

最优化理论与方法复习

基础与前沿研究院

谭兵

2018 年 12 月 28 日

1 最优化问题与数学基础

1.1 数学基础

$$\text{梯度: } L = \left(\frac{\partial f(\mathbf{X}^0)}{\partial x_1}, \frac{\partial f(\mathbf{X}^0)}{\partial x_2}, \dots, \frac{\partial f(\mathbf{X}^0)}{\partial x_n} \right)^T$$

梯度方向是函数值上升的方向, 负梯度方向是函数值下降的方向, 沿梯度方向函数具有最快的变化率。

常见梯度

- $\nabla(\mathbf{b}^T \mathbf{X}) = \mathbf{b}, \mathbf{b} = (b_1, b_2, \dots, b_n)^T \in \mathbf{R}^n$
- $\nabla(\mathbf{X}^T \mathbf{A} \mathbf{X}) = \mathbf{A} \mathbf{X} + \mathbf{A}^T \mathbf{X}$

【注】: 梯度法则: 如果 $f(x): \mathbf{R}^m \rightarrow \mathbf{R}^p$, 则梯度 $\nabla f(x) \in \mathbf{R}^{m \times p}$.

Example 1. $f(x) = \|x - a\|_2, a \in \mathbf{R}^2$, 那么 $\nabla f(x) = \frac{x-a}{\|x-a\|_2}$.

Definition 1 (方向导数). 如果函数 $z = f(x, y)$ 在点 $P(x, y)$ 是可微分的, 那么函数在该点沿任一方向的方向导数都存在, 且有

$$\frac{\partial f}{\partial l} = \frac{\partial f}{\partial x} \cos \varphi + \frac{\partial f}{\partial y} \sin \varphi$$

其中 φ 为 x 轴到方向 l 的转角。

Example 2. 求函数 $z = xe^{2y}$ 在点 $P(1, 0)$ 处沿从点 $P(1, 0)$ 到点 $Q(2, -1)$ 方向的方向导数。

Solution. 解: 这里方向 l 即为向量 $\overrightarrow{PQ} = \{1, -1\}$, 因此 x 轴到方向 l 的转角 $\varphi = -\frac{\pi}{4}$, 因为

$$\frac{\partial z}{\partial x} = e^{2y}, \quad \frac{\partial z}{\partial y} = 2xe^{2y}$$

所求方向导数

$$\frac{\partial z}{\partial l} = 1 \cdot \cos\left(-\frac{\pi}{4}\right) + 2 \cdot \sin\left(-\frac{\pi}{4}\right) = -\frac{\sqrt{2}}{2}$$

【注】: f 在方向 P 处的方向导数: $\frac{\partial f}{\partial P} = \frac{(\nabla f)^T P}{\|P\|}$.

Definition 2 (Hesse 矩阵).

$$\nabla^2 f(\mathbf{X}) = \begin{pmatrix} \frac{\partial^2 f(\mathbf{X})}{\partial x_1^2} & \frac{\partial^2 f(\mathbf{X})}{\partial x_2 \partial x_1} \\ \frac{\partial^2 f(\mathbf{X})}{\partial x_1 \partial x_2} & \frac{\partial^2 f(\mathbf{X})}{\partial x_2^2} \end{pmatrix}$$

【注】: 设 $\phi(t) = f(\mathbf{X}^0 + t\mathbf{P})$, 则

$$\phi'(t) = \nabla f(\mathbf{X}^0 + t\mathbf{P})^T \mathbf{P}, \quad \phi''(t) = \mathbf{P}^T \nabla^2 f(\mathbf{X}^0 + t\mathbf{P}) \mathbf{P}$$

Theorem 1 (多元函数的 Taylor 展开).

$$f(\mathbf{X}) = f(\mathbf{X}^0) + \nabla f(\mathbf{X}^0)^T (\mathbf{X} - \mathbf{X}^0) + \frac{1}{2} (\mathbf{X} - \mathbf{X}^0)^T \nabla^2 f(\mathbf{X}) (\mathbf{X} - \mathbf{X}^0) + o(\|\mathbf{X} - \mathbf{X}^0\|^2)$$

最优性条件

- (一阶必要条件): 若 \mathbf{X}^* 是 $f(\mathbf{X})$ 的局部极小点, 则 $\nabla f(\mathbf{X}^*) = 0$
- (二阶必要条件): 若 \mathbf{X}^* 是 $f(\mathbf{X})$ 的局部极小点, 则 $\nabla^2 f(\mathbf{X}^*)$ 半正定。
- (二阶充分条件): 若 $\nabla f(\mathbf{X}^*) = 0$, 且 $\nabla^2 f(\mathbf{X}^*)$ 是正定矩阵, 则 \mathbf{X}^* 是 $f(\mathbf{X})$ 的严格局部极小点。

Example 3. 证明, 若 \mathbf{X}^* 是 $f(\mathbf{X})$ 的局部极小点, 则 $\nabla f(\mathbf{X}^*) = 0$

证明. 令 $\mathbf{X} = \mathbf{X}^* - \alpha \nabla f(\mathbf{X}^*)$

利用多元函数的一阶 Taylor 展开

$$\begin{aligned} f(\mathbf{X}) &= f(\mathbf{X}^*) - \alpha \nabla f(\mathbf{X}^*)^T \nabla f(\mathbf{X}^*) \\ &= f(\mathbf{X}^*) - \alpha \|\nabla f(\mathbf{X}^*)\|_2^2 \end{aligned}$$

由于 \mathbf{X}^* 是局部极小值, 那么

$$-\alpha \|\nabla f(\mathbf{X}^*)\|_2^2 = f(\mathbf{X}) - f(\mathbf{X}^*) \geq 0$$

因此, $\|\nabla f(\mathbf{X}^*)\|_2^2 = 0$, 即 $\nabla f(\mathbf{X}^*) = 0$ □

Example 4. 证明, 若 x^* 是凸优化中的局部极小点, 则 x^* 是全局极小点。

证明. (反证法) 若 x^* 不是全局极小点, 则存在 \bar{x} 是全局极小点. 使得 $f(\bar{x}) \leq f(x^*)$.

令 $z = \alpha \bar{x} + (1 - \alpha)x^*$, $\alpha \in (0, 1)$

所以,

$$\begin{aligned} f(z) &= f(\alpha \bar{x} + (1 - \alpha)x^*) \\ &\leq \alpha f(\bar{x}) + (1 - \alpha)f(x^*) \\ &\leq \alpha f(x^*) + (1 - \alpha)f(x^*) \\ &\leq f(x^*) \end{aligned}$$

当 $\alpha \rightarrow 0$, $z = \alpha \bar{x} + (1 - \alpha)x^* \in N(x^*)$, 其中 $N(x^*)$ 表示 x^* 的某个邻域。

即在 x^* 的某个局部邻域 $N(x^*)$ 中有 z , 使得 $f(z) \leq f(x^*)$, 这与 x^* 是局部极小点矛盾。

因此, x^* 是全局极小点。 □

1.2 凸集

Definition 3 (凸集). 若对任意的 $X^1, X^2 \in D$ 以及 $\alpha \in [0, 1]$, 都有 $\alpha X^1 + (1 - \alpha)X^2 \in D$, 则称 D 为凸集。

【注】: 几何直观上, 若集合 D 中任意两点的连线仍在 D 中, 则称 D 为凸集。

Example 5. $D = \{X | AX \leq b, X \in R^n, A \in R^{m \times n}\}$ 是凸集。

Example 6. 若 A, B 是 R^n 中的凸集, 则 $A \cap B, A + B, A - B$ 也是凸集, 但 $A \cup B$ 一般不是凸集。

Example 7. $C = \{x \in R_+^2 | x_1 x_2 \geq 1\}$, 则 C 是凸集。

1.3 凸函数

Definition 4 (凸函数). 设 $f: D \subset R^n \rightarrow R$, D 是凸集, 若对任意的 $X^1, X^2 \in D$, 以及 $\alpha \in (0, 1)$, 都有

$$f(\alpha X^1 + (1 - \alpha)X^2) \leq \alpha f(X^1) + (1 - \alpha)f(X^2)$$

则称 $f(X)$ 为 D 上的凸函数。

【注】: 从几何上看, 曲线上任意两点的连线在相应弧段的上方, 即弦在弧之上。

Example 8. 判断 $f(x) = \frac{1}{x^2}$ 是否为凸函数, 答案, 否, 因为其定义域 $D = R - \{0\}$ 不是凸集。

【注】: 判断是否为凸函数, 首先应判断定义域是否为凸集。

Example 9. $f(x_1, x_2) = \frac{x_1^2}{x_2}$, $x_2 > 0$, 根据 Hesse 矩阵的各阶顺序主子式可以判断, 它是一个凸函数。

Example 10. $f(x) = \log(e^{x_1} + e^{x_2} + \dots + e^{x_n})$ 是凸函数。

Example 11. $f(x) = e^{x^T A x}$, 其中 A 是正定矩阵, 它是凸函数。

【注】: $f: R^n \rightarrow R^1$ 凸 (凹), $g: R^1 \rightarrow R^1$ 凸增 (凸减), 则 $h(x) = g(f(x))$ 是凸函数。

Theorem 2. $f(X)$ 在 D 上是凸函数的充要条件是对任意的 $X^1, X^2 \in D$, 都有

$$f(X^2) \geq f(X^1) + \nabla f(X^1)^T (X^2 - X^1)$$

Theorem 3. $f(X)$ 在 D 上是凸函数的充要条件是 $\nabla^2 f(X)$ 是半正定矩阵。

【注】: 二阶矩阵判断是否是正定矩阵, 看顺序主子式均 ≥ 0 。

1.4 凸规划

$$\begin{aligned} & \min f(\mathbf{X}) \\ & s.t. \\ & g_i(\mathbf{X}) \geq 0 \quad (i = 1, 2, \dots, m) \\ & h_j(\mathbf{X}) = 0 \quad (j = 1, 2, \dots, p) \end{aligned}$$

若 $f(\mathbf{X})$ 与 $-g_i(\mathbf{X})$ 都是凸函数, $h_j(\mathbf{X})$ 是线性函数, 则称其为凸规划。

Theorem 4. \mathbf{X}^* 为上面问题的最优解的充要条件是, $\forall \mathbf{X} \in \mathbf{S}$, 有

$$(\mathbf{X} - \mathbf{X}^*)^T \nabla f(\mathbf{X}^*) \geq 0$$

证明. 充分性:

$$f(\mathbf{X}) \geq f(\mathbf{X}^*) + \nabla f(\mathbf{X}^*)^T (\mathbf{X} - \mathbf{X}^*) \geq f(\mathbf{X}^*)$$

必要性:

若存在 $\mathbf{X}^0 \in \mathbf{S}$, 使得 $(\mathbf{X}^0 - \mathbf{X}^*)^T \nabla f(\mathbf{X}^*) < 0$, 则

$$\begin{aligned} & f(\mathbf{X}^* + \alpha(\mathbf{X}^0 - \mathbf{X}^*)) - f(\mathbf{X}^*) \\ &= \alpha \nabla f(\mathbf{X}^*)^T (\mathbf{X}^0 - \mathbf{X}^*) + o(\alpha \|\mathbf{X}^0 - \mathbf{X}^*\|) \\ &= \alpha \left((\mathbf{X}^0 - \mathbf{X}^*)^T \nabla f(\mathbf{X}^*) + \frac{o(\alpha \|\mathbf{X}^0 - \mathbf{X}^*\|)}{\alpha} \right) \\ &\leq 0 \end{aligned}$$

这与 \mathbf{X}^* 为最优解矛盾。 □

2 线性规划与单纯形法

2.1 基本可行解

基本解: 令一些分量为 0, 解出其他分量;

基本可行解: 既是基本解, 又是可行解。

Example 12. 求

$$\begin{aligned} x_1 + x_2 + x_3 &= 2 \\ x_1 + 2x_2 + 4x_3 &= 6 \\ x_1, x_2, x_3 &\geq 0 \end{aligned}$$

的基本可行解

Solution.

$$\mathbf{X}^1 = (0, 1, 1)^T, \quad \mathbf{X}^2 = \left(\frac{2}{3}, 0, \frac{4}{3}\right)^T, \quad \mathbf{X}^3 = (-2, 4, 0)^T (\text{舍去, 不是可行解})$$

【注】: 线性规划的顶点集和基本可行解集等价。

2.2 线性规划标准型

线性规划标准型的矩阵形式：

$$\min f(\mathbf{X}) = \mathbf{C}^T \mathbf{X}$$

s.t.

$$\mathbf{A}\mathbf{X} = \mathbf{b}$$

$$\mathbf{X} \geq 0$$

$$\sum_{j=1}^n a_{pj}x_j + x_{n+p} = b_p \quad (x_{n+p} \geq 0 : \text{松弛变量})$$

$$\sum_{j=1}^n a_{qj}x_j - x_{n+q} = b_q \quad (x_{n+q} \geq 0 : \text{剩余变量})$$

$$\exists x_i \in \mathbf{R}, x_i = x_i^+ - x_i^- \quad (x_i^+, x_i^- \geq 0 : \text{自由变量})$$

Example 13. 将下面的规划化成标准型

$$\max f(\mathbf{X}) = x_1 - 2x_2 + 3x_3$$

s.t.

$$2x_1 - 7x_3 \leq 0$$

$$3x_1 + 2x_2 \geq 0$$

$$x_1 + x_2 + x_3 = 5$$

$$x_1, x_2 \geq 0, x_3 \in \mathbf{R}$$

Solution. 标准型为

$$\min f(\mathbf{X}) = -x_1 + 2x_2 - 3(x_3^+ - x_3^-)$$

s.t.

$$2x_1 - 7(x_3^+ - x_3^-) + x_4 = 0$$

$$3x_1 + 2x_2 - x_5 = 0$$

$$x_1 + x_2 + (x_3^+ - x_3^-) = 5$$

$$x_i \geq 0 (i = 1, 2, 4, 5), x_3^+ > 0, x_3^- > 0$$

2.3 使用表格形式的单纯形法

最小值问题（最大化问题）的表格型单纯形法求解步骤：

1. 最后一行： $z_k - c_k = \max \{z_j - c_j\}$ ($z_k - c_k = \min \{z_j - c_j\}$)

2. 选择对应的列作为主列

$$\frac{\bar{b}_r}{y_{rk}} = \min \left\{ \frac{\bar{b}_i}{y_{ik}} \mid y_{ik} > 0 \right\}$$

3. 选取交叉元素作为主元。

4. 直到所有判别数均 ≤ 0 时停止（直到所有判别数均 ≥ 0 时停止）

Example 14. 用单纯形法求解下列线性规划问题

$$\begin{aligned} \min f(\mathbf{X}) &= x_2 - 3x_3 + 2x_5 \\ \text{s.t.} \\ x_1 + 3x_2 - x_3 + 2x_5 &= 7 \\ -2x_2 + 4x_3 + x_4 &= 12 \\ -4x_2 + 3x_3 + 8x_5 + x_6 &= 10 \\ x_j &\geq 0, \quad j = 1, \dots, 6 \end{aligned}$$

Solution. 迭代过程如下

P_1	P_2	P_3	P_4	P_5	P_6	b
1	3	-1	0	2	0	7
0	-2	4	1	0	0	12
0	-4	3	0	8	1	10
0	-1	3	0	-2	0	0

P_1	P_2	P_3	P_4	P_5	P_6	b
1	$\frac{5}{2}$	0	$\frac{1}{4}$	2	0	10
0	$-\frac{1}{2}$	1	$\frac{1}{4}$	0	0	3
0	$-\frac{5}{2}$	0	$-\frac{3}{4}$	8	1	1
0	$\frac{1}{2}$	0	$-\frac{3}{4}$	-2	0	-9

P_1	P_2	P_3	P_4	P_5	P_6	b
$\frac{2}{5}$	1	0	$\frac{1}{10}$	$\frac{4}{5}$	0	4
$\frac{1}{5}$	0	1	$\frac{3}{10}$	$\frac{2}{5}$	0	5
1	0	0	$-\frac{1}{2}$	10	1	11
$-\frac{1}{5}$	0	0	$-\frac{4}{5}$	$-\frac{12}{5}$	0	-11

至此，所有判别数小于或等于零，故当前可行解为 $\mathbf{X}^* = (0, 4, 5, 0, 0, 11)^T$ ，最优值为 $f(\mathbf{X}^*) = -11$.

2.4 两阶段法

基本思想：转换为标准形式后，问题中不包含需要的 n 阶单位矩阵，因此需要引进人工变量，用单纯形法求解。

Example 15.

$$\begin{aligned} \min x_1 - x_2 \\ \text{s.t.} \\ -x_1 + 2x_2 + x_3 &\leq 2 \\ -4x_1 + 4x_2 - x_3 &= 4 \\ x_1 - x_3 &= 0 \\ x_i &\geq 0, i = 1 \sim 3 \end{aligned}$$

Solution. 引入人工变量 x_5, x_6 , 构造辅助线性规划

$$\begin{aligned} \min \quad & x_5 + x_6 \\ \text{s.t.} \quad & -x_1 + 2x_2 + x_3 + x_4 = 2 \\ & -4x_1 + 4x_2 - x_3 + x_5 = 4 \\ & x_1 - x_3 + x_6 = 0 \\ & x_i \geq 0, i = 1 \sim 6 \end{aligned}$$

第一阶段

用单纯形法求解过程如下, 极小化目标函数 $x_5 + x_6$

P_1	P_2	P_3	P_4	d_5	d_6	b
-1	2	1	1	0	0	2
-4	4	-1	0	1	0	4
1	0	-1	0	0	1	0
-3	4	-2	0	0	0	4
-1/2	1	1/2	1/2	0	0	1
-2	0	-3	-2	1	0	0
1	0	-1	0	0	1	0
-1	0	-4	-2	0	0	0

因为人工变量 x_5, x_6 是基变量, 所以应该替换出 (必须要使人工变量为非基变量)

P_1	P_2	P_3	P_4	d_5	d_6	b
0	1	0	1/2	0	1/2	1
0	0	-5	-2	1	2	0
1	0	-1	0	0	1	0
0	1	0	1/2	0	1/2	1
0	0	1	2/5	-1/5	-2/5	0
1	0	0	2/5	-1/5	3/5	0

第一阶段结束后, 修改最后的单纯形表, 去掉人工变量所在的列, 把最后的判别数行按照原来问题进行修正, 其他不变。

第二阶段

极小化目标函数 $x_1 - x_2$

P_1	P_2	P_3	P_4	b
0	1	0	1/2	1
0	0	1	2/5	0
1	0	0	2/5	0
0	0	0	-1/10	-1

所以 $X^* = (0, 1, 0)^T$, $f(X^*) = -1$.

【注】: 两阶段法的标准形非常重要, 需要满足右端项 $b \geq 0$, 且第一阶段的目标函数是加入的人工变量之和。第一阶段中, 基变量对应的判别数都为 0。

3 对偶线性规划

3.1 对称形式

原规划

$$(P) \quad \begin{aligned} & \min C^T \mathbf{X} \\ & s.t. \\ & \mathbf{A}\mathbf{X} \geq b \\ & \mathbf{X} \geq 0 \end{aligned}$$

对偶规划

$$(D) \quad \begin{aligned} & \max b^T \mathbf{W} \\ & \mathbf{A}^T \mathbf{W} \leq \mathbf{C} \\ & \mathbf{W} \geq 0 \end{aligned}$$

【注：】经验：对偶规划的系数好确定，无非就是需要确定变量和约束符号。口诀：变量符号 \rightarrow 看约束条件符号：小同大反；约束条件符号 \rightarrow 看变量符号：大同小反。

原（对偶）线性规划变换规则表

原规划（对偶规划）	对偶规划（原规划）
min	max
目标中系数	约束条件右端项
约束条件右端项	目标中系数
约束条件 \geq	变量 \geq
约束条件 \leq	变量 \leq
约束条件 $=$	变量无约束
变量 \geq	约束条件 \leq
变量 \leq	约束条件 \geq
变量无约束	约束条件 $=$

Example 16. 写出对偶线性规划

$$\begin{aligned} \min f(\mathbf{X}) &= 8x_1 + 6x_2 + 3x_3 + 6x_4 \\ s.t. \\ x_1 + 2x_2 + x_4 &= 3 \\ 3x_1 + x_2 + x_3 + x_4 &= 6 \\ x_j &\geq 0, j = 1, \dots, 4 \end{aligned}$$

Solution.

$$\begin{aligned} \max \quad & g(\mathbf{W}) = 3w_1 + 6w_2 + 2w_3 \\ \text{s.t.} \quad & \\ & w_1 + 3w_2 \leq 8 \\ & 2w_1 + w_2 \leq 6 \\ & w_2 + w_3 \geq 3 \\ & w_1 + w_2 + w_3 = 6 \\ & w_1 \geq 0, w_2 \leq 0, w_3 \in R \end{aligned}$$

3.2 一般问题的原始对偶理论

原始问题:

$$\begin{aligned} \min \quad & f(x) \\ \text{s.t.} \quad & \\ & h_i(x) = 0, \quad i = 1, 2, \dots, m \\ & g_j(x) \leq 0, \quad i = 1, 2, \dots, p \end{aligned}$$

Lagrange 函数

$$L(x, \lambda, \mu) = f(x) + \sum_{i=1}^m \lambda_i h_i(x) + \sum_{j=1}^p \mu_j g_j(x)$$

需要满足以下两个原则

$$L(x, \lambda, \mu) \leq f(x), \quad \mu \geq 0.$$

关于 x 极小化 $L(x, \lambda, \mu)$

$$q(\lambda, \mu) = \min_x L(x, \lambda, \mu)$$

对偶问题:

$$\begin{cases} \max & q(\lambda, \mu) \\ \text{s.t.} & \\ & \mu \geq 0 \end{cases}$$

3.3 互补松弛性质

3.3.1 对称形式的对偶

对称形式的对偶定义如下:

原问题

$$\begin{aligned} \min \quad & cx \\ \text{s.t.} \quad & Ax \geq b \\ & x \geq 0 \end{aligned}$$

对偶问题

$$\begin{aligned} \max \quad & wb \\ \text{s.t.} \quad & wA \leq 0 \\ & w \geq 0 \end{aligned}$$

Theorem 5. 设 $x^{(0)}$ 和 $w^{(0)}$ 分别是上面原问题和对偶问题的可行解, 那么 $x^{(0)}$ 和 $w^{(0)}$ 都是最优解的充要条件是, 对所有 i 和 j 成立

- 如果 $x_j^{(0)} > 0$, 就有 $w^{(0)}p_j = c_j$ (第 j 个约束等式成立)
- 如果 $A_i x^{(0)} > b_i$, 就有 $w_i^{(0)} = 0$ (如果原问题最优解使得第 i 个约束不等式严格成立, 就有对偶问题 $w_i^{(0)} = 0$)
- 如果 $w_i^{(0)} > 0$, 就有 $A_i x^{(0)} = b_i$
- 如果 $w^{(0)}p_j < c_j$ (称作松约束), 就有 $x_j^{(0)} = 0$

Example 17. 已知线性规划

$$\begin{aligned} \max \quad & f(X) = 3x_1 + 4x_2 + x_3 \\ \text{s.t.} \quad & \\ & x_1 + 2x_2 + x_3 \leq 10 \\ & 2x_1 + 2x_2 + x_3 \leq 16 \\ & x_j \geq 0, j = 1, 2, 3 \end{aligned}$$

的最优解为 $\mathbf{X}^* = (6, 2, 0)^T$, 求其对偶规划的最优解?

Solution. 对偶规划为

$$\begin{aligned} \min \quad & g(Y) = 10y_1 + 16y_2 \\ \text{s.t.} \quad & \\ & y_1 + 2y_2 \geq 3 \\ & 2y_1 + 2y_2 \geq 4 \\ & y_1 + y_2 \geq 1 \\ & y_j \geq 0, j = 1, 2 \end{aligned}$$

设对偶规划的最优解为 $\mathbf{Y}^* = (y_1^*, y_2^*)^T$, 由松弛定理得 (因为 $x_3 = 0$, 那么对偶规划中去掉第三个不等式)

$$\begin{cases} y_1^* + 2y_2^* = 3 \\ 2y_1^* + 2y_2^* = 4 \end{cases} \Rightarrow y_1^* = y_2^* = 1$$

所以对偶规划的最优解为 $\mathbf{Y}^* = (1, 1)^T$.

Example 18. 原问题

$$\begin{aligned} \min \quad & 2x_1 + 3x_2 + x_3 \\ \text{s.t.} \quad & \\ & 3x_1 - x_2 + x_3 \geq 1 \\ & x_1 + 2x_2 - 3x_3 \geq 2 \\ & x_1, x_2, x_3 \geq 0 \end{aligned}$$

对偶问题

$$\begin{aligned} \max \quad & w_1 + 2w_2 \\ \text{s.t.} \quad & 3w_1 + w_2 \leq 2 \\ & -w_1 + 2w_2 \leq 3 \\ & w_1 - 3w_2 \leq 1 \\ & w_1, w_2 \geq 0 \end{aligned}$$

设对偶问题的最优解为 $\bar{w} = (w_1, w_2) = (\frac{1}{7}, \frac{11}{7})$, 试求原问题的最优解。

Solution. 由于在最优解 \bar{w} 处, 对偶问题的第三个约束成立严格不等式, 因此在原问题中第三个变量 $x_3 = 0$, 又由于 \bar{w} 的两个分量均大于零, 因此在原问题中前两个约束在最优解处成立等式, 即

$$\begin{cases} 3x_1 - x_2 + x_3 = 1 \\ x_1 + 2x_2 - 3x_3 = 2 \end{cases}$$

把 $x_3 = 0$ 带入上述方程组, 得到

$$\begin{cases} 3x_1 - x_2 = 1 \\ x_1 + 2x_2 = 2 \end{cases}$$

解得 $x_1 = \frac{4}{7}, x_2 = \frac{5}{7}$, 因此原问题的最优解是

$$\bar{x} = (x_1, x_2, x_3)^T = \left(\frac{4}{7}, \frac{5}{7}, 0\right)^T$$

Example 19. 已知下面线性规划问题的最优解为 $X^* = (2, 2, 4, 0)^T$, 求其对偶规划的最优解。

$$\begin{aligned} \max \quad & 2x_1 + 4x_2 + x_3 + x_4 \\ \text{s.t.} \quad & x_1 + 3x_2 + x_4 \leq 8 \\ & 2x_1 + x_2 \leq 6 \\ & x_2 + x_3 + x_4 \leq 6 \\ & x_1 + x_2 + x_3 \leq 9 \\ & x_i \geq 0, i = 1 \sim 4 \end{aligned}$$

Solution. 对偶问题为:

$$\begin{aligned} \min \quad & 8w_1 + 6w_2 + 6w_3 + 9w_4 \\ \text{s.t.} \quad & w_1 + 2w_2 + w_4 \geq 2 \\ & 3w_1 + w_2 + w_3 + w_4 \geq 4 \\ & w_3 + w_4 \geq 1 \\ & w_1 + w_3 \geq 1 \\ & w_i \geq 0 (i = 1, 2, 3, 4) \end{aligned}$$

由于 x_1, x_2, x_3 均大于 0, 那么对偶问题的前三个约束等式严格成立, 即

$$\begin{aligned} w_1 + 2w_2 + w_4 &= 2 \\ 3w_1 + w_2 + w_3 + w_4 &= 4 \\ w_3 + w_4 &= 1 \end{aligned}$$

将原问题的最优解代入原问题中，发现原问题的第四个约束条件的不等式严格成立，那么有 $w_4 = 0$.

综上，求解得到 $w = (\frac{4}{5}, \frac{3}{5}, 1, 0)^T$ ，最优值为 16.

3.4 对偶单纯形法

求解基本步骤：

$$k = \min\{i | b_i < 0\}$$

$$\frac{\sigma_l}{a_{kl}} = \min_{1 \leq j \leq n} \left\{ \frac{\sigma_j}{a_{kj}} \mid a_{kj} < 0 \right\}$$

Example 20. 用对偶单纯形法求解下面的问题

$$\begin{aligned} \min \quad & f(\mathbf{X}) = x_1 + 2x_2 \\ \text{s.t.} \quad & \\ & x_1 + 2x_2 \geq 4 \\ & x_1 \leq 5 \\ & 3x_1 + x_2 \geq 6 \\ & x_j \geq 0, \quad j = 1 \sim 2 \end{aligned}$$

Solution. 转换为下面的标准形

$$\begin{aligned} \min \quad & f(\mathbf{X}) = x_1 + 2x_2 \\ \text{s.t.} \quad & \\ & -x_1 - 2x_2 + x_3 = -4 \\ & x_1 + x_4 = 5 \\ & -3x_1 - x_2 + x_5 = -6 \\ & x_j \geq 0, \quad j = 1 \sim 5 \end{aligned}$$

对偶单纯形法求解过程如下：

P_1	P_2	P_3	P_4	P_5	b
-1	-2	1	0	0	-4
1	0	0	1	0	5
-3	-1	0	0	1	-6
-1	-2	0	0	0	0
P_1	P_2	P_3	P_4	P_5	b
1	2	-1	0	0	4
0	-2	1	1	0	1
0	5	-3	0	1	6
0	0	-1	0	0	4

这时 $b > 0$ ，所以当前最优解为 $\mathbf{X}^* = (4, 0, 0, 1, 6)^T$ ，因此原规划问题的最优解为 $\mathbf{X}^* = (4, 0)^T$. 对偶问题的最优解为 $\mathbf{W}^* = (1, 0, 0)^T$

【注】：对偶规划的最优解的第 l 个分量就是原规划最终单纯形表中剩余变量的判别数的相反数。

4 无约束最优化计算方法

4.1 基本思想

无约束优化问题:

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

新点 $X^{k+1} = X^k + t_k P^k$, 使得 $f(X^{k+1}) < f(X^k)$, 其中 t_k 称为步长因子, P^k 表示下降方向, 下降方向需满足 $\nabla f(X^k)^T P^k < 0$.

【注】: 后面的所有方法, 就是在确定下降方向 P^k 和步长因子 t_k 确定步长因子 t_k ? 即选取使得

$$f(X^k + t_k P^k) = \min_t f(X^k + t P^k)$$

这时, t_k 称为最优步长。

【注】: 求一元函数 $\varphi(t) = f(X^k + t P^k)$ 极小点的迭代法称为一维搜索, $\varphi'(t) = \nabla f(X^k + t P^k)^T P^k$

Definition 5 (收敛速度). 设序列 $\{X^k\}$ 收敛于 X^* , 若

$$\lim_{k \rightarrow \infty} \frac{\|X^{k+1} - X^*\|}{\|X^k - X^*\|} = \beta$$

则 $0 < \beta < 1$, 称 $\{X^k\}$ 为 β 线性收敛, $\beta = 0$ 时称为超线性收敛, $\beta = 1$ 时称为次线性收敛。

又若

$$\lim_{k \rightarrow \infty} \frac{\|X^{k+1} - X^*\|}{\|X^k - X^*\|^p} = \beta < +\infty$$

则称 $\{X^k\}$ 为 p 阶收敛。这里 $p \geq 1$ 。

Definition 6 (二次终止性). 一个算法用于求解具有正定矩阵的二次函数

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

时, 可以在有限步内达到它的极小点。

4.2 非精确一维搜索的三大准则

Goldstein 准则

$$\begin{cases} (i) f(X^k + t_k P^k) \leq f(X^k) + \rho t_k \nabla f(X^k)^T P^k \\ (ii) f(X^k + t_k P^k) \geq f(X^k) + (1 - \rho) t_k \nabla f(X^k)^T P^k \end{cases}$$

其中 $0 < \rho < 1$ 。

Wolfe 准则

$$\begin{cases} (i) f(X^k + t_k P^k) \leq f(X^k) + \rho t_k \nabla f(X^k)^T P^k \\ (ii) \nabla f(X^k + t_k P^k)^T P^k \geq \sigma \nabla f(X^k)^T P^k \end{cases}$$

其中 $\sigma \in (\rho, 1)$ 。

Armijo 准则

给定 $\beta \in (0, 1)$, $\rho \in (0, \frac{1}{2})$, $\tau > 0$, 设 m_k 是使得下式

$$f(\mathbf{X}^k + \beta^{m_k} \tau \mathbf{P}^k) \leq f(\mathbf{X}^k) + \rho \beta^{m_k} \tau \nabla f(\mathbf{X}^k)^T \mathbf{P}^k$$

成立的最小非负整数。

若令 $t_k = \beta^{m_k} \tau$, 其就是 Goldstein 准则中的第一个准则

$$f(\mathbf{X}^k + t_k \mathbf{P}^k) \leq f(\mathbf{X}^k) + \rho t_k \nabla f(\mathbf{X}^k)^T \mathbf{P}^k$$

为了保证算法收敛性, 需要保证每次搜索方向 p_k 与其梯度方向 $-g_k = -\nabla f(\mathbf{X}^k)$ 成锐角。

4.3 0.618 法

区间选择准则: 原区间为 $[a_k, b_k]$, 0.382 处为 λ_k , 0.618 处为 μ_k .

- 若 $f(\lambda_k) > f(\mu_k)$, 则新区间为 $[\lambda_k, b_k]$.
- 若 $f(\lambda_k) \leq f(\mu_k)$, 则新区间为 $[a_k, \mu_k]$.

【注】: 口诀: 哪边大, 舍哪边。

4.4 最速下降法

求解

$$\min_{\mathbf{X} \in \mathbf{R}^n} f(\mathbf{X})$$

下降方向: $\mathbf{P}^k = -\nabla f(\mathbf{X}^k)$, 确定最优步长 t_k 使得

$$f(\mathbf{X}^k + t_k \nabla f(\mathbf{X}^k)) = \min_t f(\mathbf{X}^k + t \nabla f(\mathbf{X}^k))$$

若 $f(\mathbf{X})$ 具有二阶连续偏导数, 由 Taylor 公式得

$$\begin{aligned} f(\mathbf{X}^k - t \nabla f(\mathbf{X}^k)) &\approx f(\mathbf{X}^k) - t \nabla f(\mathbf{X}^k)^T \nabla f(\mathbf{X}^k) \\ &\quad + \frac{1}{2} t^2 \nabla f(\mathbf{X}^k)^T \mathbf{H}(\mathbf{X}^k) \nabla f(\mathbf{X}^k) \end{aligned}$$

其中 $H(\mathbf{X}^k)$ 是 $f(\mathbf{X})$ 在 \mathbf{X}^k 的 Hesse 矩阵。

令

$$\begin{aligned} \frac{df(\mathbf{X}^k - t \nabla f(\mathbf{X}^k))}{dt} &= -\nabla f(\mathbf{X}^k)^T \nabla f(\mathbf{X}^k) \\ &\quad + t \nabla f(\mathbf{X}^k)^T \mathbf{H}(\mathbf{X}^k) \nabla f(\mathbf{X}^k) = 0 \end{aligned}$$

可得最优步长

$$t_k = \frac{\nabla f(\mathbf{X}^k)^T \nabla f(\mathbf{X}^k)}{\nabla f(\mathbf{X}^k)^T \mathbf{H}(\mathbf{X}^k) \nabla f(\mathbf{X}^k)} = \frac{(\mathbf{g}^k)^T \mathbf{g}^k}{(\mathbf{g}^k)^T \mathbf{H}^k \mathbf{g}^k}$$

由此得到第 $k+1$ 步的迭代点为

$$\mathbf{X}^{k+1} = \mathbf{X}^k - \frac{(\mathbf{g}^k)^T \mathbf{g}^k}{(\mathbf{g}^k)^T \mathbf{H}^k \mathbf{g}^k} \mathbf{g}^k$$

【注】: $\varphi'(t) = \nabla f(\mathbf{X} + t\mathbf{P})^T \mathbf{P} = 0$, 得 $(\mathbf{g}^{k+1})^T \mathbf{g}^k = 0$, 因此, 最速下降法存在锯齿现象

Example 21. 用最速下降法求 $f(\mathbf{X}) = (x_1 - 1)^2 + (x_2 - 1)^2$ 的极小点。

Solution.

$$\mathbf{g}^k = \nabla f(\mathbf{X}) = (2(x_1 - 1), 2(x_2 - 1))^T$$

$$\mathbf{H}^k = \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix}$$

$$\mathbf{X}^0 = (0, 0)^T$$

$$t_0 = \frac{(\mathbf{g}^0)^T \mathbf{g}^0}{(\mathbf{g}^0)^T \mathbf{H}^0 \mathbf{g}^0} = \frac{1}{2}$$

$$\mathbf{X}^1 = \mathbf{X}^0 - t_0 \mathbf{g}^0 = (0, 0)^T - \frac{1}{2}(-2, -2)^T = (1, 1)^T$$

$$\nabla f(\mathbf{X}^1) = (0, 0)^T, \quad \|\nabla f(\mathbf{X}^1)\| < \varepsilon$$

$$\mathbf{X}^* = \mathbf{X}^1$$

4.5 牛顿法 (二阶收敛)

基本思想: 牛顿法是用一个二次函数去近似一个目标函数, 然后精确的求出这个二次函数的极小点, 以它作为目标函数极小点的近似值。

在点 \mathbf{X}^k 处对目标函数按 Taylor 展开

$$\begin{aligned} f(\mathbf{X}) &\approx q(\mathbf{X}) \triangleq f(\mathbf{X}^k) + \mathbf{g}(\mathbf{X}^k)^T (\mathbf{X} - \mathbf{X}^k) \\ &\quad + \frac{1}{2} (\mathbf{X} - \mathbf{X}^k)^T \mathbf{H}(\mathbf{X}^k) (\mathbf{X} - \mathbf{X}^k) \end{aligned}$$

令 $\nabla q(\mathbf{X}) = \mathbf{H}(\mathbf{X}^k) (\mathbf{X} - \mathbf{X}^k) + \mathbf{g}(\mathbf{X}^k) = 0$, 得

$$\mathbf{H}(\mathbf{X}^k) (\mathbf{X} - \mathbf{X}^k) = -\mathbf{g}(\mathbf{X}^k)$$

若 Hesse 矩阵正定, 则

$$\mathbf{X} - \mathbf{X}^k = -\mathbf{H}^{-1}(\mathbf{X}^k) \mathbf{g}(\mathbf{X}^k)$$

则由上式解出来的 $\mathbf{X} = \mathbf{X}^{k+1}$, 就是二次函数 $q(\mathbf{X})$ 的极小点, 即

$$\mathbf{X}^{k+1} = \mathbf{X}^k - \mathbf{H}^{-1}(\mathbf{X}^k) \mathbf{g}(\mathbf{X}^k)$$

【注】: 当目标函数是正定二次函数时, 牛顿法能够一次到达极小点 (一步到位), 具有二次终止性。

4.6 共轭梯度法：共轭性与最速下降法的结合，具有二次终止性

最速下降法存在锯齿现象，收敛速度慢；而牛顿法需要计算 Hesse 矩阵，计算量较大，而共轭梯度法的收敛速度介于两者之间，无需计算 Hesse 矩阵，具有二次收敛性。

Definition 7 (共轭). 设 Q 是对称正定阵，如果 X 和 QY 正交，即

$$X^T QY = 0$$

则称 X 和 Y 关于 Q 共轭。

FR 共轭梯度法

$$\begin{aligned} X^{k+1} &= X^k + t_k P^k \\ t_k &= \frac{-(g^k)^T P^k}{(P^k)^T H(P^k)} \\ P^k &= \begin{cases} -g^k, & k = 0 \\ -g^k + \frac{\|g^k\|^2}{\|g^{k-1}\|^2} P^{k-1}, & k > 0 \end{cases} \end{aligned}$$

Example 22. 用 FR 方法求解 $f(X) = x_1^2 + 2x_2^2$ ，取初始点 $X^0 = (5, 5)^T$ 。

Solution. 解：

$$g = \nabla f(X) = (2x_1, 4x_2)^T, H = \nabla^2 f(X) = \begin{pmatrix} 2 & 0 \\ 0 & 4 \end{pmatrix}$$

第一次迭代

$$\begin{aligned} P^0 &= -g^0 = (-10, -20)^T \\ X^1 &= X^0 + t_0 P_0 = X^0 - t_0 g_0 \\ &= (5, 5)^T + \frac{-(g^0)^T P^0}{(P^0)^T H P^0} (-10, -20)^T \\ &= (5, 5)^T + \frac{5}{18} (-10, -20)^T \\ &= \left(\frac{20}{9}, -\frac{5}{9} \right)^T \end{aligned}$$

第二次迭代

$$\begin{aligned} P^1 &= -g^1 + \alpha_0 P_0 \\ &= \left(-\frac{40}{9}, \frac{20}{9} \right)^T + \frac{\|g^1\|^2}{\|g^0\|^2} (-10, -20)^T \\ &= \left(-\frac{40}{9}, \frac{20}{9} \right)^T + \frac{4}{81} (-10, -20)^T \\ &= \left(-\frac{400}{81}, \frac{100}{81} \right)^T \end{aligned}$$

$$\begin{aligned}
\mathbf{X}^2 &= \mathbf{X}^1 + t_1 \mathbf{P}^1 \\
&= \left(\frac{20}{9}, -\frac{5}{9}\right)^T + \frac{-(\mathbf{g}^1)^T \mathbf{P}^1}{(\mathbf{P}^1)^T \mathbf{H} \mathbf{P}^1} \left(-\frac{400}{81}, \frac{100}{81}\right)^T \\
&= \left(\frac{20}{9}, -\frac{5}{9}\right)^T + \frac{9}{20} \left(-\frac{400}{81}, \frac{100}{81}\right)^T \\
&= (0, 0)^T
\end{aligned}$$

此时 $\mathbf{g}^2 = 0$ ，已达到极小点 $\mathbf{X}^2 = (0, 0)^T$ 。

此例验证了共轭梯度法的二次终止性。

【注】：初始方向应为负梯度方向，否则所产生的一般不为共轭方向。

4.7 拟牛顿法

基本思想：用一个矩阵来近似 Hesse 逆矩阵。

拟牛顿方程：

$$\mathbf{H}^{k+1} \mathbf{Y}^k = \mathbf{S}^k$$

秩 1 具有如下形式：

$$\mathbf{H}^{k+1} = \mathbf{H}^k + \Delta \mathbf{H}^k = \mathbf{H}^k + \lambda \mathbf{u} \mathbf{u}^T$$

秩 1 校正 (SR1)

$$\begin{aligned}
\mathbf{X}^{k+1} &= \mathbf{X}^k + t_k \mathbf{P}^k \\
\mathbf{Y}^k &\triangleq \mathbf{g}^{k+1} - \mathbf{g}^k, \quad \mathbf{S}^k \triangleq \mathbf{X}^{k+1} - \mathbf{X}^k, \quad \mathbf{Z}^k = \mathbf{S}^k - \mathbf{H}^k \mathbf{Y}^k \\
\mathbf{H}^{k+1} &= \mathbf{H}^k + \frac{\mathbf{Z}^k (\mathbf{Z}^k)^T}{(\mathbf{Y}^k)^T \mathbf{Z}^k} \\
\mathbf{P}^{k+1} &= -\mathbf{H}^{k+1} \mathbf{g}^{k+1}
\end{aligned}$$

【注】：SR1 是一种共轭方向法，当然具有二次终止性。对于正定二次函数，SR1 方法至多 n 步终止。但是，不能保证 $\mathbf{P}^k = -\mathbf{H}^k \mathbf{g}^k$ 是下降方向，即 \mathbf{H}^k 不正定。

秩 2 具有如下形式：

$$\Delta \mathbf{H}^k = \lambda_1 \mathbf{u}_1 \mathbf{u}_1^T + \lambda_2 \mathbf{u}_2 \mathbf{u}_2^T$$

秩 2 校正公式 (DFP 算法)

$$\mathbf{H}^{k+1} = \mathbf{H}^k + \frac{\mathbf{S}^k (\mathbf{S}^k)^T}{(\mathbf{S}^k)^T \mathbf{Y}^k} - \frac{\mathbf{H}^k \mathbf{Y}^k (\mathbf{H}^k \mathbf{Y}^k)^T}{(\mathbf{H}^k \mathbf{Y}^k)^T \mathbf{Y}^k}$$

(正定遗传性)：若 \mathbf{H}^0 是对称正定矩阵，则 DFP 校正公式所产生的 \mathbf{H}^k 是对称正定矩阵。

【注】：一般情况下， $\mathbf{H}^0 = \mathbf{I}_n$

【注】：DFP 本质上也是一种共轭方向法，也具有二次收敛性。

Example 23. 用 DFP 算法求 $\min 2x_1^2 + x_2^2 - 4x_1 + 2$ ，取 $\mathbf{X}^0 = (2, 1)^T$

Solution.

$$\mathbf{g} = \begin{pmatrix} 4(x_1 - 1) \\ 2x_2 \end{pmatrix}, \quad \mathbf{Q} = \begin{pmatrix} 4 & 0 \\ 0 & 2 \end{pmatrix}, \quad \mathbf{H}^0 = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

第一次迭代:

$$\mathbf{g}^0 = (4, 2)^T$$

$$\mathbf{P}^0 = -\mathbf{H}^0 \mathbf{g}^0 = -\mathbf{g}^0$$

$$\mathbf{X}^1 = \mathbf{X}^0 + t_0 \mathbf{P}^0 = \mathbf{X}^0 + \frac{-(\mathbf{g}^0)^T \mathbf{P}^0}{(\mathbf{P}^0)^T \mathbf{Q} \mathbf{P}^0} \mathbf{P}^0 = \left(\frac{8}{9}, \frac{4}{9} \right)^T$$

第二次迭代:

$$\mathbf{g}^1 = \left(-\frac{4}{9}, \frac{8}{9} \right)^T$$

$$\mathbf{S}^0 = \mathbf{X}^1 - \mathbf{X}^0 = \left(-\frac{10}{9}, -\frac{5}{9} \right)^T$$

$$\mathbf{Y}^0 = \mathbf{g}^1 - \mathbf{g}^0 = \left(-\frac{40}{9}, -\frac{10}{9} \right)^T$$

$$\begin{aligned} \mathbf{H}^1 &= \mathbf{H}^0 + \frac{\mathbf{S}^0 (\mathbf{S}^0)^T}{(\mathbf{S}^0)^T \mathbf{Y}^0} - \frac{\mathbf{Y}^0 (\mathbf{Y}^0)^T}{(\mathbf{Y}^0)^T \mathbf{Y}^0} \\ &= \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + \frac{1}{18} \begin{pmatrix} 4 & 2 \\ 2 & 1 \end{pmatrix} - \frac{1}{17} \begin{pmatrix} 16 & 4 \\ 4 & 1 \end{pmatrix} \\ &= \frac{1}{306} \begin{pmatrix} 86 & -38 \\ -38 & 305 \end{pmatrix} \end{aligned}$$

搜索方向

$$\mathbf{P}^1 = -\mathbf{H}^1 \mathbf{g}^1 = \frac{4}{17} (1, -4)^T$$

步长

$$t_1 = \min_{\lambda} f(\mathbf{X}^1 + t \mathbf{P}^1)$$

从 \mathbf{X}^1 出发沿 \mathbf{P}^1 进行一维搜索, 即

$$\mathbf{X}^2 = \mathbf{X}^1 + t_1 \mathbf{P}^1 = (1, 0)^T$$

第三次迭代:

$$\|\mathbf{g}^2\| = 0$$

迭代终止, 所以 \mathbf{X}^2 是极小点。

4.8 信赖域方法

前面的方法是先确定搜索方法, 再确定步长, 信赖域方法是先确定一个步长, 再确定搜索方法。

实际下降量

$$\Delta f^k = f(\mathbf{X}^k) - f(\mathbf{X}^k + \mathbf{S}^k)$$

预测下降量

$$\Delta q^k = f(\mathbf{X}^k) - q^k(\mathbf{S}^k)$$

比值

$$r^k = \Delta f^k / \Delta q^k$$

它衡量二次模型近似目标函数的程度， r^k 越接近于 1，表示近似程度越好。

【注】：当 $r^k < 0$ 时，无效步； $(\frac{1}{4}, \frac{3}{4})$ ，不变； $(\frac{3}{4}, 1)$ ，扩大 h ； $(0, \frac{1}{4})$ ，缩小 h 。 h 表示信赖域半径。

【注】：简记口诀：比值大，扩大；比值小，缩小。

【注】：在较强的假设下，信赖域方法具有二阶收敛速度

5 最优性条件

5.1 无约束问题的极值条件

(必要条件)：若 \bar{x} 是局部极小点，则梯度 $\nabla f(\bar{x}) = 0$ ，且 Hesse 矩阵 $\nabla^2 f(\bar{x}) = 0$ 半正定。

(二阶充分条件)：若梯度 $\nabla f(\bar{x}) = 0$ ，且 Hesse 矩阵 $\nabla^2 f(\bar{x}) = 0$ 正定，则 \bar{x} 是局部极小点。

(充要条件)：设 $f(x)$ 是定义在 \mathbb{R}^n 上的可微凸函数， $\bar{x} \in \mathbb{R}^n$ ，则 \bar{x} 是全局极小点的充分必要条件是梯度 $\nabla f(\bar{x}) = 0$ 。

5.2 约束问题的极值条件

5.2.1 不等式约束优化问题的一阶最优性条件

下降方向满足： $\nabla f(\bar{x})^T d < 0$

可行方向满足： $\bar{x} + \lambda d \in S$

考虑非线性规划问题：

$$\begin{aligned} \min \quad & f(x) \\ \text{s. t.} \quad & g_i(x) \geq 0, \quad i = 1, \dots, m \end{aligned}$$

这个问题的可行域

$$S = \{x | g_i(x) \geq 0, i = 1, \dots, m\}$$

K-T 条件：

$$\begin{aligned} \nabla f(\bar{x}) - \sum_{i=1}^m w_i \nabla g_i(\bar{x}) &= 0 \\ w_i g_i(\bar{x}) &= 0, \quad i = 1, \dots, m \\ w_i &\geq 0, \quad i = 1, \dots, m \end{aligned}$$

Example 24.

$$\begin{aligned} \min \quad & (x_1 - 2)^2 + x_2^2 \\ \text{s. t.} \quad & x_1 - x_2^2 \geq 0 \\ & -x_1 + x_2 \geq 0 \end{aligned}$$

验证下列两点

$$x^{(1)} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad \text{和} \quad x^{(2)} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

是否为 K-T 点。

Solution. 记

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

$$g_1(x) = x_1 - x_2^2$$

$$g_2(x) = -x_1 + x_2$$

目标函数和约束函数的梯度是

$$\nabla f(x) = \begin{bmatrix} 2(x_1 - 2) \\ 2x_2 \end{bmatrix}, \quad \nabla g_1(x) = \begin{bmatrix} 1 \\ -2x_2 \end{bmatrix}, \quad \nabla g_2(x) = \begin{bmatrix} -1 \\ 1 \end{bmatrix}$$

先验证 $x^{(1)}$, 在这一点, $g_1(x) \geq 0$ 和 $g_2(x) \geq 0$ 都是起作用约束, 目标函数和约束函数的梯度分别是

$$\nabla f(x^{(1)}) = \begin{bmatrix} -4 \\ 0 \end{bmatrix}, \quad \nabla g_1(x^{(1)}) = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \quad \nabla g_2(x^{(1)}) = \begin{bmatrix} -1 \\ 1 \end{bmatrix}$$

设

$$\begin{bmatrix} -4 \\ 0 \end{bmatrix} - w_1 \begin{bmatrix} 1 \\ 0 \end{bmatrix} - w_2 \begin{bmatrix} -1 \\ 1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

即

$$-4 - w_1 + w_2 = 0$$

$$-w_2 = 0$$

解此方程组得到

$$w_1 = -4, \quad w_2 = 0$$

由于 $w_1 < 0$, 因此 $x^{(1)}$ 不是 $K-T$ 点。

在验证 $x^{(2)}$, $g_1(x) \geq 0$ 和 $g_2(x) \geq 0$ 都是起作用约束, 目标函数和约束函数的梯度分别是

$$\nabla f(x^{(2)}) = \begin{bmatrix} -2 \\ 2 \end{bmatrix}, \quad \nabla g_1(x^{(2)}) = \begin{bmatrix} 1 \\ -2 \end{bmatrix}, \quad \nabla g_2(x^{(2)}) = \begin{bmatrix} -1 \\ 1 \end{bmatrix}$$

设

$$\begin{bmatrix} -2 \\ 2 \end{bmatrix} - w_1 \begin{bmatrix} 1 \\ -2 \end{bmatrix} - w_2 \begin{bmatrix} -1 \\ 1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

即

$$\begin{cases} -2 - w_1 + w_2 = 0 \\ 2 + 2w_1 - w_2 = 0 \end{cases}$$

解此方程组得到

$$w_1 = 0, \quad w_2 = 2$$

所以 $x^{(2)}$ 是 $K-T$ 点。

Example 25.

$$\begin{aligned} \min \quad & f(x) \stackrel{\text{def}}{=} (x_1 - 1)^2 + x_2 \\ \text{s. t.} \quad & g_1(x) = -x_1 - x_2 + 2 \geq 0 \\ & g_2(x) = x_2 \geq 0 \end{aligned}$$

求满足 $K-T$ 条件的点。

Solution. 目标函数和约束函数的梯度分别是

$$\nabla f(x) = \begin{bmatrix} 2(x_1 - 1) \\ 1 \end{bmatrix}, \quad \nabla g_1(x) = \begin{bmatrix} -1 \\ -1 \end{bmatrix}, \quad \nabla g_2(x) = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

$K-T$ 条件为

$$\begin{aligned} \nabla f(x) - \sum_{i=1}^2 w_i \nabla g_i(x) &= 0 \\ w_i g_i(x) &= 0, \quad i = 1, 2 \\ w_i &\geq 0, \quad i = 1, 2 \end{aligned}$$

即

$$\begin{aligned} 2(x_1 - 1) + w_1 &= 0 \\ 1 + w_1 - w_2 &= 0 \\ w_1(-x_1 - x_2 + 2) &= 0 \\ w_2 x_2 &= 0 \\ w_1, w_2 &\geq 0 \end{aligned}$$

解此方程组得到一组解

$$x_1 = 1, \quad x_2 = 0, \quad w_1 = 0, \quad w_2 = 1$$

因为 w_1 和 w_2 都是非负数, 因此得到 $K-T$ 点

$$\bar{x} = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$$

5.2.2 一般约束优化问题的一阶最优性条件

$$\begin{aligned} \min \quad & f(x), \quad x \in \mathbb{R}^n \\ \text{s. t.} \quad & g(x) \geq 0 \\ & h(x) = 0 \end{aligned}$$

Lagrange 函数

$$L(x, w, v) = f(x) - \sum_{i=1}^m w_i g_i(x) - \sum_{j=1}^l v_j h_j(x)$$

KKT 条件如下

$$\begin{aligned} \nabla_x L(x, w, v) &= 0 && \text{原始最优化条件} \\ g_i(x) &\geq 0, \quad i = 1, \dots, m && \text{原始可行性条件} \\ h_j(x) &= 0, \quad j = 1, \dots, l && \text{原始可行性条件} \\ w_i g_i(x) &= 0, \quad i = 1, \dots, m && \text{互补松弛条件} \\ w_i &\geq 0, \quad i = 1, \dots, m && \text{对偶可行性条件} \end{aligned}$$

5.3 惩罚函数法

5.3.1 外点罚函数法

对于

$$\begin{aligned} & \min f(\mathbf{X}) \\ & \text{s.t.} \\ & g_i(\mathbf{X}) \geq 0, i = 1 \sim m \end{aligned}$$

构造外点罚函数

$$P(\mathbf{X}, m_k) = f(\mathbf{X}) + m_k \sum_{i=1}^m (\min(g_i(\mathbf{X}), 0))^2$$

Example 26. 用外点罚函数法求解下列问题

$$\begin{aligned} & \min f(x) = (x_1 - 1)^2 + x_2^2 \\ & \text{s.t. } g(x) = x_2 - 1 \geq 0 \end{aligned}$$

Solution. 定义罚函数

$$\begin{aligned} F(x, \sigma) &= (x_1 - 1)^2 + x_2^2 + \sigma [\max\{0, -(x_2 - 1)\}]^2 \\ &= \begin{cases} (x_1 - 1)^2 + x_2^2, & x_2 \geq 1 \\ (x_1 - 1)^2 + x_2^2 + \sigma(x_2 - 1)^2, & x_2 < 1 \end{cases} \end{aligned}$$

用解析法求解

$$\min F(x, \sigma)$$

求偏导, 得

$$\begin{aligned} \frac{\partial F}{\partial x_1} &= 2(x_1 - 1) \\ \frac{\partial F}{\partial x_2} &= \begin{cases} 2x_2, & x_2 \geq 1 \\ 2x_2 + 2\sigma(x_2 - 1), & x_2 < 1 \end{cases} \end{aligned}$$

令

$$\frac{\partial F}{\partial x_1} = 0, \quad \frac{\partial F}{\partial x_2} = 0$$

得到

$$\bar{x}_\sigma = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 1 \\ \frac{\sigma}{1+\sigma} \end{bmatrix}$$

令 $\sigma \rightarrow +\infty$, 得

$$\bar{x}_\sigma \rightarrow \bar{x} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

5.3.2 内点罚函数法

内点罚函数只适用于以下问题

$$\begin{aligned} & \min f(x) \\ & \text{s.t. } g_i(x) \geq 0, \quad i = 1, \dots, m \end{aligned}$$

定义障碍函数

$$G(x, r) = f(x) + rB(x)$$

其中 $B(x)$ 是连续函数, 当点 x 趋向于可行域边界时, $B(x) \rightarrow \infty$, r 是很小的正数。

两种最重要的形式为:

$$B(x) = \sum_{i=1}^m \frac{1}{g_i(x)}$$

及

$$B(x) = -\sum_{i=1}^m \log g_i(x)$$

Example 27. 用内点罚函数为求解

$$\begin{aligned} \min \quad & \frac{1}{12} (x_1 + 1)^3 + x_2 \\ \text{s. t.} \quad & x_1 - 1 \geq 0 \\ & x_2 \geq 0 \end{aligned}$$

Solution. 定义障碍函数

$$G(x, r_k) = \frac{1}{12} (x_1 + 1)^3 + x_2 + r_k \left(\frac{1}{x_1 - 1} + \frac{1}{x_2} \right)$$

下面用解析法求解问题

$$\begin{aligned} \min \quad & G(x, r_k) \\ \text{s. t.} \quad & x \in S \end{aligned}$$

令

$$\begin{aligned} \frac{\partial G}{\partial x_1} &= \frac{1}{4} (x_1 + 1)^2 - \frac{r_k}{(x_1 - 1)^2} = 0 \\ \frac{\partial G}{\partial x_2} &= 1 - \frac{r_k}{x_2^2} = 0 \end{aligned}$$

解得

$$\bar{x}_{r_k} = (x_1, x_2) = \left(\sqrt{1 + 2\sqrt{r_k}}, \sqrt{r_k} \right)$$

当 $r_k \rightarrow 0$, $\bar{x}_{r_k} \rightarrow \bar{x} = (1, 0)$, \bar{x} 是问题的最优解。