}{\lambda_j + \lambda} q_j$$

显然, 当 $\lambda \rightarrow -\lambda_1$ 时, $p(\lambda) \rightarrow p_{LS}$, 因此

$$\|p(\lambda)\| \in (0, \|p_{LS}\|)$$

- 若 $\lambda = -\lambda_1$, 则 $G - \lambda_1 I$ 半正定, 且方程的解为

$$p(\tau) = -\sum_{j \notin I} \frac{q_j^T g}{\lambda_j - \lambda_1} q_j + \sum_{j \in I} \tau_j q_j = p_{LS} + \sum_{j \in I} \tau_j q_j$$

其中 $\tau_j, j \in I$ 可以是任意常数. 这实际上就是[信赖域子问题求解](#)中的hard case.

注意到 q_j 是单位正交的, 故

$$\|p(\tau)\|^2 = \|p_{LS}\|^2 + \sum_{j \in I} \tau_j^2 \geq \|p_{LS}\|^2$$

因此 $\|p_{LS}\|$ 的取值范围是

$$\|p(\tau)\| \in [\|p_{LS}\|, +\infty)$$

因此, 我们可以通过判断 $\|p_{LS}\|$ 的值和 Δ 的关系来判断最优解是否属于 hard case.

hard case 的本质特征是: 当信赖域子问题的解

$$p(\lambda) = (G + \lambda I)^{-1}g$$

无法到达边界 $\|p(\lambda)\| = \Delta$ 时, 信赖域方法会因为每次的迭代量太小而变得低效. 解决 hard case 的方法就是在原本的 $p(\lambda)$ 上加上额外的负曲率方向.

根据以上对子问题最优解的分析, 容易得到求解信赖域子问题的通用算法:

Algorithm 9: 信赖域子问题的求解算法

输入: $g \in \mathbb{R}^n$, $G \in \mathbb{R}^{n \times n}$, $\Delta > 0$
输出: 信赖域子问题的最优解 $p^* \in \mathbb{R}^n$
令 (λ_1, q) 为对称阵 $G \in \mathbb{R}^{n \times n}$ 的最小特征对, 其中 λ_1 为最小特征值, $\|q\| = 1$
 $a = \max(0, -\lambda_1)$ (λ 的取值下界)
if $\lambda_1 > 0$ **then**
 (G 对称正定)
 $p^N = -G^{-1}g$ (Newton 下降方向)
 if $\|p^N\| \leq \Delta$ **then**
 $p^* = p^N$ (无约束最小点)
 return
 end
else if $q^T g = 0$ **then**
 $p_{LS} = -(G - \lambda_1 I)^{-1}g$ 为最小二乘解
 if $\|p_{LS}\|^2 \leq \Delta$ **then**
 ($hard\ case$)
 $\tau = \sqrt{\Delta^2 - \|p_{LS}\|^2}$
 $p^* = p_{LS} + \tau q$
 return
 end
end
(normal cases)
 $b = \|g\|/\Delta + a$ (λ 的取值上界)
在区间 $[a, b]$ 上求方程 $\|p(\lambda)\| = \Delta$ 的解, 输出解 $p^* = p(\lambda)$

上述算法对可能出现的各种情形都进行了处理, 最终信赖域子问题的求解化归为在一个有限区间 $[a, b]$ 上求解非线性方程 $\|p(\lambda)\| = \Delta$.

5.6 数值求解信赖域子问题的算法

基于以上对 hard case 的一些讨论, 我们介绍一些求解信赖域子问题 (5.7) 的数值算法. 注意 LM 方法仅包含对常数 λ_k 的简单修正, 因此没有对 hard case 进行额外的处理.

5.6.1 Hebden 方法

我们讨论非线性函数

$$\varphi(\lambda) = \|p(\lambda)\| - \Delta \quad (5.19)$$

在 $[a, b]$ 上的根 λ 的求解算法, 其中 $p(\lambda) = -(G + \lambda I)^{-1}g$. Hebden 方法的基本思想是用一个有理函数

$$\bar{\varphi}(\lambda) = \frac{\beta}{\alpha + \lambda} - \Delta \quad (5.20)$$

逼近 $\varphi(\lambda)$, 其中 $\alpha, \beta \in \mathbb{R}$. 给定 $\lambda \in \mathbb{R}$, 若取 $\alpha, \beta \in \mathbb{R}$ 使得 $\varphi(\lambda) = \bar{\varphi}(\lambda)$ 且 $\varphi'(\lambda) = \bar{\varphi}'(\lambda)$, 则

$$\alpha = -\lambda - \frac{\varphi(\lambda) + \Delta}{\varphi'(\lambda)}, \quad \beta = (\varphi(\lambda) + \Delta)(\lambda + \alpha) \quad (5.21)$$

则由 $\bar{\varphi}(\lambda) = 0$ 可以得到

$$\lambda = \lambda - \frac{\varphi(\lambda) + \Delta}{\Delta} \frac{\varphi(\lambda)}{\varphi'(\lambda)} \quad (5.22)$$

显然, 此方程的不动点为 $\varphi(\lambda) = 0$ 的解, 因此我们得到 $\lambda^{(l)}$ 的迭代计算公式:

$$\lambda^{(l+1)} = \lambda^{(l)} - \frac{\varphi(\lambda^{(l)}) + \Delta}{\Delta} \frac{\varphi(\lambda^{(l)})}{\varphi'(\lambda^{(l)})} \quad (5.23)$$

相应的数值算法为

Algorithm 10: Hebden 迭代: 在 $[a, b]$ 上求解 $\|p(\lambda)\| = \Delta$

输入: $g \in \mathbb{R}^n$, $G \in \mathbb{R}^{n \times n}$, $\Delta > 0$, 区间 $[a, b]$

输出: $\|p(\lambda)\| = \Delta$ 的解

$\lambda^{(0)} = -1$, $\lambda^{(1)} = \lambda$;

for $l = 1, 2, \dots$ **do**

$p_l = -(G + \lambda^{(l)} I)^{-1}g$

$\varphi(\lambda^{(l)}) = \|p_l\| - \Delta$

$\varphi'(\lambda^{(l)}) = -\frac{1}{\|p_l\|} p_l^T (G + \lambda^{(l)} I)^{-1} p_l$

计算下一步迭代点

$\lambda^{(l+1)} = \lambda^{(l)} - \frac{\varphi(\lambda^{(l)}) + \Delta}{\Delta} \frac{\varphi(\lambda^{(l)})}{\varphi'(\lambda^{(l)})}$

令 $\lambda^{(l)} = \max(\lambda^{(l)}, 1.01a)$;

end

输出 $p(\lambda) = p^{(l)}$.

5.6.2 More-Sorensen 方法

与 Hebden 方法不同, More-Sorensen 方法考虑用 Newton 迭代算法求解非线性方程

$$\varphi(\lambda) = \frac{1}{\|p(\lambda)\|} - \frac{1}{\Delta} \quad (5.24)$$

的解, 因为 $\varphi(\lambda)$ 在 $\lambda = -\lambda_1$ 处连续, 所以 $\varphi(\lambda)$ 具有良好的正则性. Newton 迭代格式为

$$\lambda^{(l+1)} = \lambda^{(l)} - \frac{\varphi(\lambda^{(l)})}{\varphi'(\lambda^{(l)})} \quad (5.25)$$

容易计算

$$\varphi(\lambda) = \frac{\Delta - \|p\|}{\Delta \|p\|}, \quad \varphi'(\lambda) = \frac{1}{\|p\|^3} p^T (G + \lambda I)^{-1} p$$

故

$$\frac{\varphi(\lambda)}{\varphi'(\lambda)} = \frac{\Delta - \|p\|}{\Delta} \cdot \frac{\|p\|^2}{p^T (G + \lambda I)^{-1} p} \quad (5.26)$$

因此相应的数值算法为

Algorithm 11: More-Sorensen 迭代

输入: $g \in \mathbb{R}^n$, $B \in \mathbb{R}^{n \times n}$, $\Delta > 0$, $a \geq 0$, 满足 $\|p(\lambda)\| \leq \Delta$ 的初始点

输出: $\|p(\lambda)\| = \Delta$ 的解

$\lambda^{(0)} = -1$, $\lambda^{(1)} = \lambda$;

for $l = 1, 2, \dots$ **do**

如果 $|\lambda^{(l)} - \lambda^{(l-1)}| < 10^{-6}$, 跳出循环;

做 Cholesky 分解 $G + \lambda^{(l)} I = R^T R$;

求解 $R^T R p_l = -g$, $R^T q_l = p_l$, 然后计算下一步迭代点

$$\lambda^{(l+1)} = \lambda^{(l)} + \left(\frac{\|p_l\|^2}{\|q_l\|^2} \right) \left(\frac{\|p_l\| - \Delta}{\Delta} \right)$$

令 $\lambda^{(l)} = \max(\lambda^{(l)}, 1.01a)$;

end

输出 $p(\lambda) = p^{(l)}$.

在上述方法中可以证明

$$\|q_l\|^2 = p_l^T (G + \lambda^{(l)})^{-1} p_l$$

5.6.3 Dogleg 方法

Dogleg 方法是对 Cauchy 点的一个简单改进, 它只能应用于 Hesse 矩阵 $G \in \mathbb{R}^{n \times n}$ 对称正定的情形. 设

$$p^U = -\frac{g^T g}{g^T G g} g$$

是负梯度方向上的无约束最小点, 而

$$p^N = -G^{-1} g$$

是 Newton 方法给出的最小点, 则 Dogleg 方法在一条折线

$$\tilde{p}(\tau) = \begin{cases} \tau p^U, & 0 \leq \tau \leq 1 \\ p^U + (\tau - 1)(p^N - p^U), & 1 \leq \tau \leq 2 \end{cases}$$

上计算目标函数的最小值. 可以证明 Dogleg 折线具有如下性质:

引理 5.2 (Dogleg 折线) 设 $G \in \mathbb{R}^{n \times n}$ 对称正定, 则

- (1) $\|\tilde{p}(\tau)\|$ 关于 τ 单调递增;
- (2) $m(\tilde{p}(\tau))$ 关于 τ 单调递减.

因此, 为了计算 Dogleg 点, 只需计算 Dogleg 折线与边界 $B(0, \Delta)$ 的交点.

5.6.4 二维子空间极小化方法

二维子空间极小化方法的思想是在 \mathbb{R}^n 的一个二维子空间上求解 $f(x)$ 的最小值. 当 $B \in \mathbb{R}^{n \times n}$ 正定时, 考察由 $g, B^{-1}g$ 生成的二维子空间

$$\min_{p \in \mathbb{R}^n} m(p) = f + g^T p + \frac{1}{2} p^T B p, \quad \text{s.t. } \|p\| \leq \Delta, p \in \text{span}[g, B^{-1}g] \quad (5.27)$$

则 (5.27) 的解可以作为子问题 (5.7) 的近似解. 当 B 非正定时, 取定 $\alpha > 0$ 使得 $B + \alpha I$ 正定, 则相应的极小化问题为

$$\min_{p \in \mathbb{R}^n} m(p) = f + g^T p + \frac{1}{2} p^T B p, \quad \text{s.t. } \|p\| \leq \Delta, p \in \text{span}[g, (B + \alpha I)^{-1}g] \quad (5.28)$$

一般地, 二维子空间方法由如下算法给出:

Algorithm 12: 二维子空间极小化方法

输入: $g \in \mathbb{R}^n$, $B \in \mathbb{R}^{n \times n}$, $\Delta > 0$

输出: 信赖域子问题 (5.7) 的近似解

令 (λ_1, q) 为对称阵 $B \in \mathbb{R}^{n \times n}$ 的最小特征对, 其中 λ_1 为最小特征值, $\|q\| = 1$

取定常数 $\varepsilon_0 = 10^{-6}$

```

if  $\lambda_1 \geq \varepsilon_0$  then
    ( $B$  对称正定)
     $p^B = -B^{-1}g$  (Newton 下降方向)
    if  $\|p^B\| \leq \Delta$  then
         $p = p^B$  (无约束极小点)
        return
    else
         $S = \text{span}[g, -B^{-1}g]$  (构造二维子空间)
    end

else if  $|\lambda_1| < \varepsilon_0$  then
    ( $B$  几乎奇异)
     $p = p^C$  (Cauchy 点)
    return

else
    ( $B$  为不定矩阵)
    选择常数  $\alpha = 1.5|\lambda_1| \in (-\lambda_1, -2\lambda_1]$ 
     $p = -(B + \alpha I)^{-1}g$ 
    if  $\|p\| \leq \Delta$  then
         $\gamma = -p^T q + \sqrt{(p^T q)^2 + \Delta^2 - \|p\|^2}$ 
         $p = p + \gamma q$  (hard case 增加的额外项)
        return
    else
         $S = \text{span}\{g, p\}$  (构造二维子空间)
    end
end

```

在二维子空间 S 上极小化二次函数 $m(p)$, 得到近似的最优解 p^*

在上述算法中, 我们对于 $\|(B + \alpha I)^{-1}g\| \leq \Delta$ 使用了类似于 hard case 的处理方式. 当 B 是不定矩阵时, 可以通过在

$$p = -(B + \alpha I)^{-1}g$$

加上负曲率方向 q 来使得 $\|p + \gamma q\| = \Delta$. 容易验证, 此式等价于方程

$$\gamma^2 + 2\gamma p^T q = \Delta^2 - \|p\|^2 \quad (5.29)$$

此方程的解恰好为 $\gamma = -p^T q + \sqrt{(p^T q)^2 + \Delta^2 - \|p\|^2}$.

在以上算法中, 仍需解决的问题是求解一般形式的二维子空间极小化问题

$$\min_{p \in \mathbb{R}^n} m(p) = f + g^T p + \frac{1}{2} p^T B p, \quad \text{s.t. } \|p\| \leq \Delta, p \in \text{span}[m_1, m_2] \quad (5.30)$$

其中 m_1, m_2 是二维子空间 S 的一个标准正交基. 利用 (m_1, m_2) , 下降步 $p \in \mathbb{R}^n$ 可以表示为

$$p = xm_1 + ym_2 = Mq \quad (5.31)$$

其中 $M = [m_1, m_2] \in \mathbb{R}^{n \times 2}$, $q \in \mathbb{R}^2$. 因此 (5.30) 变为

$$m(q) = f + g^T M q + \frac{1}{2} q^T M^T B M q = f + U^T q + \frac{1}{2} q^T G q \quad (5.32)$$

这里我们定义 $U = M^T g \in \mathbb{R}^2$ 和 $G = M^T B M \in \mathbb{R}^2$. 经过以下推导, 二维子空间极小化问题 (5.30) 简化为

$$\min_{q \in \mathbb{R}^2} m(q) = f + U^T q + \frac{1}{2} q^T G q, \quad \text{s.t. } \|q\| \leq \Delta \quad (5.33)$$

它可以转化为一个四次多项式的根问题. 具体的细节这里不再赘述.

6 约束优化理论

6.1 约束优化的基本概念

考虑约束优化问题

$$\begin{aligned} & \min_{x \in \mathbb{R}^n} f(x) \\ & \text{s.t. } c_i(x) = 0, \quad i \in E \\ & \quad c_i(x) \geq 0, \quad i \in I \end{aligned} \quad (6.1)$$

其中 $f(x)$ 是目标函数, $c_i(x)$ 是约束函数. $i \in E$ 时为等式约束, $i \in I$ 时为不等式约束.

定义 6.1 约束优化问题 (6.1) 的可行域为

$$X = \{x \in \mathbb{R}^n : c_i(x) = 0, i \in E; c_i(x) \geq 0, i \in I\} \quad (6.2)$$

因而约束优化问题转化为 $f(x)$ 在 X 上的最小值的求解.

定义 6.2 若 $x^* \in X$ 满足

$$f(x) \geq f(x^*), \quad \forall x \in X \quad (6.3)$$

则 x^* 是问题的全局极小点(最优解). 如果对 $x \neq x^*$ 都有

$$f(x) > f(x^*), \quad \forall x \neq x^* \quad (6.4)$$

则 x^* 是问题的严格全局极小点(最优解).

类似地还可以定义局部极小点和严格局部极小点. 在给定的点 $x \in \mathbb{R}^n$ 处, 约束条件 $c_i(x)$ 称为积极的, 如果在此处 $c_i(x) = 0$. 引入定义

定义 6.3 对任何 $x \in \mathbb{R}^n$, 称下标集合

$$\mathcal{A}(x) = E \cup I(x) \quad (6.5)$$

为积极约束集合, 其中

$$I(x) = \{i : c_i(x) \leq 0\} \quad (6.6)$$

简而言之, 积极约束描述来优化问题的临界状态: 可行方向的范围受到积极约束的限制.

6.2 一阶必要条件

判断一个点 x^* 是否为局部极小点主要依赖于它在局部的性质, 因此可行方向在最优化条件中起到重要的作用.

定义 6.4 设 $x^* \in X, d \in \mathbb{R}^n$ 称为可行方向, 如果存在 $\delta > 0$ 使得

$$x^* + td \in X, \quad \forall t \in [0, \delta] \quad (6.7)$$

x^* 处的所有可行方向的集合记为 $\text{FD}(x^*, X)$.

沿着可行方向的一整条线段都落在可行域中.

定义 6.5 设 $x^* \in X, d \in \mathbb{R}^n, x^*$ 称为线性化可行方向, 如果

$$d^T c_i(x) = 0, \quad i \in E \quad (6.8)$$

$$d^T c_i(x) \geq 0, \quad i \in I(x^*) \quad (6.9)$$

x^* 处的所有线性化可行方向记为 $\text{LFD}(x^*, X)$.

在线性化可行方向上,

- 等式约束的 $c_i(x)$ 应当不变, 即 $d^T c_i(x) = 0$;
- 有效不等式约束的 $c_i(x)$ 应当增加, 即 $d^T c_i(x) \geq 0$;
- 无效不等式约束的 $c_i(x)$ 没有限制.

因此其定义如上所示.

定义 6.6 设 $x^* \in X$, $d \in \mathbb{R}^n$, 如果存在序列 d_k 和 $\delta_k \rightarrow 0$ 使得

$$x^* + \delta_k d_k \in X \quad (6.10)$$

且 $d_k \rightarrow d$, $\delta_k \rightarrow 0$, 则 d 称为 x^* 处的序列可行方向, 记为 $SFD(x^*, X)$.

三种方式定义的可行方向有如下关系:

引理 6.1 若 $x^* \in X$ 且所有约束函数在 x^* 处可微, 则

$$FD(x^*, X) \subset SFD(x^*, X) \subset LFD(x^*, X) \quad (6.11)$$

可行方向对 $d \in \mathbb{R}^n$ 的约束太强, 通常不会用到. 线性化可行方向对应于线性方程组的解, 在实际中较为常用. 序列可行方向在局部极小点的判断中较为有用.

引理 6.2 (一阶必要条件: 序列可行) 设 x^* 是局部极小点, 若 $f(x), c_i(x)$ 在 x^* 处可微, 则

$$d^T \nabla c_i(x^*) \geq 0, \quad \forall d \in SFD(x^*, X) \quad (6.12)$$

上述定理揭示了局部极小点处序列可行方向的性质.

引理 6.3 (Farkas 引理) 设 $a_0, a_i (i = 1, \dots, l), b_i (i = 1, \dots, l') \in \mathbb{R}^n$, 则线性方程组

$$d^T a_i = 0, \quad i = 1, \dots, l \quad (6.13)$$

$$d^T b_i \geq 0, \quad i = 1, \dots, l' \quad (6.14)$$

$$d^T a_0 < 0 \quad (6.15)$$

无解当且仅当存在实数 $\lambda_i (i = 1, \dots, l)$ 和非负实数 $\mu_i (i = 1, \dots, l')$ 使得

$$a_0 = \sum_{i=1}^l \lambda_i a_i + \sum_{i=1}^{l'} \mu_i b_i \quad (6.16)$$

在 Farkas 引理中, $d^T a_i = 0$ 对应于等式约束, $d^T b_i \geq 0$ 对应于不等式约束, $d^T a_0 < 0$ 对应于下降方向的条件. 如果可行方向上没有下降方向, 则梯度方向 a_0 一定是约束梯度方向的线性组合, 并且不等式约束上的分量非负. 基于这种原因, 我们常常希望所谓的约束规范条件成立.

定义 6.7 (约束规范条件) 设 $x^* \in X$, 称 x^* 处**约束规范条件**满足, 如果

$$\text{LFD}(x^*, X) = \text{SFD}(x^*, X) \quad (6.17)$$

注意, 在各种可行方向和约束规范条件的定义中, 我们没有涉及目标函数的性质. 本质上说, **约束规范条件是对定义域性质和约束条件的刻画**.

下面我可以得到局部极小点满足的一阶必要条件:

定理 6.1 (一阶必要条件: KKT) 设 x^* 是局部极小点, 如果 x^* 处**约束规范条件**满足, 即

$$\text{SFD}(x^*, X) = \text{LFD}(x^*, X) \quad (6.18)$$

则必存在 λ^* 使得

$$\nabla f(x^*) = \sum_{i \in E \cup I(x^*)} \lambda_i^* \nabla c_i(x^*) \quad (6.19)$$

且

$$\lambda_i^* \geq 0, \quad \lambda_i^* c_i(x^*) = 0, \quad i \in I \quad (6.20)$$

证明 根据一阶必要条件和约束优化规范条件,

$$d^T \nabla c_i(x^*) \geq 0, \quad \forall d \in \text{LFD}(x^*, X) \quad (6.21)$$

故下面的线性方程组无解:

$$d^T \nabla c_i(x^*) = 0, \quad i \in E \quad (6.22)$$

$$d^T \nabla c_i(x^*) \geq 0, \quad i \in I(x^*) \quad (6.23)$$

$$d^T \nabla f(x^*) < 0 \quad (6.24)$$

因此, 由 Farkas 引理, 存在 $\lambda_i^* (i \in E \cup I(x^*))$ 使得

$$\nabla f(x^*) = \sum_{i \in E} \lambda_i^* \nabla c_i(x^*) + \sum_{i \in I(x^*)} \lambda_i^* \nabla c_i(x^*) \quad (6.25)$$

其中 $\lambda_i^* \geq 0, i \in I(x^*)$. 反过来, 我们也可以通过 KKT 条件来得到一阶必要条件:

$$d^T \nabla f(x^*) = \sum_{i \in E} \lambda_i^* d^T \nabla c_i(x^*) + \sum_{i \in I(x^*)} \lambda_i^* d^T \nabla c_i(x^*) \geq 0 \quad (6.26)$$

因此 (6.21) 成立. 综上, KKT 条件等价于 (6.21). 我们可以使用直观的方式来理解 KKT 条件:

- 最优性: $\nabla f(x^*) = \sum_{i \in E \cup I} \lambda_i^* \nabla c_i(x^*)$

- 非负性: $\lambda_i^* \geq 0, i \in I$
- 互补性: $\lambda_i^* c_i(x^*) = 0, i \in I$

一种更直观的方式是利用有效约束改写 KKT 条件:

- 最优性: $\nabla f(x^*) = \sum_{i \in \mathcal{A}(x^*)} \lambda_i^* \nabla c_i(x^*)$
- 非负性: $\lambda_i^* \geq 0, i \in I(x^*)$

KKT 条件里的 x^* 称为 KKT 点, λ^* 称为 Lagrange 乘子. 本质上, 我们只需要有效约束上的 λ_i^* 就可以判断是否为 KKT 点.


例 1 考虑约束优化问题

$$\min_{x \in \mathbb{R}^n} -x_1 - x_2 \quad (6.27)$$

$$\text{s.t. } x_2 - x_1^2 \geq 0 \quad (6.28)$$

$$1 - x_1^2 - x_2^2 \geq 0 \quad (6.29)$$

求出该问题的所有 KKT 点.



在该问题中, $f(x) = -x_1 - x_2$, 约束函数

$$c_1(x) = x_2 - x_1^2, \quad c_2(x) = 1 - x_1^2 - x_2^2$$

于是

$$\nabla f(x) = \begin{bmatrix} -1 \\ -1 \end{bmatrix}, \quad \nabla c_1(x) = \begin{bmatrix} -2x_1 \\ 1 \end{bmatrix}, \quad \nabla c_2(x) = \begin{bmatrix} -2x_1 \\ -2x_2 \end{bmatrix}$$

因此 KKT 条件给出

$$\begin{cases} -1 = -2x_1\lambda_1 - 2x_1\lambda_2 \\ -1 = \lambda_1 - 2x_2\lambda_2 \end{cases}$$

因此 $\lambda_2 \neq 0$, 否则 $\lambda_1 = -1 < 0$. 下面分别讨论 $\lambda_1 = 0$ 和 $\lambda_1 \neq 0$ 的情形:

- $\lambda_1 = 0$, 则 $x_1 = x_2$, 因此 $x_1 = x_2 = \pm \frac{1}{\sqrt{2}}$. 由于 $\lambda_2 > 0$, 故 $x_1 = x_2 = \frac{1}{\sqrt{2}}$, 因此

$$x^* = \left(\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right), \quad \lambda^* = \left(0, \frac{1}{\sqrt{2}} \right)$$

- $\lambda_1 \neq 0$, 则两个约束条件都起作用, 有

$$1 = x_1^2 + x_1^4$$

因此

$$x_1 = \pm \sqrt{\frac{\sqrt{5}-1}{2}}, \quad x_2 = \frac{\sqrt{5}-1}{2}$$

但 $x_1(\lambda_1 + \lambda_2) = 1 > 0$, 故 $x_1 > 0$, 从而

$$x_1 = \sqrt{\frac{\sqrt{5}-1}{2}}$$

因此对应的点 x^* 和 Lagrange 乘子 λ^* 为

$$x^* = (a, a^2), \quad \lambda^* = \left(\frac{a-1}{2a^2+1}, \frac{2a+1}{2a(2a^2+1)} \right)$$

其中

$$a = \sqrt{\frac{\sqrt{5}-1}{2}} < 1$$

因此 $\lambda_1^* < 0$, 故 x^* 不是 KKT 点!


综上, $x^* = (\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}})$ 是唯一的 KKT 点.

在下面的例子我们将看到, 也可以用 $d^T \nabla f(x^*) \geq 0$ 判断给定的点是否为 KKT 点.

例 2 (Nocedal 12.15) Consider the following problem where t is a parameter to be fixed prior to solving the problem:

$$\min_x \left(x_1 - \frac{3}{2} \right)^2 + (x_2 - t)^4, \quad \text{s.t. } \begin{bmatrix} 1 - x_1 - x_2 \\ 1 - x_1 + x_2 \\ 1 + x_1 - x_2 \\ 1 + x_1 + x_2 \end{bmatrix} \geq 0$$

- (a) For what values of t does the point $x^* = (1, 0)^T$ satisfy the KKT conditions?
- (b) Show that when $t = 1$, only the first constraint is active at the solution, and find the solution.



在此问题中, 目标函数为 $f(x) = (x_1 - \frac{3}{2})^2 + (x_2 - t)^4$, 约束函数 $c_1(x), c_2(x), c_3(x), c_4(x)$ 由上述不等式给出. 由于

$$\nabla f(x) = \begin{bmatrix} 2x_1 - 3 \\ 4(x_2 - t)^3 \end{bmatrix}$$

故在可行点 x 处的 KKT 条件为

$$\begin{cases} 2x_1 - 3 = -\lambda_1 - \lambda_2 + \lambda_3 + \lambda_4 \\ 4(x_2 - t)^3 = -\lambda_1 + \lambda_2 - \lambda_3 + \lambda_4 \end{cases}$$

(a) 在 $x^* = (1, 0)$ 处, 约束条件 $c_3(x), c_4(x)$ 不起作用, 因此 $\lambda_3 = \lambda_4 = 0$, 于是可得

$$\begin{cases} -1 = -\lambda_1 - \lambda_2 \\ -4t^3 = -\lambda_1 + \lambda_2 \end{cases}$$

因此得到 Lagrange 乘子为

$$\lambda_1 = \frac{1}{2} + 2t^3, \quad \lambda_2 = \frac{1}{2} - 2t^3$$

根据 $\lambda_1, \lambda_2 \geq 0$ 的条件, x^* 是 KKT 点当且仅当 $\lambda_1, \lambda_2 \geq 0$, 即 $|t| \leq \sqrt[3]{\frac{1}{4}}$.

(b) 分情况讨论:

- 当 $t = 1$ 时, 我们首先证明约束 $c_1(x) = 0$ 必须被满足. 否则, 若 $x \in \mathbb{R}^2$ 使得 $c_1(x) > 0$, 则 $d = (1, 1)$ 是线性化可行方向, 但是沿着 d 的方向

$$d^T g(x) = (2x_1 - 3) + 4(x_2 - 1)^3 < 0$$

故 x 一定不是 KKT 点. 在 KKT 点处, 必须有 $c_1(x) = 0$ 满足.

- 在 $x = (1, 0)$ 处, 线性化可行方向 $d = (-1, 1)$ 使得

$$d^T g(x) = -(2x_1 - 3) + 4(x_2 - 1)^3 = -3 < 0$$

因此 $x = (1, 0)$ 不是 KKT 点.

- 在 $x = (0, 1)$ 处, 线性化可行方向 $d = (1, -1)$ 使得

$$d^T g(x) = (2x_1 - 3) - 4(x_2 - 1)^3 = -3 < 0$$

因此 $x = (0, 1)$ 不是 KKT 点.

- 因此, KKT 点只能出现在 $c_1(x) = 0$ 对应的开线段上. 此时 $c_2(x), c_3(x), c_4(x)$ 均不起作用, 故 $\lambda_2 = \lambda_3 = \lambda_4 = 0$, 且由 KKT 条件可得

$$\begin{cases} 2x_1 - 3 = -\lambda_1 \\ 4(x_2 - 1)^3 = -\lambda_1 \\ x_1 + x_2 = 1 \end{cases}$$

其解为 $x_1 \approx 0.7281$.

综上, 此问题在 $c_1(x) = 0$ 上存在唯一的 KKT 点.

例 3 考虑约束优化问题


$$\min_{x \in \mathbb{R}^2} (x_1 - 2)^2 + x_2^2 \quad (6.30)$$

$$\text{s.t. } (1 - x_1)^3 - x_2 \geq 0 \quad (6.31)$$

$$x_1, x_2 \geq 0 \quad (6.32)$$

回答以下问题:

- (1) 求出该问题的所有 KKT 点;
- (2) 求问题的局部极小点.



目标函数为

$$f(x) = (x_1 - 2)^2 + x_2^2$$

约束函数为

$$c_1(x) = (1 - x_1)^3 - x_2, \quad c_2(x) = x_1, \quad c_3(x) = x_2$$

因此

$$\nabla f(x) = \begin{bmatrix} 2(x_1 - 1) \\ 2x_2 \end{bmatrix}, \quad \nabla c_1(x) = \begin{bmatrix} -3(1 - x_1)^2 \\ -1 \end{bmatrix}, \quad \nabla c_2(x) = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \quad \nabla c_3(x) = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

相应的 KKT 条件为

$$\begin{cases} 2(x_1 - 2) = -3\lambda_1(1 - x_1)^2 + \lambda_2 \\ 2x_2 = -\lambda_1 + \lambda_3 \end{cases}$$

由于 $\lambda_1 \geq 0$, 故 $\lambda_3 \geq 2x_2$. 下面分 3 种情形讨论上述方程的解:

- 若 $x_2 \neq 0$, 则 $\lambda_3 > 0$, 因此 $c_3(x) = x_2 = 0$ 为有效约束. 但这意味着 $x_2 = 0$, 矛盾!
- 因此必须 $x_2 = 0$. 若 $x_1 \in [0, 1)$, 则在 $x^* = (x_1, 0)$ 处, 沿着方向 $d = (1, 0)$ 一定会使目标函数 $f(x)$ 的值下降, 因为

$$d^T \nabla f(x) = 2(x_1 - 2) < 0$$

但 $d = (1, 0) \in \text{LFD}(x^*, X)$ 为线性化可行方向, 与 KKT 条件矛盾! 因此 $x_1 \in [0, 1)$ 时, x^* 不可能是 KKT 点.

- 剩下唯一的可能性: $x^* = (1, 0)$. 此时 $c_2(x) = x_1$ 为无效约束, $\lambda_2 = 0$. 但 KKT 条件给出

$$\begin{cases} -2 = \lambda_2 \\ 0 = -\lambda_1 + \lambda_3 \end{cases}$$

矛盾!

综上, 该问题不存在 KKT 点.

但是, 这显然不意味着这个问题没有局部极小点. 实际上, 除了 $x^* = (1, 0)$ 之外, 其它所有点处都有约束规范条件成立, 因此那些点一定不是局部极小点. 因此, 唯一的局部极小点就是 $x^* = (1, 0)$, 但是在这个点, 约束规范条件不成立.

下面我们给出使得约束规范条件 (6.17) 成立的若干条件:

定理 6.2 (约束规范条件) 若以下之一成立, 则约束规范条件 $\text{SFD}(x^*, X) = \text{LFD}(x^*, X)$ 成立:

1. 所有 $c_i(x), i \in \mathcal{A}(x^*)$ 是线性函数.
2. LICQ: $\nabla c_i(x^*), i \in \mathcal{A}(x^*)$ 线性无关.

综合以上结果, 我们可以给出完整的一阶最优条件刻画:

定理 6.3 (一阶必要条件) 设 x^* 是局部极小点, 如果 $\nabla c_i(x), i \in \mathcal{A}(x^*)$ 线性无关, 则 x^* 是 KKT 点, 即存在 Lagrange 乘子 λ^* 使得 KKT 条件成立.

6.3 一阶充分条件

我们讨论局部极小点的一阶充分条件.

定理 6.4 设 $x^* \in X$. 如果 $f(x)$ 和 $c_i(x)$ 在 x^* 处可微, 且

$$d^T \nabla f(x^*) > 0, \quad \forall 0 \neq d \in \text{SFD}(x^*, X) \quad (6.33)$$

则 x^* 是严格局部极小点.

由于 $\text{SFD}(x^*, X) \subset \text{LFD}(x^*, X)$, 因此我们得到以下结果:

推论 6.1 设 $x^* \in X$. 如果 $f(x)$ 和 $c_i(x)$ 在 x^* 处可微, 且

$$d^T \nabla f(x^*) > 0, \quad \forall 0 \neq d \in \text{LFD}(x^*, X) \quad (6.34)$$

则 x^* 是严格局部极小点.

在实际中, 更加实用的判断极小点的方式是直接验证不等式:

定理 6.5 (实用充分条件) 设 x^* 是约束优化问题的 KKT 点, λ 是相应的 Lagrange 乘子. 如果

$$L(x^*, \lambda) \leq L(x, \lambda) \quad (6.35)$$

在 x^* 的某个邻域 $B(x^*, \delta)$ 中成立, 则 x^* 是局部极小点. 若不等式对 $x \in \mathbb{R}^n$ 恒成立, 则 x^* 是全局极小点.

在 KKT 点处, 有 $L(x^*, \lambda) = f(x^*)$. 由

$$L(x, \lambda) = f(x) - \sum_{i=1}^n \lambda_i c_i(x) \geq L(x^*, \lambda) = f(x^*)$$

可以得到, 当 x 位于可行域中时,

$$f(x) \geq f(x^*) + \sum_{i=1}^n \lambda_i c_i(x) \geq f(x^*)$$

因此 x^* 为局部极小点.

例 4 求解如下的约束优化问题

$$\min x_1^2 + x_2^2 \quad (6.36)$$

$$\text{s.t. } x_1^2 + x_2 - 1 \geq 0 \quad (6.37)$$

首先我们求出问题的 KKT 点. 目标函数 $f(x) = x_1^2 + x_2^2$, 约束函数 $c(x) = x_1^2 + x_2 - 1$, 故

$$\nabla f(x) = \begin{bmatrix} 2x_1 \\ 2x_2 \end{bmatrix}, \quad \nabla c(x) = \begin{bmatrix} 2x_1 \\ 1 \end{bmatrix}$$

因此 KKT 条件给出

$$\begin{cases} 2x_1 = 2x_1\lambda \\ 2x_2 = \lambda \end{cases}$$

按照 x_1 分情况讨论:

- 如果 $x_1 \neq 0$, 则 $\lambda = 1$, $x_2 = \frac{1}{2}$, 并且约束有效. 此时 $x_1 = \frac{1}{\sqrt{2}}$ (或者相应的负值). 故

$$x^* = \left(\frac{1}{\sqrt{2}}, \frac{1}{2} \right), \quad \lambda^* = 1$$

它是一个 KKT 点. 为了证明它是局部极小点, 我们证明

$$L(x, \lambda^*) \geq f(x^*)$$

对 $x \in \mathbb{R}^2$ 恒成立. 事实上,

$$\begin{aligned} L(x, \lambda^*) &= f(x) - c(x) \\ &= x_2^2 - x_2 + 1 \\ &\geq \frac{3}{4} = f(x^*) \end{aligned}$$

因此当 x 位于可行域中时

$$f(x) \geq f(x^*) + c(x) \geq f(x^*)$$

因此 $x^* = (\frac{1}{\sqrt{2}}, \frac{1}{2})$ 是局部极小点.

- 如果 $x_1 = 0$, 则 $x_2 \geq 1$, 故 $\lambda_2 > 0$, 为有效约束. 因此 $x_2 = 1, \lambda = 2$, 故

$$x^* = (0, 1), \quad \lambda^* = 2$$

它是一个 KKT 点. 为了证明它不是局部极小点, 考虑

$$x^\varepsilon = (\varepsilon, 1 - \varepsilon^2), \quad \varepsilon > 0$$

则 x^ε 位于可行域中, 且 ε 充分小时,

$$f(x^\varepsilon) = \varepsilon^2 + (1 - \varepsilon^2)^2 < f(x^*)$$

故 x^* 不是局部极小点.

综上, 该问题的极小点为 $x^* = (\pm \frac{1}{\sqrt{2}}, \frac{1}{2})$.

我们对一阶最优性条件做一总结:

必要	$d^T \nabla f(x^*) \geq 0, \forall d \in \text{SFD}(x^*, X)$	\iff	$d^T \nabla f(x^*) \geq 0, \forall d \in \text{LFD}(x^*, X)$: KKT 条件
充分	$d^T \nabla f(x^*) > 0, \forall 0 \neq d \in \text{SFD}(x^*, X)$	\iff	$d^T \nabla f(x^*) > 0, \forall 0 \neq d \in \text{LFD}(x^*, X)$
实用充分	$L(x^*, \lambda) \leq L(x, \lambda), \forall x \in \mathbb{R}^n$		

表 1:: 一阶最优性条件

求 KKT 点的解题策略:

1. 求解 KKT 方程组
2. 验证 x 不是 KKT 点时, 取一线性化可行方向 d 使得 $d^T \nabla f(x) < 0$

验证局部极小点的解题策略:

1. 排除其它所有可能是局部极小点的地方 (适用于 KKT 点只有 1 个的情形)
2. 当约束函数和目标函数简单时, 使用基本不等式证明
3. 证明 $L(x^*, \lambda) \leq L(x, \lambda), \forall x \in \mathbb{R}^n$
4. 使用定义证明某一点不是局部极小点

6.4 二阶最优性条件

二阶最优性条件主要适用于已经求出 KKT 点, 但是利用已知的一阶条件不足以判断它是否是最优的情形. 不过, 在实际情形中, 我们可以用其它的方法来判断某个点是否是最优的, 比如目标函数比较简单的情形. 计算 Lagrange 函数的二阶导数实际上还是相对复杂的, 零约束子空间实际上也没那么好求.

下面我们假设在某个 x^* 处, 一阶必要条件满足, 但充分条件不满足, 即:

$$d^T \nabla f(x^*) \geq 0, \quad \forall d \in SFD(x^*, X) \quad (6.38)$$

$$d^T \nabla f(x^*) = 0, \quad \exists 0 \neq d \in SFD(x^*, X) \quad (6.39)$$

则这些条件不足以判断 x^* 是否是局部极小点. 假设约束规范条件成立, 则第一个条件给出 KKT 条件, 因此

$$\nabla f(x^*) = \sum_{i \in \mathcal{A}(x^*)} \lambda_i^* \nabla c_i(x^*) \quad (6.40)$$

于是 d 使得 $d^T \nabla f(x^*) = 0$ 当且仅当

$$\lambda_i^* d^T \nabla c_i(x^*) = 0, \quad \forall i \in I(x^*) \quad (6.41)$$

自然地, 我们引入如下定义

定义 6.8 设 x^* 是 KKT 点且 λ^* 为相应的 Lagrange 乘子. 若 $d \in LFD(x^*, X)$ 且

$$\lambda_i^* d^T \nabla c_i(x^*) = 0, \quad \forall i \in I(x^*) \quad (6.42)$$

则 d 称为 x^* 处的线性化零约束方向. x^* 处的所有线性化零约束方向的集合记为 $G(x^*, \lambda^*)$.

关于线性化零约束方向 d 的评注:

- d 首先得是一个可行方向;

- d 的定义与目标函数没有直接关系, 间接关系是最优性条件:

$$\nabla f(x^*) = \sum_{i \in \mathcal{E}} \lambda_i^* \nabla c_i(x^*) + \sum_{i \in \mathcal{I}(x^*)} \lambda_i^* \nabla c_i(x^*) \quad (6.43)$$

一方面, d 可行意味着

$$d^T \nabla c_i(x^*) = 0, \quad i \in \mathcal{E}$$

另一方面, d 是线性化零约束方向意味着

$$\lambda_i^* d^T \nabla c_i(x^*) = 0, \quad i \in I(x^*)$$

因此在 x^* 处沿着 d 的方向 $f(x)$ 的值不改变. 这是它称为线性化零约束方向的原因.

- 在老师的笔记中, 线性化零约束方向被定义为

$$\text{LFD}_1(x^*, X) = \left\{ \begin{array}{l} d^T \nabla c(x^*) = 0, i \in E \\ d \neq 0 : d^T \nabla c(x^*) = 0, i \in I(x^*), \lambda_i^* \neq 0 \\ d^T \nabla c(x^*) \geq 0, i \in I(x^*), \lambda_i^* = 0 \end{array} \right\} \quad (6.44)$$

这两种定义是等价的.

类似地还可以定义序列零约束方向:

定义 6.9 设 x^* 是 KKT 点且 λ^* 为相应的 Lagrange 乘子. 如果存在序列 d_k 和 $\delta_k > 0$ 使得

$$\begin{aligned} x^* + \delta_k d_k &\in X \\ \sum_{i=1}^m \lambda_i^* c_i(x^* + \delta_k d_k) &= 0 \end{aligned}$$

且 $d_k \rightarrow d$ 和 $\delta_k \rightarrow 0$, 则称 d 是 x^* 处的序列零约束方向.

在上面的定义中, 上面的等式等价于

$$\lambda_i^* c_i(x^* + \delta_k d_k) = 0, \quad \forall i \in I$$

事实上, 由于 $x^* + \delta_k d_k$ 是可行点, 故

$$c(x^* + \delta_k d_k) = 0, \quad i \in \mathcal{E}$$

引理 6.4 设 x^* 是 KKT 点且 λ^* 是相应的 Lagrange 乘子, 则

$$S(x^*, \lambda^*) \subset G(x^*, \lambda^*) \quad (6.45)$$

在等式

$$\sum_{i=1}^m \lambda_i^* \frac{c_i(x^* + \delta_k d_k) - c_i(x^*)}{\delta_k} = 0 \quad (6.46)$$

中令 $k \rightarrow \infty$, 有

$$\sum_{i=1}^m \lambda_i^* d^T \nabla c_i(x^*) = 0 \quad (6.47)$$

对于等式约束, 已经有 $d^T \nabla c_i(x^*) = 0$; 对于无效不等式约束, 有 $\lambda_i^* = 0$, 因此上式变成

$$\sum_{i \in I(x^*)} \lambda_i^* d^T \nabla c_i(x^*) = 0 \quad (6.48)$$

由于其中的每一项非负, 故每一项均为 0. 下面我们给出二阶必要条件和充分条件:

定理 6.6 (二阶必要条件) 设 x^* 是局部极小点, λ^* 是 Lagrange 乘子, 则

$$d^T \nabla_{xx}^2 L(x^*, \lambda^*) d \geq 0, \quad \forall d \in S(x^*, \lambda^*) \quad (6.49)$$

注意: x^* 是局部极小点时, 由约束规范条件 x^* 是 KKT 点, 故 λ^* 一定存在.

定理 6.7 (二阶充分条件) 设 x^* 是 KKT 点, λ^* 是相应的 Lagrange 乘子. 若

$$d^T \nabla_{xx}^2 L(x^*, \lambda^*) d > 0, \quad \forall 0 \neq d \in G(x^*, \lambda^*) \quad (6.50)$$

则 x^* 是严格极小点.

关于二阶条件我们有以下评注:

1. 为什么是 Lagrange 函数 $L(x, \lambda^*)$ 而不是目标函数 $f(x)$? 因为 Lagrange 函数才满足

$$\nabla_x L(x^*, \lambda^*) = 0 \quad (6.51)$$

即一阶导数为 0. 对这样的函数考虑二阶导数才合理.

2. 为什么只在零约束方向上考虑二阶导数? 因为在其它方向上, $f(x)$ 沿着 d 的方向一定是递增的, 也就是一阶条件已经够用了, 没必要考虑二阶条件.

6.5 鞍点理论

对给定的约束优化问题 (6.1), 考虑 Lagrange 函数

$$L(x, \lambda) = f(x) - \sum_{i \in E \cup I} \lambda_i c_i(x) \quad (6.52)$$

其中 $x \in \mathbb{R}^n$, $\lambda \in K$, 区域 K 定义为

$$K = \{\lambda : \lambda_i \geq 0, i \in I\} \quad (6.53)$$

定义 6.10 $\bar{x} \in \mathbb{R}^n$ 和 $\bar{\lambda} \in K$ 称为 $L(x, \lambda)$ 的鞍点, 如果对任何 $x \in \mathbb{R}^n$ 和 $\lambda \in K$, 都有

$$L(\bar{x}, \lambda) \leq L(\bar{x}, \bar{\lambda}) \leq L(x, \bar{\lambda}) \quad (6.54)$$

鞍点理论最重要的结果是: 鞍点一定是最优解.

定理 6.8 (鞍点定理) 设 $(\bar{x}, \bar{\lambda})$ 是 $L(x, \lambda)$ 的鞍点, 则 \bar{x} 是约束优化问题 (6.1) 的最优解.

首先证明: $L(\bar{x}, \lambda) \leq L(\bar{x}, \bar{\lambda})$ 恒成立给出 \bar{x} 是可行点. 由 $L(x, \lambda)$ 的表达式, 可得

$$f(\bar{x}) - \sum_{i \in E \cup I} \lambda_i c_i(\bar{x}) \leq f(\bar{x}) - \sum_{i \in E \cup I} \bar{\lambda}_i c_i(\bar{x}), \quad \lambda \in K \quad (6.55)$$

即

$$\sum_{i \in E} \bar{\lambda}_i c_i(\bar{x}) + \sum_{i \in I} \bar{\lambda}_i c_i(\bar{x}) \leq \sum_{i \in E} \lambda_i c_i(\bar{x}) + \sum_{i \in I} \lambda_i c_i(\bar{x}) \quad (6.56)$$

当 $i \in E$ 时, 必须 $c_i(\bar{x}) = 0$; 当 $i \in I$ 时, 必须 $c_i(\bar{x}) \geq 0$. 因此 \bar{x} 是可行点.

下面考察右端的不等式. 当 x 是可行点时, 由 $L(\bar{x}, \bar{\lambda}) \leq L(x, \bar{\lambda})$ 可以得到

$$f(\bar{x}) \leq f(x) - \sum_{i \in I} \lambda_i c_i(x) \quad (6.57)$$

故

$$f(x) \geq f(\bar{x}) + \sum_{i \in I} \lambda_i c_i(x) \geq f(\bar{x}) \quad (6.58)$$

因此 \bar{x} 一定是最优解. 鞍点的这一条性质反过来不一定对.

定理 6.9 (鞍点逆定理) 设凸规划问题是强相容的, 则若 x^* 是约束优化问题的最优解, 则存在 λ^* 使得 (x^*, λ^*) 是 Lagrange 函数 $L(x, \lambda)$ 的鞍点, 且 $\lambda_i^* c_i(x^*) = 0, i \in I$.

求一个 Lagrange 函数的鞍点的方法:

1. 求出约束优化问题的最小点;
2. 求出最小点的 Lagrange 乘子;
3. 验证相应的 (x^*, λ^*) 是鞍点.

6.6 对偶问题

根据鞍点理论, 最优点的计算可以通过 $L(x, \lambda)$ 的鞍点的计算得到. 更具体地说, 计算分为 2 步:

1. 将 $L(x, \lambda)$ 对 $x \in \mathbb{R}^n$ 取最小值得到 $\theta(\lambda)$;

2. 对 $\theta(\lambda)$ 在定义域 K 取最大值.

我们可以将上述思想说明得更加形式化:

定义 6.11 (对偶问题) 对于约束优化问题

$$\begin{aligned} & \min_{x \in \mathbb{R}^n} f(x) \\ \text{s.t. } & c_i(x) = 0, i \in E \\ & c_i(x) \geq 0, i \in I \end{aligned}$$

设它的 Lagrange 函数为

$$L(x, \lambda) = f(x) - \sum_{i \in E \cup I} \lambda_i c_i(x)$$

其中 $x \in \mathbb{R}^n$, $\lambda \in K$, 且

$$\theta(\lambda) = \min_{x \in \mathbb{R}^n} L(x, \lambda)$$

则相应的对偶问题为

$$\begin{aligned} & \min \theta(\lambda) \\ \text{s.t. } & \lambda_i \geq 0, i \in I \end{aligned}$$

我们用一些简单的例子来说明上述思想.

例 5 考虑约束最优化问题

$$\min x_1 + x_2 \tag{6.59}$$

$$\text{s.t. } x_1^2 + x_2^2 \leq 2 \tag{6.60}$$

在此问题中, $f(x) = x_1 + x_2$, $c(x) = 2 - x_1^2 - x_2^2$, 因此 Lagrange 函数为

$$\begin{aligned} L(x, \lambda) &= f(x) - \lambda c(x) \\ &= \lambda(x_1^2 + x_2^2) + x_1 + x_2 - 2\lambda \end{aligned}$$

当 $\lambda > 0$ 时, 该函数的最小值在

$$x_1 = x_2 = -\frac{1}{2\lambda}$$

处取到. 因此

$$\theta(\lambda) = \max_x L(x, \lambda) = -\frac{1}{2\lambda} - 2\lambda \leq -2$$

且等号成立当且仅当 $\lambda = \frac{1}{2}$. 因此最优点为 $x^* = (-1, -1)$, 相应的 Lagrange 乘子 $\lambda^* = \frac{1}{2}$.

例 6 考虑约束最优化问题

$$\min x_1^2 + x_2^2 \quad (6.61)$$

$$\text{s.t. } x_1 + x_2 \geq 4 \quad (6.62)$$

$$x_1, x_2 \geq 0 \quad (6.63)$$

$$(6.64)$$

此问题的 Lagrange 函数为

$$L(x, \lambda) = x_1^2 + x_2^2 - \lambda_1(x_1 + x_2 - 4) - \lambda_2 x_1 - \lambda_3 x_2$$

对 x_1, x_2 取最小值, 可以得到

$$\theta(\lambda) = \min_x L(x, \lambda) = -\frac{(\lambda_1 + \lambda_2)^2}{4} - \frac{(\lambda_1 + \lambda_3)^2}{4} + 4\lambda_1$$

其中 $\lambda_1, \lambda_2, \lambda_3 \geq 0$. 下面求 $\theta(\lambda)$ 的最大值.

$$\theta(\lambda) \leq -\frac{\lambda_1^2}{2} + 4\lambda_1 \leq 8$$

等号成立当且仅当 $\lambda_1 = 4, \lambda_2 = \lambda_3 = 0$. 此时

$$x_1 = \frac{\lambda_1 + \lambda_2}{2} = 2, \quad x_2 = \frac{\lambda_1 + \lambda_3}{2} = 2$$

因此最优点 $x^* = (2, 2)$.

例 7 考虑优化问题

$$\min x_1$$

$$\text{s.t. } |x_1| + |x_2| \leq 1$$

求出该问题的对偶问题并求解之.

该问题的目标函数为 $f(x) = x_1$, 约束函数为

$$c_1(x) = 1 - x_1 - x_2$$

$$c_2(x) = 1 - x_1 + x_2$$

$$c_3(x) = 1 + x_1 - x_2$$

$$c_4(x) = 1 + x_1 + x_2$$

因此 Lagrange 函数为

$$\begin{aligned} L(x, \lambda) &= f(x) - \lambda_1 c_1(x) - \lambda_2 c_2(x) - \lambda_3 c_3(x) - \lambda_4 c_4(x) \\ &= x_1 + \lambda_1(x_1 + x_2 - 1) + \lambda_2(x_1 - x_2 - 1) + \lambda_3(-x_1 + x_2 - 1) + \lambda_4(-x_1 - x_2 - 1) \\ &= x_1(1 + \lambda_1 + \lambda_2 - \lambda_3 - \lambda_4) + x_2(\lambda_1 - \lambda_2 + \lambda_3 - \lambda_4) - \lambda_1 - \lambda_2 - \lambda_3 - \lambda_4 \end{aligned}$$

定义区域

$$K = \left\{ \lambda \in \mathbb{R}^4 : \begin{array}{l} 1 + \lambda_1 + \lambda_2 - \lambda_3 - \lambda_4 = 0 \\ \lambda_1 - \lambda_2 + \lambda_3 - \lambda_4 = 0 \\ \lambda_1, \lambda_2, \lambda_3, \lambda_4 \geq 0 \end{array} \right\}$$

则在 K 上有 $\lambda_4 = \lambda_1 + \frac{1}{2}$, $\lambda_3 = \lambda_2 + \frac{1}{2}$. 因此对偶 Lagrange 函数为

$$\theta(\lambda) = \begin{cases} -\lambda_1 - \lambda_2 - \lambda_3 - \lambda_4, & \lambda \in K \\ -\infty, & \lambda \notin K \end{cases}$$

因此 $\lambda \in K$ 时,

$$\theta(\lambda) \leq -1$$

且等号成立当且仅当 $\lambda_1 = \lambda_2 = 0$, $\lambda_3 = \lambda_4 = 0$. 由于 $c_3(x) = c_4(x) = 0$ 为有效约束, 故 $x_1 = -1$, $x_2 = 0$, 即原问题的最优点为 $x^* = (-1, 0)$.

现在一个自然的问题是, 原问题与对偶问题的最优解是否是相同的, 即是否有

$$\min_{x \in X} f(x) = \max_{\lambda \in K} \theta(\lambda)$$

定理 6.10 (弱对偶定理) 设 $x \in X$, $\lambda \in K$, 则

$$f(x) \geq \theta(\lambda)$$

按照 $\theta(\lambda)$ 的定义,

$$\theta(\lambda) = \min_{x \in \mathbb{R}^n} \{f(x) - \sum_{i \in E \cup I} \lambda_i c_i(x)\} \leq f(x) - \sum_{i \in E \cup I} \lambda_i c_i(x)$$

当 $x \in X$, $\lambda \in K$ 时,

$$\sum_{i \in E \cup I} \lambda_i c_i(x) \geq 0$$

因此 $\theta(\lambda) \leq f(x)$. 由弱对偶定理可以得到

$$\inf_{x \in X} f(x) \geq \sup_{\lambda \in K} \theta(\lambda)$$

定义 6.12 (对偶间隙) 给定约束优化问题 $f(x)$ 和相应的对偶函数 $\theta(\lambda)$, 定义其对偶间隙为

$$\gamma = \inf_{x \in X} f(x) - \sup_{\lambda \in K} \theta(\lambda) \quad (6.65)$$

下面我们的任务是探讨在何种情形下对偶间隙为 0.

定义 6.13 (Slater 条件) 对凸规划问题, 若

$$D = \left\{ x \in \mathbb{R}^n : \begin{array}{l} c_i(x) = 0, \quad i \in E \\ c_i(x) > 0, \quad i \in I \end{array} \right\}$$

非空, 则称约束函数满足 Slater 条件.

定理 6.11 (强对偶定理) 对凸规划问题, 若 Slater 条件满足, 则对偶间隙 $\gamma = 0$.

考虑一个具体的例子: 二次规划.

$$\min_{x \in \mathbb{R}^n} f(x) = \frac{1}{2} x^T G x + g^T x \quad (6.66)$$

$$\text{s.t. } a_i^T x = b_i, \quad i \in E \quad (6.67)$$

$$a_i^T x \geq b_i, \quad i \in I \quad (6.68)$$

此问题的 Lagrange 函数为

$$\begin{aligned} L(x, \lambda) &= f(x) - \lambda^T (Ax - b) \\ &= \frac{1}{2} x^T G x + g^T x - \lambda^T (Ax - b) \\ &= \frac{1}{2} x^T G x + x^T (g - A^T \lambda) + b^T \lambda \end{aligned}$$

其中 $\lambda \in K$, 区域 K 定义为

$$K = \left\{ \lambda : \begin{array}{l} \lambda_i = 0, \quad i \in E \\ \lambda_i \geq 0, \quad i \in I \end{array} \right\}$$

因此对偶函数

$$\theta(\lambda) = \min_{x \in \mathbb{R}^n} L(x, \lambda) = -\frac{1}{2} (-g + A^T \lambda)^T G^{-1} (-g + A^T \lambda) + b^T \lambda$$

原优化问题的对偶函数为

$$\max \frac{1}{2} (-g + A^T \lambda)^T G^{-1} (-g + A^T \lambda) + b^T \lambda \quad (6.69)$$

$$\text{s.t. } \lambda_i \geq 0, \quad i \in I \quad (6.70)$$

下面我们来计算对偶间隙 ($y = -g + A^T \lambda$):

$$f(x) - \theta(\lambda) = \lambda^T(Ax - b) + \frac{1}{2}(x^T Gx + y^T G^{-1}y + 2x^T y) \quad (6.71)$$

其中当 $x \in D, \lambda \in K$ 时, $\lambda^T(Ax - b) \geq 0$, 因此对偶间隙非负. 可以验证, 对偶间隙为 0 当且仅当

$$\lambda_2^T(Ax_2 - b_2) = 0$$

且

$$A^T \lambda = Gx + g$$

这恰好就是原优化问题对应的 KKT 条件! 对偶理论主要用于线性规划和二次规划.

7 可行方向法

在前面的章节我们已经讨论过约束优化问题的基本理论: KKT 条件. 在本节我们讨论求解约束优化问题的基本算法. 有一类简单的罚函数方法, 它通过增加罚函数将约束问题转化为无约束问题. 例如, 对于等式约束问题

$$\begin{aligned} & \min f(x) \\ & \text{s.t. } c_i(x) = 0, i \in E \end{aligned}$$

则相应的罚函数为

$$p(x, \sigma) = f(x) + \sigma \sum_{i \in E} c_i^2(x) \quad (7.1)$$

当 $\sigma \rightarrow +\infty$ 时, $p(x, \sigma)$ 的极小点收敛到约束优化问题的极小点.

7.1 可行方向法的一般性质

可行方向法的基本思想是每一步迭代都必须在可行方向 $FD(x, D)$ 上进行. 考虑

$$\begin{aligned} & \min f(x) \\ & \text{s.t. } x \in D \end{aligned}$$

其中 D 是由等式约束和不等式约束围成的区域:

$$D = \left\{ x \in \mathbb{R}^n : \begin{array}{l} c_i(x) = 0, \quad i \in E \\ c_i(x) \geq 0, \quad i \in I \end{array} \right\}$$

在每一个迭代点 x_k , 我们希望找到一个可以使得函数值下降的可行方向, 即找到 $d \in \mathbb{R}^n$ 使得

$$d^T \nabla f(x_k) < 0, \quad d \in \text{FD}(x_k, D)$$

这样我们就可以在 d 的方向上进行线搜索, 并且使得函数值严格下降.

Algorithm 13: 可行方向法

输入: 定义域 D , 初始点 $x_0 \in D$

输出: 迭代点序列 $\{x_k\}$

for $k = 0, 1, \dots$ **do**

找到一个可行下降方向 $d_k \in \mathbb{R}^n$ 使得

$$d_k^T \nabla f(x_k) < 0, \quad d_k \in \text{FD}(x_k, D)$$

如果不存在, 则迭代停止;

在 d_k 上进行 (精确) 线搜索得到步长 α_k ;

更新迭代点 $x_{k+1} = x_k + \alpha_k d_k$;

end

在迭代中, 要求 $f(x_k)$ 的值严格下降. 值得注意的是, 这样的可行下降方向并非总是存在. 例如在非线性等式约束

$$c(x_1, x_2) = x_1^2 - x_2 = 0$$

上, 可行方向 $\text{FD}(x, D) = \emptyset$. 幸运的是, [对于凸优化问题, 除全局极小点外, 可行下降方向总是可以找到的.](#)

引理 7.1 (凸优化存在可行下降方向) 设定义域 D 是凸集, 且目标函数 $f(x)$ 在 D 上为凸函数, 则在 x 处存在可行下降方向当且仅当 x 不是局部极小点.

当 x 是局部极小点时, 它显然不存在可行下降方向, 否则沿着此方向函数值减少. 当 x 不存在可行下降方向时, 我们来验证它是局部极小点. 若否, 则存在 $\bar{x} \neq x$, 且 $f(\bar{x}) < f(x)$. 令方向 $d = \bar{x} - x$, 则必有 $d^T \nabla f(x) < 0$, 即沿着 d 的方向函数值严格下降. 但是 $d \in \text{FD}(x, D)$, 故 d 为可行下降方向, 矛盾!

7.2 变量消去法

变量消去法的基本思想是用非基本变量 x_N 表示基本变量 x_B . 对于线性约束的情形, 设约束条件为 $Ax = b$, 其中 $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$. 设

$$x = \begin{bmatrix} x_B \\ x_N \end{bmatrix}, \quad A = \begin{bmatrix} A_B & A_N \end{bmatrix}$$

且 $A_B \in \mathbb{R}^{m \times n}$ 非奇异, 则基本变量 x_B 可以表为

$$x_B = A_B^{-1}(b - A_N x_N) \quad (7.2)$$

因此原约束优化问题成为了关于 x_N 的无约束优化问题.

我们可以将上面的思想应用于一般的非线性约束中. 考虑等式约束

$$c(x) = \begin{bmatrix} c_1(x) \\ \vdots \\ c_m(x) \end{bmatrix} = 0$$

并且假设 x 可以分解为

$$x = \begin{bmatrix} x_B \\ x_N \end{bmatrix} \in \mathbb{R}^n$$

其中基本变量 $x_B \in \mathbb{R}^m$, 非基本变量 $x_N \in \mathbb{R}^{n-m}$, 则约束条件可以写为

$$c(x_B, x_N) = 0 \quad (7.3)$$

假设我们可以唯一地从中解出

$$x_B = \varphi(x_N) \quad (7.4)$$

则原约束问题转化为无约束问题

$$\tilde{f}(x_N) := f(\varphi(x_N), x_N)$$

的优化. 下面的任务是计算 $\tilde{f}(x_N)$ 关于 x_N 的梯度, 即所谓的**简约梯度**.

引理 7.2 (简约梯度) 对于无约束优化函数 $\tilde{f}(x_N) := f(\varphi(x_N), x_N)$, 它的简约梯度为

$$\tilde{g}(x_N) = \underbrace{\nabla_N f(x)}_{(n-m) \times 1} - \underbrace{\nabla_N c(x)}_{(n-m) \times m} \underbrace{(\nabla_B c(x))^{-1}}_{m \times m} \underbrace{\nabla_B f(x)}_{m \times 1} \in \mathbb{R}^{(n-m) \times 1} \quad (7.5)$$

在上面的表达式中, 约束条件 $c(x)$ 视为行向量, 而所有的梯度均为列向量. 首先考虑关于自由变量 x_N 的方程

$$c(\varphi(x_N), x_N) = 0$$

对 x_N 取导数, 有

$$(\nabla \varphi(x_N))^T \nabla_B c(x) + \nabla_N c(x) = 0 \implies (\nabla \varphi(x_N))^T = -\nabla_N c(x)(\nabla_B c(x))^{-1}$$

因此 $\tilde{f}(x_N)$ 的导数为

$$\begin{aligned}\tilde{g}(x_N) &= \nabla_N f(\varphi(x_N), x_N) \\ &= (\nabla \varphi(x_N))^T \nabla_N f(x) + \nabla_B f(x) \\ &= \nabla_N f(x) - \nabla_N c(x)(\nabla_B c(x))^{-1} \nabla_B f(x)\end{aligned}$$

得证. 因此, 下降方向可以选为

- 最速下降方向: $\tilde{d} = -\tilde{g}(x_N)$
- 拟 Newton 方向: $\tilde{d} = -B^{-1}\tilde{g}(x_N)$

在迭代点 x_N 处, 我们对目标函数 $\tilde{f}(x_N + \alpha d)$ 进行线搜索, 实际上是在对

$$f(\varphi(x_N + \alpha d), x_N + \alpha d)$$

进行线搜索. 因此, 每一步需要求解一个非线性方程

$$c(x_B, x_N + \alpha d) = 0$$

来得到 $x_N = \varphi(x_N + \alpha d)$.

除了直接做变量分离

$$x = \begin{bmatrix} x_B \\ x_N \end{bmatrix}$$

来进行变量消去外, 我们也可以考虑一般形式

$$x = \underbrace{Y}_{n \times m} x_y + \underbrace{Z}_{n \times (n-m)} x_z, \quad x_y \in \mathbb{R}^m, \quad x_z \in \mathbb{R}^{n-m}$$

其中 $AY \in \mathbb{R}^{m \times m}$ 非奇异, $AZ = 0$, 且 Z 的列线性无关. 因此可以得到

$$Ax = b = AYx_y \implies x_y = (AY)^{-1}b$$

因此变量 x 可以用自由变量 x_z 线性表出:

$$x = Y(AY)^{-1}b + Zx_z, \quad x_z \in \mathbb{R}^{n-m}$$

Y, Z 可以用下面的方法选取: 做 QR 分解

$$A^T P = \begin{bmatrix} Y & Z \end{bmatrix} \begin{bmatrix} R \\ 0 \end{bmatrix}$$

我们在本节考虑线性不等式约束其中 P 是任意可逆矩阵.

7.3 Rosen 投影梯度法

在本节我们考虑不等式约束优化问题

$$\begin{aligned} & \min f(x) \\ & \text{s.t. } Ax \geq b \end{aligned}$$

7.3.1 投影矩阵及其性质

定义 7.1 (投影矩阵) 矩阵 $P \in \mathbb{R}^{n \times n}$ 称为**投影矩阵**, 如果 $P^2 = P$, 称为**正交投影矩阵**, 如果 $P^2 = P$ 且 $P = P^T$. 对给定的矩阵 $P \in \mathbb{R}^{n \times n}$, 定义

$$R(P) = \{Px : x \in \mathbb{R}^n\}, \quad N(P) = \{x \in \mathbb{R}^n : Px = 0\}$$

分别为其**值域**和**零空间**.

例 8 设 $e \in \mathbb{R}^n$ 为任意单位向量, 则

$$P = I - ee^T \tag{7.6}$$

是正交投影矩阵.

定理 7.1 (正交投影的性质) 若 $P \in \mathbb{R}^{n \times n}$ 为正交投影矩阵, 则

- (i) P 半正定;
- (ii) $R(P)$ 与 $N(P)$ 互为正交补. 对任意 $x \in \mathbb{R}^n$, 存在唯一的 $p \in R(P)$ 和 $q \in N(P)$ 使得

$$x = p + q$$

- (iii) $I - P$ 也是正交投影, 且 $R(I - P) = N(P)$, $N(I - P) = R(P)$.

(i) 由于 $P = P^T$, 故 P 是一个对称矩阵. 由于

$$x^T Px = \|Px\|^2$$

故 P 半正定.

(ii) 先证明 $R(P)$ 与 $N(P)$ 相互正交. 任取 $p \in R(P)$ 和 $q \in N(P)$, 有

$$p = Pz, \quad Pq = 0$$

因此

$$p^T q = z^T Pq = 0$$

故 $R(P)$ 和 $N(P)$ 正交. 由于

$$\dim R(P) = \text{rank}(P), \quad \dim N(P) = n - \text{rank}(P)$$

故 $\dim R(P) + \dim N(P) = n$, 从而 $R(P)$ 与 $N(P)$ 互为正交补.

(iii) 先证 $R(I - P) = N(P)$. 任取 $x \in \mathbb{R}^n$, 有

$$(I - P)x = x - Px \in N(P) \implies R(I - P) \subset N(P)$$

任取 $z \in N(P)$, 有

$$z = (I - P)z \in R(I - P) \implies N(P) \subset R(I - P)$$

因此 $R(I - P) = N(P)$. 取正交补得到 $N(I - P) = R(P)$. 由于 P 是半正定的, 可以得到

推论 7.1 (投影下降方向) 设 $g \in \mathbb{R}^n$ 是迭代点 x 处的梯度, 则

$$d = -Pg$$

满足 $g^T d \leq 0$.

根据以上讨论, 正交投影矩阵 P 的作用可以看作是在 $R(P)$ 上的正交投影.

引理 7.3 (零空间正交投影) 设 $A \in \mathbb{R}^{q \times n}$ 且 A 为行满秩矩阵, 则

$$P = I - A^T(AA^T)^{-1}A \tag{7.7}$$

是从 \mathbb{R}^n 在 $N(A)$ 上的正交投影.

给定 $x \in \mathbb{R}^n$, 我们计算 x 在 $N(A)$ 上的正交投影. 它可转化为约束优化问题

$$\begin{aligned} & \min_z \frac{1}{2} \|z - x\|^2 \\ & \text{s.t. } Az = 0 \end{aligned}$$

其中 $Az = 0$ 等价于 $z \in N(A)$, 而 $\|z - x\|^2$ 的最小值刻画了投影的性质. 由于此问题为凸优化问题, 因此极小点等价于 KKT 点. 该问题的 Lagrange 函数为

$$L(z, \lambda) = \frac{1}{2} \|z - x\|^2 - \lambda^T Az$$

在 KKT 点处

$$\frac{\partial L}{\partial z} = z - x - A^T \lambda = 0$$

由于 $Az = 0$, 故

$$A(z - x) = AA^T\lambda \implies \lambda = -(AA^T)^{-1}Ax$$

因此

$$z = x + A^T\lambda = x - A^T(AA^T)^{-1}Ax = Px$$

故 $Px = z$, 即 P 是 $N(A)$ 上的正交投影.

7.3.2 投影梯度矩阵构造可行下降方向

在不等式约束优化问题中, 投影矩阵起到重要的作用:

定理 7.2 (投影可行下降方向 I) 设 $\bar{x} \in D$,

(1) 对任何投影矩阵 P , 若 $Pg(\bar{x}) \neq 0$, 则

$$\bar{d} = -Pg(\bar{x})$$

是 \bar{x} 处的下降方向.

(2) 在不等式约束条件下, 设 $A_q \in \mathbb{R}^{q \times n}$ 是由有效约束对应的行向量构成的矩阵, 且设 A_q 是行满秩的, 则

$$P_q = I - A_q^T(A_q A_q^T)^{-1}A_q \quad (7.8)$$

为正交投影矩阵, 且 $\bar{d} = -P_q g(\bar{x})$ 为可行下降方向.

关于上述定理我们有以下评注:

1. 在沿着下降方向 \bar{d} 时, 起作用约束条件没有被破坏, 因为 $\bar{d} \in N(A_q)$. 因此, 算法适用于在给定的起作用约束条件下求 $f(x)$ 的最小值.
2. 算法有一个重要的应用条件: $P_q g(\bar{x}) \neq 0$. 如果此条件不成立, 则说明 $P_q g(\bar{x}) = 0$, 因此

$$g(\bar{x}) = A_q^T(A_q A_q^T)^{-1}A_q g(\bar{x}) \quad (7.9)$$

若我们定义

$$\lambda = (A_q A_q^T)^{-1}A_q g(\bar{x})$$

则上述等式可以改写为

$$g(\bar{x}) = A_q^T \lambda = \sum_{i=1}^q \lambda_i a_i \quad (7.10)$$

其中 $a_i \in \mathbb{R}^n$ 是 A_q 的第 i 行, 即 $g(\bar{x})$ 是 A_q 的行向量的线性组合! 这恰好对应于我们熟知的 KKT 条件.

3. 在 $g(\bar{x})$ 的展开 (7.10) 中, 注意 $a_i, i = 1, \dots, q$ 是线性无关的, 因为 A_q 是行满秩的. 因此, 展开式中的系数 λ_i 是唯一的.
4. 可以直接验证 $P = I - A^T(AA^T)^{-1}A$ 满足 $AP = PA^T = 0$.

定理 7.3 (投影可行下降方向 II) 设 $\bar{x} \in D$ 且 $P_q g(\bar{x}) = 0$. 定义

$$\lambda = (A_q A_q^T)^{-1} A_q g(\bar{x}) \in \mathbb{R}^q \quad (7.11)$$

则有

- (1) 若 $\lambda \geq 0$, 则 \bar{x} 为 KKT 点;
- (2) 若 $\lambda_i < 0$, 则从约束条件中去掉 i 得到 $A_{q-1} \in \mathbb{R}^{(q-1) \times n}$, 则投影矩阵

$$P_{q-1} = I - A_{q-1}^T (A_{q-1} A_{q-1}^T)^{-1} A_{q-1} \quad (7.12)$$

使得 $\bar{d} = -P_{q-1}g(\bar{x})$ 为可行下降方向.

为简便起见, 假定 $i = q$, 即第 q 个约束被去除了. 设

$$A_q = \begin{bmatrix} A_{q-1} \\ a_q^T \end{bmatrix} \in \begin{bmatrix} \mathbb{R}^{(q-1) \times n} \\ \mathbb{R}^{1 \times n} \end{bmatrix}, \quad \lambda = \begin{bmatrix} \mu \\ \lambda_q \end{bmatrix} \in \begin{bmatrix} \mathbb{R}^{q-1} \\ \mathbb{R} \end{bmatrix}$$

则由 $P_q g(\bar{x}) = 0$ 可知

$$g(\bar{x}) = A_{q-1}^T \mu + \lambda_q a_q \quad (7.13)$$

因此方向 $\bar{d} = -P_{q-1}g(\bar{x})$ 可以表示为

$$\bar{d} = -\lambda_q P_{q-1} a_q \quad (7.14)$$

为了证明 \bar{d} 是可行下降方向, 需要

1. \bar{d} 是可行方向. 由于只有 q 一个约束条件被破坏, 所以只需要

$$a_q^T \bar{d} \geq 0 \iff \lambda_q a_q^T P_{q-1} a_q \leq 0 \quad (7.15)$$

由于 $\lambda_q \geq 0$, P_{q-1} 是半正定的, 上式显然成立.

2. \bar{d} 是下降方向, 即证明 $P_{q-1}g(\bar{x}) \neq 0$. 若 $P_{q-1}g(\bar{x}) = 0$, 则 \bar{g} 是 A_{q-1} 的行向量的线性组合, 这与唯一展开 (7.13) 矛盾!

因此我们得到如下的求解线性不等式约束问题

$$\begin{aligned} & \min f(x) \\ & \text{s.t. } Ax \geq b \end{aligned}$$

的投影梯度算法:

Algorithm 14: 投影梯度法 (线性不等式约束)

```

for  $k = 0, 1, \dots$  do
    确定有效约束  $A_q \in \mathbb{R}^{q \times n}$ 
    计算正交投影矩阵  $P_q \in \mathbb{R}^{n \times n}$ 
    if  $P_q g(x_k) \neq 0$  then
        (投影可行下降方向 I: 给定约束下的优化)
        取可行下降方向  $d_k = -P_q g(x_k)$ 
    else
        (投影可行下降方向 II: 减少一个约束条件)
        计算 Lagrange 乘子  $\lambda = (A_q A_q^T)^{-1} A_q g(x_k) \in \mathbb{R}^q$ 
        if  $\lambda \geq 0$  then
             $x_k$  是 KKT 点
            return
        else
            设下标  $i$  使得  $\lambda_i < 0$ 
            从有效约束  $A_q$  中去掉第  $i$  行得到  $A_{q-1} \in \mathbb{R}^{(q-1) \times n}$ 
            计算正交投影矩阵  $P_{q-1} \in \mathbb{R}^{n \times n}$ 
            取可行下降方向  $d_k = -P_{q-1} g(x_k)$ 
        end
    end
    在下降方向  $d_k$  上进行线搜索得到步长  $\alpha_k$ 
     $x_{k+1} = x_k + \alpha_k d_k$ 
end

```

7.4 Zoutendijk 可行方向

考虑含有等式约束和不等式约束的优化问题

$$\begin{aligned} & \min f(x) \\ \text{s.t. } & a_i^T x = b_i, \quad i \in E \\ & a_i^T x \geq b_i, \quad i \in I \end{aligned}$$

Zoutendijk 子问题由下给出:

定义 7.2 (Zoutendijk 子问题) 在给定的迭代点 x_k 处, 考虑线性规划问题

$$\begin{aligned} & \min g_k^T d \\ \text{s.t. } & A_E d = 0 \quad (i \in E) \\ & A_{I_k} d \geq 0 \quad (i \in I(x_k)) \\ & \|d_k\|_\infty \leq 1 \end{aligned}$$

Motzkin 定理是 Farkas 引理的一个推广.

引理 7.4 (Motzkin 定理) 设 $m_1, m_2 \geq 0, m_3 > 0$ 为整数. 再设 $A_1 \in \mathbb{R}^{m_1 \times n}, A_2 \in \mathbb{R}^{m_2 \times n}, \mathbb{R}^{m_3 \times n}$, 则下面的两个线性系统中有且仅有一个有解:

$$A_1 x = 0, \quad A_2 x \geq 0, \quad A_3 x > 0 \tag{7.16}$$

$$A_1^T a_1 + A_2^T a_2 + A_3^T a_3 = 0, \quad a_2 \geq 0, \quad a_3 \neq 0 \tag{7.17}$$

利用上述定理可以给出 Zoutendijk 子问题的可解性:

定理 7.4 设 $\bar{x} \in D$, 则 \bar{x} 是极小点当且仅当 Zoutendijk 子问题的最优值为 0,