

# 1 定义

## 1. 梯度

若  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  在点  $\vec{x}_0 = (x_1, x_2, \dots, x_n)$  处可微, 即  $f(\vec{x})$  在该点关于各变量的一阶偏导数存在, 则  $f(\vec{x})$  的  $n$  个偏导数构成的列向量

$$\left( \left. \frac{\partial f}{\partial x_1} \right|_{\vec{x}=\vec{x}_0}, \left. \frac{\partial f}{\partial x_2} \right|_{\vec{x}=\vec{x}_0}, \dots, \left. \frac{\partial f}{\partial x_n} \right|_{\vec{x}=\vec{x}_0} \right)^T$$

称为  $f(\vec{x})$  在点  $\vec{x}_0$  处的梯度, 记为  $\nabla f(\vec{x})|_{\vec{x}=\vec{x}_0}$ .

## 2. Hesse 矩阵

对于  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , 矩阵

$$H(f(\vec{x})) = \begin{pmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_2 \partial x_1} & \cdots & \frac{\partial^2 f}{\partial x_n \partial x_1} \\ \frac{\partial^2 f}{\partial x_1 \partial x_2} & \frac{\partial^2 f}{\partial x_2^2} & \cdots & \frac{\partial^2 f}{\partial x_n \partial x_2} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_1 \partial x_n} & \frac{\partial^2 f}{\partial x_2 \partial x_n} & \cdots & \frac{\partial^2 f}{\partial x_n^2} \end{pmatrix}$$

称为  $f(\vec{x})$  的 Hesse 矩阵

## 3. 凸集

设  $S$  是  $\mathbb{R}^n$  中的一个集合。若对于任意两点  $\vec{x}_1, \vec{x}_2 \in S$  及每个实数  $\lambda \in [0, 1]$ , 有

$$\lambda \vec{x}_1 + (1 - \lambda) \vec{x}_2 \in S$$

则称  $S$  为凸集。  $\lambda \vec{x}_1 + (1 - \lambda) \vec{x}_2$  称为  $\vec{x}_1$  和  $\vec{x}_2$  的凸组合。

### Remark

线段与直线均为  $\mathbb{R}$  上的凸集。

对于由  $D = \{\vec{x} \mid f_i(\vec{x}) = 0, g_j(\vec{x}) \geq 0\}$  构成的集合, 若  $f_i(\vec{x})$  均为线性函数,  $g_j(\vec{x})$  均为凸函数, 则  $D$  为凸集。

## 4. 凸包

集合  $T \subset \mathbb{R}^n$  的凸包是指所有包含  $T$  的凸集的交集, 记为

$$\text{conv}T = \bigcap_{T \subset C} C$$

其中,  $C$  为凸集。

## 5. 凸函数

设  $S \subset \mathbb{R}^n$  为非空凸集, 函数  $f: S \rightarrow \mathbb{R}$ . 若  $\forall \vec{x}_1, \vec{x}_2 \in S$ , 和每一个  $\lambda \in (0, 1)$ , 都有

$$f(\lambda \vec{x}_1 + (1 - \lambda) \vec{x}_2) \leq \lambda f(\vec{x}_1) + (1 - \lambda) f(\vec{x}_2)$$

则称  $f$  是  $S$  上的凸函数。若上面的不等式对于  $\vec{x}_1 \neq \vec{x}_2$  严格成立, 则称  $f$  是  $S$  上的严格凸函数。

## 6. 上镜图

对于函数  $f: S \rightarrow \mathbb{R}$ , 称集合

$$\left\{ \begin{array}{l} \text{epi} f = \\ \{(x, y) \mid x \in S, y \in \mathbb{R}, y \geq f(x)\} \end{array} \right\}$$

为  $f$  的上镜图。

## 7. 驻点与鞍点

若  $f(\vec{x})$  在点  $\vec{x}^*$  处可微, 且  $\nabla f(\vec{x}^*) = 0$ , 则称  $\vec{x}^*$  为  $f$  的一个驻点。既不是极大点也不是极小点的驻点称为鞍点。

## 8. 共轭方向

设  $A$  是  $n \times n$  对称正定矩阵, 若  $\mathbb{R}^n$  中的两个方向  $\vec{d}^{(1)}$  和  $\vec{d}^{(2)}$  满足

$$\vec{d}^{(1)\top} A \vec{d}^{(2)} = 0$$

则称这两个方向关于  $A$  共轭。

## 9. 矩阵的内积

定义  $S^n$  为一组  $n \times n$  对称矩阵的集合。对于任意矩阵  $A, B \in S^n$ , 定义  $A$  与  $B$  的内积为

$$A \cdot B = \text{trace}(AB) = \sum_{i=1}^n \sum_{j=1}^n a_{ij} b_{ij}$$

## 2 定理

## 1. 凸集的性质

设  $S_1$  和  $S_2$  是  $\mathbb{R}^n$  中两个凸集,  $\beta$  是实数, 则

- $\beta S_1 = \{\beta \vec{x} \mid \vec{x} \in S_1\}$  是凸集
- $S_1 \cap S_2$  为凸集
- $S_1 + S_2 = \{\vec{x}_1 + \vec{x}_2 \mid \vec{x}_1 \in S_1, \vec{x}_2 \in S_2\}$  为凸集
- $S_1 - S_2 = \{\vec{x}_1 - \vec{x}_2 \mid \vec{x}_1 \in S_1, \vec{x}_2 \in S_2\}$  为凸集

## 2. 凸函数的性质

设  $S$  为  $\mathbb{R}^n$  的非空凸子集, 则  $f$  是凸函数当且仅当其上镜图是凸集。

## 3. 凸函数的判定定理

- 设  $S$  是  $\mathbb{R}^n$  中的非空开凸集,  $f: S \rightarrow \mathbb{R}$  是可微的函数, 则  $f$  是凸函数当且仅当  $\forall \vec{x}^* \in S$ , 有

$$f(\vec{x}) - f(\vec{x}^*) \geq \nabla f(\vec{x}^*) (\vec{x} - \vec{x}^*), \forall \vec{x} \in S$$

$f$  严格凸当且仅当  $\forall \vec{x}^* \in S$ , 有

$$f(\vec{x}) - f(\vec{x}^*) > \nabla f(\vec{x}^*) (\vec{x} - \vec{x}^*), \forall \vec{x} \in S, \vec{x} \neq \vec{x}^*$$

- 设  $S$  是  $\mathbb{R}^n$  中的非空开凸集,  $f: S \rightarrow \mathbb{R}$  是二次可微的函数, 则

- $f$  是凸函数当且仅当  $S$  上每一点的 Hesse 矩阵是半正定的

**Remark**

实对称矩阵  $A$  半正定当且仅当其特征值均非负。

- $f$  是严格凸函数当且仅当  $S$  上每一点的 Hesse 矩阵是正定的

**Remark**

实对称矩阵  $A$  正定当且仅当其特征值均正。

## 3 方法

### 3.1 无约束极值问题 (UNLP)

#### 3.1.1 定义

$$\min f(\vec{x}), \vec{x} \in \mathbb{R}^n$$

其中  $f$  是  $\mathbb{R}^n$  上的实值函数。

#### 3.1.2 极值条件

- 极小点的必要条件

设  $\vec{x}^*$  是问题 UNLP 的局部极小点。

- 若  $f$  在  $\vec{x}^*$  处可微, 则  $\nabla f(\vec{x}^*) = 0$ .
- 若  $f$  在  $\vec{x}^*$  处二次可微, 则  $\nabla f(\vec{x}^*) = 0$  且 Hesse 矩阵  $H(\vec{x}^*)$  半正定。

- 二阶充分条件

假设  $f$  在  $\vec{x}^*$  点二次可微, 若  $\nabla f(\vec{x}^*) = 0$  且 Hesse 矩阵  $H(\vec{x}^*)$  是正定的, 则  $\vec{x}^*$  是 UNLP 的一个严格局部极小点。

- 充要条件

假设  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  是可微的凸函数, 则  $\vec{x}^*$  是 UNLP 的全局最小点当且仅当  $\nabla f(\vec{x}^*) = 0$

#### 3.1.3 一维搜索

得到点  $\vec{x}^{(k)}$  后, 需要按某种规则确定一个方向  $\vec{d}^{(k)}$ , 再从  $\vec{x}^{(k)}$  出发, 沿方向  $\vec{d}^{(k)}$  在直线上求目标函数的极小点, 从而得到  $\vec{x}^{(k)}$  的后继点  $\vec{x}^{(k+1)}$ . 重复以上做法, 直至求得问题的解。这种方法称为一维搜索。

- 试探法

- 0.618 法

设  $f$  在  $[a, b]$  上单峰。

**step 1** 置初始区间  $[a_1, b_1]$  及精度要求  $L > 0$ . 计算试探点  $\lambda_1$  和  $\mu_1$ , 计算函数值  $f(\lambda_1)$  和  $f(\mu_1)$ . 计算公式是

$$\lambda_1 = a_1 + 0.382(b_1 - a_1)$$

$$\mu_1 = a_1 + 0.618(b_1 - a_1)$$

令  $k = 1$

**step 2** 若  $b_k - a_k < L$ , 则停止计算。否则, 当  $f(\lambda_k) > f(\mu_k)$  时, 转**step 3**; 当  $f(\lambda_k) \leq f(\mu_k)$  时, 转**step 4**。

**step 3** 置  $a_{k+1} = \lambda_k, b_{k+1} = b_k, \lambda_{k+1} = \mu_k$

$$\mu_{k+1} = a_{k+1} + 0.618(b_{k+1} - a_{k+1})$$

计算函数值  $f(\mu_{k+1})$ , 转**step 5**。

**step 4** 置  $a_{k+1} = a_k, b_{k+1} = \mu_k, \mu_{k+1} = \lambda_k$

$$\lambda_{k+1} = a_{k+1} + 0.382(b_{k+1} - a_{k+1})$$

计算函数值  $f(\lambda_{k+1})$ , 转**step 5**。

**step 5** 置  $k = k + 1$ , 返回**step 2**。

○ Fibonacci 法

设有数列  $\{F_k\}$ , 满足

$$* F_0 = F_1 = 1$$

$$* F_{k+1} = F_k + F_{k-1}$$

则称  $\{F\}$  为 Fibonacci 数列。

设  $f$  在  $[a, b]$  上单峰。

**step 1** 置初始区间  $[a_1, b_1]$  及精度要求  $L > 0$ . 求计算函数值的次数  $n$ , 使

$$F_n \geq \frac{b_1 - a_1}{L}$$

置辨别常数  $\delta > 0$ . 计算试探点  $\lambda_1$  和  $\mu_1$ , 计算函数值  $f(\lambda_1)$  和  $f(\mu_1)$ . 计算公式是

$$\lambda_1 = a_1 + \frac{F_{n-2}}{F_n}(b_1 - a_1)$$

$$\mu_1 = a_1 + \frac{F_{n-1}}{F_n}(b_1 - a_1)$$

令  $k = 1$

**step 2** 若  $f(\lambda_k) > f(\mu_k)$  时, 转**step 3**; 当  $f(\lambda_k) \leq f(\mu_k)$  时, 转**step 4**。

**step 3** 置  $a_{k+1} = \lambda_k, b_{k+1} = b_k, \lambda_{k+1} = \mu_k$

$$\mu_{k+1} = a_{k+1} + \frac{F_{n-k-1}}{F_{n-k}}(b_{k+1} - a_{k+1})$$

若  $k = n - 2$ , 则转**step 6**; 否则, 计算函数值  $f(\mu_{k+1})$ , 转**step 5**。

**step 4** 置  $a_{k+1} = a_k, b_{k+1} = \mu_k, \mu_{k+1} = \lambda_k$

$$\lambda_{k+1} = a_{k+1} + \frac{F_{n-k-2}}{F_{n-k}}(b_{k+1} - a_{k+1})$$

若  $k = n - 2$ , 则转**step 6**; 否则, 计算函数值  $f(\lambda_{k+1})$ , 转**step 5**。

**step 5** 置  $k = k + 1$ , 转**step 2**。

**step 6** 令  $\lambda_n = \lambda_{n-1}, \mu_n = \lambda_{n-1} + \delta$ , 计算  $f(\lambda_n)$  和  $f(\mu_n)$

若  $f(\lambda_n) > f(\mu_n)$ , 则令

$$a_n = \lambda_n, b_n = b_{n-1}$$

若  $f(\lambda_n) \leq f(\mu_n)$ , 则令

$$a_n = a_{n-1}, b_n = \lambda_n$$

停止计算, 最小值包含于  $[a_n, b_n]$ 。

- 最速下降法

最速下降法的迭代公式为

$$\vec{x}^{(k+1)} = \vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}$$

其中  $\vec{d}^{(k)}$  是从  $\vec{x}^{(k)}$  出发的搜索方向, 这里取在点  $\vec{x}^{(k)}$  处的最速下降方向, 即

$$\vec{d}^{(k)} = -\nabla f(\vec{x}^{(k)})$$

$\lambda_k$  是从  $\vec{x}^{(k)}$  出发沿方向  $\vec{d}^{(k)}$  进行一维搜索的步长, 即  $\lambda_k$  满足

$$f(\vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}) = \min_{\lambda \geq 0} f(\vec{x}^{(k)} + \lambda \vec{d}^{(k)})$$

**step 1** 给定初点  $\vec{x}^{(1)} \in \mathbb{R}^n$ , 允许误差  $\varepsilon > 0$ , 置  $k = 1$ .

**step 2** 计算搜索方向  $\vec{d}^{(k)} = -\nabla f(\vec{x}^{(k)})$

**step 3** 若  $\|\vec{d}^{(k)}\| \leq \varepsilon$ , 则停止计算; 否则, 从  $\vec{x}^{(k)}$  出发, 沿  $\vec{d}^{(k)}$  进行一维搜索, 求  $\lambda_k$ , 使

$$f(\vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}) = \min_{\lambda \geq 0} f(\vec{x}^{(k)} + \lambda \vec{d}^{(k)})$$

**step 4** 令  $\vec{x}^{(k+1)} = \vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}$ , 置  $k = k + 1$ , 转 **step 2**.

- Newton 法

对于函数  $f(\vec{x})$ , 记  $\nabla f(\vec{x})$  为  $f$  在  $\vec{x}$  处的梯度,  $\nabla^2 f(\vec{x})$  为在  $\vec{x}$  处的 Hesse 矩阵,  $\nabla^2 f(\vec{x})^{-1}$  为在  $\vec{x}$  处的 Hesse 矩阵的逆矩阵。则 Newton 法的迭代公式为

$$\vec{x}^{(k+1)} = \vec{x}^{(k)} - \nabla^2 f(\vec{x}^{(k)})^{-1} \nabla f(\vec{x}^{(k)})$$

- 阻尼 Newton 法

阻尼 Newton 法的迭代公式为

$$\vec{x}^{(k+1)} = \vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}$$

其中  $\vec{d}^{(k)} = -\nabla^2 f(\vec{x}^{(k)})^{-1} \nabla f(\vec{x}^{(k)})$  为 Newton 方向,  $\lambda_k$  是由一维搜索得到的步长, 即满足

$$f(\vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}) = \min_{\lambda \geq 0} f(\vec{x}^{(k)} + \lambda \vec{d}^{(k)})$$

**step 1** 给定初始点  $\vec{x}^{(1)}$ , 允许误差  $\varepsilon > 0$ , 置  $k = 1$ .

**step 2** 计算  $\nabla f(\vec{x}^{(k)})$ ,  $\nabla^2 f(\vec{x}^{(k)})^{-1}$

**step 3** 若  $\|\nabla f(\vec{x}^{(k)})\| < \varepsilon$ , 则停止迭代; 否则, 令

$$\vec{d}^{(k)} = -\nabla^2 f(\vec{x}^{(k)})^{-1} \nabla f(\vec{x}^{(k)})$$

**step 4** 从  $\vec{x}^{(k)}$  出发, 沿方向  $\vec{d}^{(k)}$  作一维搜索,

$$f(\vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}) = \min_{\lambda \geq 0} f(\vec{x}^{(k)} + \lambda \vec{d}^{(k)})$$

$$\text{令 } \vec{x}^{(k+1)} = \vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}$$

**step 5** 置  $k = k + 1$ , 转 **step 2**

- 修正 Newton 法

**step 1** 给定初始点  $\vec{x}^{(1)}$ , 允许误差  $\varepsilon > 0$ , 置  $k = 1$ .

**step 2** 计算  $\nabla f(\vec{x}^{(k)})$ ,  $\nabla^2 f(\vec{x}^{(k)})^{-1}$

**step 3** 若  $\|\nabla f(\vec{x}^{(k)})\| < \varepsilon$ , 则停止迭代; 否则, 置矩阵  $B_k = \nabla^2 f(\vec{x}^{(k)}) + E_k$ , 其中  $E_k$  为修正矩阵 (当  $\nabla^2 f(\vec{x}^{(k)})$  正定时, 它取 0), 令

$$\vec{d}^{(k)} = -B_k^{-1} \nabla f(\vec{x}^{(k)})$$

**step 4** 从  $\vec{x}^{(k)}$  出发, 沿方向  $\vec{d}^{(k)}$  作一维搜索,

$$f(\vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}) = \min_{\lambda \geq 0} f(\vec{x}^{(k)} + \lambda \vec{d}^{(k)})$$

$$\text{令 } \vec{x}^{(k+1)} = \vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}$$

**step 5** 置  $k = k + 1$ , 转 **step 2**

• 共轭梯度法

对于二次凸函数

$$f(\vec{x}) = \frac{1}{2} \vec{x}^T A \vec{x} + b^T \vec{x} + c$$

**step 1** 给定初始点  $\vec{x}^{(1)}$ , 置  $k = 1$

**step 2** 计算  $g_k = \nabla f(\vec{x}^{(k)})$ . 若  $\|g_k\| = 0$ , 停止迭代; 否则, 进行下一步

**step 3** 令

$$\vec{d}^{(k)} = -g_k + \beta_{k-1} \vec{d}^{(k-1)}$$

其中,

$$\beta_{k-1} = \begin{cases} 0 & k = 1 \\ \frac{\|g_k\|^2}{\|g_{k-1}\|^2} & k \geq 2 \end{cases}$$

**step 4**

$$\lambda_k = -\frac{g_k^T \vec{d}^{(k)}}{\vec{d}^{(k)T} A \vec{d}^{(k)}}$$

$$\text{令 } \vec{x}^{(k+1)} = \vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}$$

**step 5** 若  $k = n$ , 则停止迭代; 否则, 置  $k = k + 1$ , 转 **step 2**

• DFP 算法

**step 1** 给定初始点  $\vec{x}^{(1)} \in \mathbb{R}^n$ , 允许误差  $\varepsilon > 0$

**step 2** 置  $H_1 = I_n$ , 计算出在  $\vec{x}^{(1)}$  处的梯度

$$g_1 = \nabla f(\vec{x}^{(1)})$$

置  $k = 1$

**step 3** 令  $\vec{d}^{(k)} = -H_k g_k$

**step 4** 从  $\vec{x}^{(k)}$  出发, 沿方向  $\vec{d}^{(k)}$  作一维搜索,

$$f(\vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}) = \min_{\lambda \geq 0} f(\vec{x}^{(k)} + \lambda \vec{d}^{(k)})$$

$$\text{令 } \vec{x}^{(k+1)} = \vec{x}^{(k)} + \lambda_k \vec{d}^{(k)}$$

**step 5** 检验是否满足收敛准则, 若

$$\|\nabla f(\vec{x}^{(k+1)})\| \leq \varepsilon$$

则停止迭代, 得到点  $\vec{x}^{(k+1)}$ ; 否则, 进行 **step 6**

**step 6** 若  $k = n$ , 则令  $\vec{x}^{(1)} = \vec{x}^{(k+1)}$ , 返回**step 2**; 否则, 进行**step 7**

**step 7** 令  $g_{k+1} = \nabla f(\vec{x}^{(k+1)})$ ,  $\vec{p}^{(k)} = \vec{x}^{(k+1)} - \vec{x}^{(k)}$ ,  $\vec{q}^{(k)} = \vec{g}_{k+1} - \vec{g}_k$

$$H_{k+1} = H_k + \frac{\vec{p}^{(k)} \vec{p}^{(k)\top}}{\vec{p}^{(k)\top} \vec{q}^{(k)}} - \frac{H_k \vec{q}^{(k)} \vec{q}^{(k)\top} H_k}{\vec{q}^{(k)\top} H_k \vec{q}^{(k)}}$$

置  $k = k + 1$ , 返回**step 3**

## 3.2 有约束极值问题

### 3.2.1 定义

$$\begin{aligned} \min \quad & f(\vec{x}) \\ \text{s.t.} \quad & a_i(\vec{x}) = 0, i = 1, 2, \dots, p \\ & c_j(\vec{x}) \geq 0, j = 1, 2, \dots, q \end{aligned}$$

其中  $a_i(\vec{x}) = 0$  称为等式约束,  $c_j(\vec{x}) \geq 0$  称为不等式约束。

其对应的 Lagrange 函数为

$$L(\vec{x}, \vec{\lambda}, \vec{\mu}) = f(\vec{x}) - \sum_{i=1}^p \lambda_i a_i(\vec{x}) - \sum_{j=1}^q \mu_j c_j(\vec{x})$$

### 3.2.2 极值条件

- KKT 条件

若  $\vec{x}^*$  是极小点, 则

- $a_i(\vec{x}^*) = 0, i = 1, 2, \dots, p$
- $c_j(\vec{x}^*) \geq 0, j = 1, 2, \dots, q$
- $\nabla f(\vec{x}^*) = \sum_{i=1}^p \lambda_i^* \nabla a_i(\vec{x}^*) + \sum_{j=1}^q \mu_j^* \nabla c_j(\vec{x}^*)$
- $\mu_j^* c_j(\vec{x}^*) = 0, j = 1, 2, \dots, q$
- $\mu_j^* \geq 0, j = 1, 2, \dots, q$

## 3.3 凸问题

### 3.3.1 定义

$$\begin{aligned} \min \quad & f(\vec{x}) \\ \text{s.t.} \quad & a_i(\vec{x}) = 0, i = 1, 2, \dots, p \\ & c_j(\vec{x}) \geq 0, j = 1, 2, \dots, q \end{aligned}$$

其中,  $f$  为凸函数,  $D = \{\vec{x} \mid a_i(\vec{x}) = 0, c_j(\vec{x}) \geq 0\}$  是凸集。

### 3.3.2 极值条件

- 满足 KKT 条件的点一定为其极值点。

- Wolfe 对偶定理

对于一个凸问题，定义其 Wolfe 对偶问题为

$$\begin{aligned} \max \quad & L(\vec{x}) \\ \text{s.t.} \quad & \nabla_{\vec{x}} L = 0 \\ & \mu_i \geq 0 \end{aligned}$$

其中， $L$  为  $f$  的 Lagrange 函数。

则此两个问题的极值点相同。

## 3.4 线性规划问题

### 3.4.1 定义

$$\begin{aligned} \min \quad & \vec{c}^T \vec{x} \\ \text{s.t.} \quad & A\vec{x} = \vec{b} \\ & \vec{x} \geq \vec{0} \end{aligned}$$

### 3.4.2 极值条件

- 原始对偶内点法

设原问题的 Wolfe 对偶问题为

$$\begin{aligned} \max \quad & L(\vec{x}) \\ \text{s.t.} \quad & \nabla_{\vec{x}} L = 0 \\ & \mu_i > 0 \\ & \vec{x} > 0 \end{aligned}$$

其 KKT 条件为

$$\begin{aligned} A^T \lambda + \mu &= c \\ A\vec{x} &= \vec{b} \\ X\mu &= \tau e \end{aligned}$$

其中  $\tau > 0, e = [1, 1, \dots, 1]^T$

**step 1** 在可行域里面找到一个初始点  $\vec{w}_0 = \{\vec{x}_0, \vec{\lambda}_0, \vec{\mu}_0\}$

**step 2** 在第  $k$  次迭代中，对 KKT 条件增加一阶扰动  $\tau = \tau_k$ ，获得增量  $\delta_w$  来更新下一个点  $\vec{w}_k$ 。解方程：

$$\begin{cases} A\delta_x = 0 \\ A\delta_\lambda + \delta_\mu = 0 \\ M\delta_x + X\delta_\mu = \tau_{k+1} - X\delta_\mu\delta_k \end{cases}$$

其中  $M = \text{diag}\{(\mu_k)_1, (\mu_k)_2, \dots, (\mu_k)_n\}$



**step 3** 在下一轮迭代中的初始点更新为  $\overrightarrow{w}_{k+1} = \{\overrightarrow{x}_k + \overrightarrow{\delta}_x, \overrightarrow{\lambda}_k + \overrightarrow{\delta}_\lambda, \overrightarrow{\mu}_k + \overrightarrow{\delta}_\mu\}$

**step 4** 在 KKT 条件中  $\tau$  更新为更加靠近中心路径的  $\tau_{k+1}$ , 方法为

$$\tau_{k+1} = \frac{\mu_k^T \overrightarrow{x}_k}{n + \rho}$$

其中  $\rho > \sqrt{n}$

**step 5** 为了获得更好的  $w_{k+1}$ , 可以采用一维搜索的方法

$$\overrightarrow{w}_{k+1} = \overrightarrow{w}_k + \alpha_k \overrightarrow{\delta}_w$$

• 对偶形式

$$\begin{aligned} \max \quad & h(\overrightarrow{y}) = b^T \overrightarrow{y} \\ \text{s.t.} \quad & c - A^T \overrightarrow{y} \geq 0 \end{aligned}$$

### 3.5 二次规划问题

#### 3.5.1 定义

$$\begin{aligned} \min \quad & \overrightarrow{x}^T H \overrightarrow{x} + \overrightarrow{p}^T \overrightarrow{x} \\ \text{s.t.} \quad & \overrightarrow{a}_i^T \overrightarrow{x} = \overrightarrow{b}_i, i = 1, 2, \dots, p \\ & \overrightarrow{c}_i^T \overrightarrow{x} = \overrightarrow{d}_i, i = 1, 2, \dots, q \end{aligned}$$

考虑等式约束的二次规划问题

$$\begin{aligned} \min \quad & f(\overrightarrow{x}) = \overrightarrow{x}^T H \overrightarrow{x} + \overrightarrow{p}^T \overrightarrow{x} \\ \text{s.t.} \quad & A \overrightarrow{x} = \overrightarrow{b} \end{aligned}$$

称为等式约束二次规划问题

#### 3.5.2 极值条件

• Lagrange 法  
Lagrange 函数

$$L = f(\overrightarrow{x}) - \overrightarrow{\lambda}^T (A \overrightarrow{x} - \overrightarrow{b})$$

求其 Lagrange 矩阵

$$\begin{pmatrix} H & -A \\ -A & 0 \end{pmatrix} \begin{pmatrix} \overrightarrow{x} \\ \overrightarrow{\lambda} \end{pmatrix} = \begin{pmatrix} -\overrightarrow{p} \\ -\overrightarrow{q} \end{pmatrix}$$

### 3.6 半定问题

#### 3.6.1 定义

原始 SDP 问题为

$$\begin{aligned} \min \quad & C \cdot X \\ \text{s.t.} \quad & A_i \cdot X = b_i, i = 1, 2, \dots, p \\ & X \geq 0 \end{aligned}$$

### 3.6.2 对偶形式

$$\begin{aligned} \max \quad & b^T \vec{y} \\ \text{s.t.} \quad & C - \sum_{i=1}^p y_i A_i \geq 0 \end{aligned}$$