

# 可行方向法

李宗军

青岛理工大学 · 理学院

2016 年





# 要点

可行方向法

|zj

可行方向法

- ① 可行方向法
  - 简约梯度法



# 复习 I

可行方向法

|zj

可行方向法

- ① 等式约束的 K-T 条件
- ② 不等式约束的 K-T 条件
- ③ 一般的 NLP 的 K-T 条件

$$\nabla f(x) + \sum_{i \in I} \lambda_i \nabla g_i(x) + \sum_{j \in J} u_j \nabla h_j(x) = 0$$

$$\lambda_i g_i(x) = 0, i \in I$$

$$\lambda_i \geq 0, i \in I$$

- ④ K-T 条件的计算
- ⑤ K-T 条件是必要条件，注意其梯度们是线性无关的
- ⑥ 对凸规划，K-T 条件是充要条件



# 复习 II

可行方向法

|zj

可行方向法

- ⑦ LP 问题的 K-T 条件
- ⑧ K-T 的作用是把最优化问题转换为方程组问题



# 简约梯度法

可行方向法

lzj

可行方向法

简约梯度法

$$\min f(x)$$

$$\text{st.} \begin{cases} Ax = b \\ x \geq 0 \end{cases}$$

## ② 算法思想

仿照 LP 中的单纯形法，在每一轮迭代的当前点  $x^k$  处，把  $x^k$  分为基变量部分和非基变量部分，则  $f(x) = F(x_N)$ , 采用  $F(x_N)$  的负梯度方向构造可行下降方向  $p$ , 迭代步长采用一维搜索方法。



# 算法推导

$$\bullet Ax = b \Rightarrow Bx_B + Nx_N = b, x_B = B^{-1}b - B^{-1}Nx_N$$

可行方向法

|zj

可行方向法

简约梯度法



# 算法推导

可行方向法

- $Ax = b \Rightarrow Bx_B + Nx_N = b, x_B = B^{-1}b - B^{-1}Nx_N$
- 代入目标函数，有  $f(x) = f(B^{-1}b - B^{-1}Nx_N, x_N)$ , 令为  $F(x_N)$ .

|zj

可行方向法

简约梯度法



# 算法推导

可行方向法

- $Ax = b \Rightarrow Bx_B + Nx_N = b, x_B = B^{-1}b - B^{-1}Nx_N$
- 代入目标函数，有  $f(x) = f(B^{-1}b - B^{-1}Nx_N, x_N)$ , 令为  $F(x_N)$ .
- 取  $\nabla F(x_N) = - (B^{-1}N)^T \nabla_B f(x) + \nabla_N f(x) \stackrel{\text{LET}}{=} r_N$  作为下降方向。下面考察可行性。

|zj

可行方向法

简约梯度法



# 算法推导

可行方向法

|zj

- $Ax = b \Rightarrow Bx_B + Nx_N = b, x_B = B^{-1}b - B^{-1}Nx_N$
- 代入目标函数，有  $f(x) = f(B^{-1}b - B^{-1}Nx_N, x_N)$ , 令为  $F(x_N)$ .
- 取  $\nabla F(x_N) = - (B^{-1}N)^T \nabla_B f(x) + \nabla_N f(x) \stackrel{\text{LET}}{=} r_N$  作为下降方向。下面考察可行性。
- 取  $p = (p_B, p_N)^T = (p_B, r_N)^T$ , 则下个迭代点为  $x' = x + tp = (x_B, x_N)^T + t(p_B, p_N)^T$ .

可行方向法

简约梯度法



# 算法推导

可行方向法

|zj

- $Ax = b \Rightarrow Bx_B + Nx_N = b, x_B = B^{-1}b - B^{-1}Nx_N$
- 代入目标函数，有  $f(x) = f(B^{-1}b - B^{-1}Nx_N, x_N)$ , 令为  $F(x_N)$ .
- 取  $\nabla F(x_N) = - (B^{-1}N)^T \nabla_B f(x) + \nabla_N f(x) \stackrel{\text{LET}}{=} r_N$  作为下降方向。下面考察可行性。
- 取  $p = (p_B, p_N)^T = (p_B, r_N)^T$ , 则下个迭代点为  $x' = x + tp = (x_B, x_N)^T + t(p_B, p_N)^T$ .
- 要使  $x'$  满足可行性，即  $Ax' = b, x' \geq 0$ . 从而

可行方向法

简约梯度法



# 算法推导

可行方向法

|zj

- $Ax = b \Rightarrow Bx_B + Nx_N = b, x_B = B^{-1}b - B^{-1}Nx_N$
- 代入目标函数，有  $f(x) = f(B^{-1}b - B^{-1}Nx_N, x_N)$ , 令为  $F(x_N)$ .
- 取  $\nabla F(x_N) = - (B^{-1}N)^T \nabla_B f(x) + \nabla_N f(x) \stackrel{\text{LET}}{=} r_N$  作为下降方向。下面考察可行性。
- 取  $p = (p_B, p_N)^T = (p_B, r_N)^T$ , 则下个迭代点为  $x' = x + tp = (x_B, x_N)^T + t(p_B, p_N)^T$ .
- 要使  $x'$  满足可行性，即  $Ax' = b, x' \geq 0$ . 从而
- $Ax' = A(x + tp) = Ax + tAp = b + tAp = b$ , 从而  $Ap = 0$ , 即

可行方向法

简约梯度法



# 算法推导

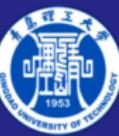
可行方向法

|zj

可行方向法

简约梯度法

- $Ax = b \Rightarrow Bx_B + Nx_N = b, x_B = B^{-1}b - B^{-1}Nx_N$
- 代入目标函数，有  $f(x) = f(B^{-1}b - B^{-1}Nx_N, x_N)$ , 令为  $F(x_N)$ .
- 取  $\nabla F(x_N) = - (B^{-1}N)^T \nabla_B f(x) + \nabla_N f(x) \stackrel{\text{LET}}{=} r_N$  作为下降方向。下面考察可行性。
- 取  $p = (p_B, p_N)^T = (p_B, r_N)^T$ , 则下个迭代点为  $x' = x + tp = (x_B, x_N)^T + t(p_B, p_N)^T$ .
- 要使  $x'$  满足可行性，即  $Ax' = b, x' \geq 0$ . 从而
- $Ax' = A(x + tp) = Ax + tAp = b + tAp = b$ , 从而  $Ap = 0$ , 即
- $(B, N)(p_B, p_N)^T = Bp_B + Np_N = 0$ , 解得  $p_B = -B^{-1}Np_N$



# 算法推导 II

可行方向法

|zj

•  $x' = x + tp \geq 0 \Rightarrow$

$$\begin{cases} \forall t > 0, & p \geq 0 \\ t \leq \left\{ -\frac{x_i^k}{p_i^k} \mid p_i^k < 0, i = 1, \dots, n \right\} & \text{else} \end{cases}'$$

可行方向法

简约梯度法



# 算法推导 II

可行方向法

|zj

- $x' = x + tp \geq 0 \Rightarrow$

$$\begin{cases} \forall t > 0, & p \geq 0 \\ t \leq \left\{ -\frac{x_i^k}{p_i^k} | p_i^k < 0, i = 1, \dots, n \right\} & \text{else} \end{cases}'$$

- 故取  $t_{\max} = \begin{cases} +\infty, & p^k \geq 0 \\ \min \left\{ -\frac{x_i^k}{p_i^k} | p_i^k < 0, i = 1, \dots, n \right\}, & \text{else} \end{cases}$

可行方向法

简约梯度法



# 算法推导 II

可行方向法

|zj

- $x' = x + tp \geq 0 \Rightarrow$

$$\begin{cases} \forall t > 0, & p \geq 0 \\ t \leq \left\{ -\frac{x_i^k}{p_i^k} | p_i^k < 0, i = 1, \dots, n \right\} & \text{else} \end{cases}$$

- 故取  $t_{\max} = \begin{cases} +\infty, & p^k \geq 0 \\ \min \left\{ -\frac{x_i^k}{p_i^k} | p_i^k < 0, i = 1, \dots, n \right\}, & \text{else} \end{cases}$

- 对  $p_N = r_N, x'_N = x_N + tr_N$ , 其分量形式  $x'_i = x_i + tr_i$ , 为保证

$$x'_i \geq 0, \text{ 选取 } p_i = \begin{cases} -r_i, & r_i \leq 0 \\ -x_i r_i, & r_i > 0 \end{cases}$$

可行方向法

简约梯度法



## 定理 4.5.3

可行方向法

|zj

可行方向法

简约梯度法

- ① 若  $p \neq 0$ , 则  $p$  是  $f(x)$  在  $x^k$  处的可行下降方向;
- ②  $p = 0$  的充要条件是  $x^k$  是 K-T 点。



# 迭代步骤 I

- ① 算法初始化，给定初始点  $x^0, \varepsilon > 0, k := 0$
- ② 设  $I_B^k$  是  $x^k$  的  $m$  个最大分量的下标集，对矩阵  $A$  进行分解  
$$A = (B_k, N_k)$$
- ③ 计算  $\nabla f(x^k) = (\nabla_B f(x^k), \nabla_N f(x^k))^T$ , 然后计算简约梯度  
$$r_N^k = (B_k^{-1} N_k)^T \nabla_B f(x^k) - \nabla_N f(x^k).$$
 记  $r_N^k$  的第  $i$  个分量为  $r_i^k$
- ④ 构造  $p^k = (p_B^k, p_N^k)^T$ , 其中  
$$p_N^k = (p_i^k) = \begin{cases} r_i^k, & r_i^k \leq 0 \\ x_i^k r_i^k, & r_i^k > 0 \end{cases}, p_B^k = -B_k^{-1} N_k p_N^k.$$
 若  $\|p^k\| \leq \varepsilon$ ,  
停止迭代，输出  $x^k$ .
- ⑤ 采用一维搜索，求解  $\min \{f(x^k + tp^k) | 0 \leq t \leq t_{\max}^k\}$ , 得

到最优解  $t_k$ , 其中  $t_{\max}^k = \begin{cases} +\infty, & p^k \geq 0 \\ \min \left\{ -\frac{x_i^k}{p_i^k} | p_i^k < 0 \right\}, & \text{else} \end{cases}$

可行方向法

|zj

可行方向法

简约梯度法



# 迭代步骤 II

可行方向法

|zj

可行方向法

简约梯度法

- ⑥  $x^{k+1} = x^k + t_k p^k, k := k + 1$ , 转向 2.



# 程序 MMA

可行方向法

|zj

可行方向法

简约梯度法

MMA 演示



# 算法说明

可行方向法

|zj

- ① 数值实验表明：对于大规模的线性约束的 NLP，简约梯度法是最好的
- ② 对约束最优化而言，迭代方向必须是可行下降方向，此类算法统称为可行下降算法。
- ③ 由定理 4.5.3 ( $p^k = 0$  的充要条件是  $x^k$  是 K-T 点。)，从而迭代终止条件采用简单的  $\|p^k\| \leq \varepsilon$ , 而不是采用复杂的 K-T 条件。
- ④ 初始点，可采用 LP 中的两阶段法获得。

可行方向法

简约梯度法



# 小结

可行方向法

|zj

可行方向法

简约梯度法

- ① 简约梯度法，适用的问题是  $\min \{f(x) | Ax = b, x \geq 0\}$
- ② 算法思想
- ③ 算法推导：迭代方向、迭代步长、终止条件、初始点
- ④ 迭代步骤
- ⑤ MMA 程序



# 作业

可行方向法

|zj

可行方向法

简约梯度法

T25