



---

# 最优化方法

---

东南大学

计算机&人工智能学院

宋沫飞

[songmf@seu.edu.cn](mailto:songmf@seu.edu.cn)



# 内点法



- 不等式约束的极小化问题
- 对数障碍函数和中心路径
- 障碍方法
- 可行性和阶段1方法
- 自和谐条件的复杂性分析




# 不等式约束的极小化

---





# 不等式约束的极小化



$$\begin{aligned} & \text{minimize} && f_0(x) \\ & \text{subject to} && f_i(x) \leq 0, \quad i = 1, \dots, m \\ & && Ax = b \end{aligned}$$



# 不等式约束的极小化



$$\begin{aligned} & \text{minimize} && f_0(x) \\ & \text{subject to} && f_i(x) \leq 0, \quad i = 1, \dots, m \\ & && Ax = b \end{aligned}$$

函数 $f$ 为凸函数，二次连续可微



# 不等式约束的极小化



$$\begin{aligned} & \text{minimize} && f_0(x) \\ & \text{subject to} && f_i(x) \leq 0, \quad i = 1, \dots, m \\ & && Ax = b \end{aligned}$$

函数 $f$ 为凸函数，二次连续可微

$$A \in \mathbf{R}^{p \times n} \text{ with } \mathbf{rank} A = p$$



# 不等式约束的极小化



$$\begin{aligned} & \text{minimize} && f_0(x) \\ & \text{subject to} && f_i(x) \leq 0, \quad i = 1, \dots, m \\ & && Ax = b \end{aligned}$$

函数 $f$ 为凸函数，二次连续可微

$$A \in \mathbf{R}^{p \times n} \text{ with } \mathbf{rank} A = p$$

假设最优值  $p^*$  为有限且存在



# 不等式约束的极小化



$$\begin{aligned} & \text{minimize} && f_0(x) \\ & \text{subject to} && f_i(x) \leq 0, \quad i = 1, \dots, m \\ & && Ax = b \end{aligned}$$

函数 $f$ 为凸函数，二次连续可微

$$A \in \mathbf{R}^{p \times n} \text{ with } \mathbf{rank} A = p$$

假设最优值  $p^*$  为有限且存在

假设问题为严格可行：存在  $\tilde{x}$  满足





# 不等式约束的极小化



$$\begin{array}{ll} \text{minimize} & f_0(x) \\ \text{subject to} & f_i(x) \leq 0, \quad i = 1, \dots, m \\ & Ax = b \end{array}$$

函数 $f$ 为凸函数，二次连续可微

$$A \in \mathbf{R}^{p \times n} \text{ with } \mathbf{rank} A = p$$

假设最优值  $p^*$  为有限且存在

假设问题为严格可行：存在  $\tilde{x}$  满足

$$\tilde{x} \in \mathbf{dom} f_0, \quad f_i(\tilde{x}) < 0, \quad i = 1, \dots, m, \quad A\tilde{x} = b$$



# 不等式约束的极小化



$$\begin{aligned} & \text{minimize} && f_0(x) \\ & \text{subject to} && f_i(x) \leq 0, \quad i = 1, \dots, m \\ & && Ax = b \end{aligned}$$

函数 $f$ 为凸函数，二次连续可微

$$A \in \mathbf{R}^{p \times n} \text{ with } \mathbf{rank} A = p$$

假设最优值  $p^*$  为有限且存在

假设问题为严格可行：存在  $\tilde{x}$  满足

$$\tilde{x} \in \mathbf{dom} f_0, \quad f_i(\tilde{x}) < 0, \quad i = 1, \dots, m, \quad A\tilde{x} = b$$

因此，具有强对偶且对偶优化存在



# 例子





# 例子



- 线性规划、二次规划、二次约束的二次规划



# 例子



- 线性规划、二次规划、二次约束的二次规划
- 基于线性不等式约束的熵最大化



# 例子



- 线性规划、二次规划、二次约束的二次规划
- 基于线性不等式约束的熵最大化

$$\begin{aligned} & \text{minimize} && \sum_{i=1}^n x_i \log x_i \\ & \text{subject to} && Fx \preceq g \\ & && Ax = b \end{aligned}$$



# 例子



- 线性规划、二次规划、二次约束的二次规划
- 基于线性不等式约束的熵最大化

$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n x_i \log x_i \\ \text{subject to} & Fx \preceq g \\ & Ax = b \end{array}$$

- 其中,  $\text{dom } f_0 = \mathbf{R}_{++}^n$



# 例子



- 线性规划、二次规划、二次约束的二次规划
- 基于线性不等式约束的熵最大化

$$\begin{aligned} & \text{minimize} && \sum_{i=1}^n x_i \log x_i \\ & \text{subject to} && Fx \preceq g \\ & && Ax = b \end{aligned}$$

- 其中,  $\text{dom } f_0 = \mathbf{R}_{++}^n$
- 可微性需要重形式化问题





# 例子



- 线性规划、二次规划、二次约束的二次规划
- 基于线性不等式约束的熵最大化

$$\begin{aligned} & \text{minimize} && \sum_{i=1}^n x_i \log x_i \\ & \text{subject to} && Fx \preceq g \\ & && Ax = b \end{aligned}$$

- 其中,  $\text{dom } f_0 = \mathbf{R}_{++}^n$
- 可微性需要重形式化问题
  - 分段线性极小化



# 例子



- 线性规划、二次规划、二次约束的二次规划
- 基于线性不等式约束的熵最大化

$$\begin{aligned} & \text{minimize} && \sum_{i=1}^n x_i \log x_i \\ & \text{subject to} && Fx \preceq g \\ & && Ax = b \end{aligned}$$

- 其中,  $\text{dom } f_0 = \mathbf{R}_{++}^n$
- 可微性需要重形式化问题
  - 分段线性极小化
  - 基于线性规划的范数逼近



# 对数障碍





# 对数障碍



- 通过示性函数重形式化不等式约束问题



# 对数障碍



□ 通过示性函数重形式化不等式约束问题

$$\begin{aligned} & \text{minimize} && f_0(x) + \sum_{i=1}^m I_-(f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$



# 对数障碍



- 通过示性函数重形式化不等式约束问题

$$\begin{aligned} & \text{minimize} && f_0(x) + \sum_{i=1}^m I_-(f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$

- 其中,  $I_-(u) = 0$  if  $u \leq 0$ ,  $I_-(u) = \infty$  otherwise



# 对数障碍




- 通过示性函数重形式化不等式约束问题

$$\begin{aligned} & \text{minimize} && f_0(x) + \sum_{i=1}^m I_-(f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$

- 其中,  $I_-(u) = 0$  if  $u \leq 0$ ,  $I_-(u) = \infty$  otherwise
- 通过对数障碍近似



# 对数障碍



- 通过示性函数重形式化不等式约束问题

$$\begin{aligned} & \text{minimize} && f_0(x) + \sum_{i=1}^m I_-(f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$

- 其中,  $I_-(u) = 0$  if  $u \leq 0$ ,  $I_-(u) = \infty$  otherwise

- 通过对数障碍近似

$$\begin{aligned} & \text{minimize} && f_0(x) - (1/t) \sum_{i=1}^m \log(-f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$





# 对数障碍



- 通过示性函数重形式化不等式约束问题

$$\begin{aligned} & \text{minimize} && f_0(x) + \sum_{i=1}^m I_-(f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$

- 其中,  $I_-(u) = 0$  if  $u \leq 0$ ,  $I_-(u) = \infty$  otherwise

- 通过对数障碍近似

$$\begin{aligned} & \text{minimize} && f_0(x) - (1/t) \sum_{i=1}^m \log(-f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$

- 为等式约束问题



# 对数障碍



- 通过示性函数重形式化不等式约束问题

$$\begin{aligned} & \text{minimize} && f_0(x) + \sum_{i=1}^m I_-(f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$

- 其中,  $I_-(u) = 0$  if  $u \leq 0$ ,  $I_-(u) = \infty$  otherwise

- 通过对数障碍近似

$$\begin{aligned} & \text{minimize} && f_0(x) - (1/t) \sum_{i=1}^m \log(-f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$

- 为等式约束问题

- $t > 0$ ,  $-(1/t) \log(-u)$ 为  $I_-$  的平滑近似



# 对数障碍



- 通过示性函数重形式化不等式约束问题

$$\begin{aligned} & \text{minimize} && f_0(x) + \sum_{i=1}^m I_-(f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$

- 其中,  $I_-(u) = 0$  if  $u \leq 0$ ,  $I_-(u) = \infty$  otherwise

- 通过对数障碍近似

$$\begin{aligned} & \text{minimize} && f_0(x) - (1/t) \sum_{i=1}^m \log(-f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$

- 为等式约束问题

- $t > 0$ ,  $-(1/t) \log(-u)$ 为  $I_-$  的平滑近似

- 近似程度随  $t \rightarrow \infty$  提高



# 对数障碍



- 通过示性函数重形式化不等式约束问题

$$\begin{aligned} & \text{minimize} && f_0(x) + \sum_{i=1}^m I_-(f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$

- 其中,  $I_-(u) = 0$  if  $u \leq 0$ ,  $I_-(u) = \infty$  otherwise


- 通过对数障碍近似

$$\begin{aligned} & \text{minimize} && f_0(x) - (1/t) \sum_{i=1}^m \log(-f_i(x)) \\ & \text{subject to} && Ax = b \end{aligned}$$

- 为等式约束问题

- $t > 0$ ,  $-(1/t) \log(-u)$ 为  $I_-$  的平滑近似

- 近似程度随  $t \rightarrow \infty$  提高





# 对数障碍函数

---





# 对数障碍函数



$$\phi(x) = - \sum_{i=1}^m \log(-f_i(x)), \quad \mathbf{dom} \phi = \{x \mid f_1(x) < 0, \dots, f_m(x) < 0\}$$



# 对数障碍函数



$$\phi(x) = - \sum_{i=1}^m \log(-f_i(x)), \quad \mathbf{dom} \phi = \{x \mid f_1(x) < 0, \dots, f_m(x) < 0\}$$

□ 根据组合规则为凸函数



# 对数障碍函数



$$\phi(x) = - \sum_{i=1}^m \log(-f_i(x)), \quad \mathbf{dom} \phi = \{x \mid f_1(x) < 0, \dots, f_m(x) < 0\}$$

- 根据组合规则为凸函数
- 二阶可微连续函数，导数为





# 对数障碍函数



$$\phi(x) = - \sum_{i=1}^m \log(-f_i(x)), \quad \mathbf{dom} \phi = \{x \mid f_1(x) < 0, \dots, f_m(x) < 0\}$$

- 根据组合规则为凸函数
- 二阶可微连续函数，导数为

$$\nabla \phi(x) = \sum_{i=1}^m \frac{1}{-f_i(x)} \nabla f_i(x)$$

$$\nabla^2 \phi(x) = \sum_{i=1}^m \frac{1}{f_i(x)^2} \nabla f_i(x) \nabla f_i(x)^T + \sum_{i=1}^m \frac{1}{-f_i(x)} \nabla^2 f_i(x)$$



# 中心路径

---





# 中心路径



□ 对  $t > 0$ , 定义  $x^*(t)$  为如下问题的解



# 中心路径



□ 对  $t > 0$ , 定义  $x^*(t)$  为如下问题的解

$$\begin{array}{ll} \text{minimize} & t f_0(x) + \phi(x) \\ \text{subject to} & Ax = b \end{array}$$



# 中心路径



□ 对  $t > 0$ , 定义  $x^*(t)$  为如下问题的解

$$\begin{array}{ll} \text{minimize} & t f_0(x) + \phi(x) \\ \text{subject to} & Ax = b \end{array}$$

□ (此时, 假设  $x^*(t)$  存在且唯一)



# 中心路径



□ 对  $t > 0$ , 定义  $x^*(t)$  为如下问题的解

$$\begin{array}{ll} \text{minimize} & t f_0(x) + \phi(x) \\ \text{subject to} & Ax = b \end{array}$$

□ (此时, 假设  $x^*(t)$  存在且唯一)

□ 中心路径为  $\{x^*(t) \mid t > 0\}$



# 中心路径



□ 对  $t > 0$ , 定义  $x^*(t)$  为如下问题的解

$$\begin{aligned} & \text{minimize} && t f_0(x) + \phi(x) \\ & \text{subject to} && Ax = b \end{aligned}$$

□ (此时, 假设  $x^*(t)$  存在且唯一)

□ 中心路径为  $\{x^*(t) \mid t > 0\}$

$$\begin{aligned} & \text{minimize} && c^T x \\ & \text{subject to} && a_i^T x \leq b_i, \quad i = 1, \dots, 6 \end{aligned}$$



# 中心路径



□ 对  $t > 0$ , 定义  $x^*(t)$  为如下问题的解

$$\begin{array}{ll} \text{minimize} & t f_0(x) + \phi(x) \\ \text{subject to} & Ax = b \end{array}$$

□ (此时, 假设  $x^*(t)$  存在且唯一)

□ 中心路径为  $\{x^*(t) \mid t > 0\}$

$$\begin{array}{ll} \text{minimize} & c^T x \\ \text{subject to} & a_i^T x \leq b_i, \quad i = 1, \dots, 6 \end{array}$$

□ 超平面  $c^T x = c^T x^*(t)$  与  $\phi$  的等值线





# 中心路径



□ 对  $t > 0$ , 定义  $x^*(t)$  为如下问题的解

$$\begin{aligned} & \text{minimize} && t f_0(x) + \phi(x) \\ & \text{subject to} && Ax = b \end{aligned}$$

□ (此时, 假设  $x^*(t)$  存在且唯一)

□ 中心路径为  $\{x^*(t) \mid t > 0\}$

$$\begin{aligned} & \text{minimize} && c^T x \\ & \text{subject to} && a_i^T x \leq b_i, \quad i = 1, \dots, 6 \end{aligned}$$

□ 超平面  $c^T x = c^T x^*(t)$  与  $\phi$  的等值线

□ 相切于  $x^*(t)$



# 中心路径



□ 对  $t > 0$ , 定义  $x^*(t)$  为如下问题的解

$$\begin{aligned} & \text{minimize} && t f_0(x) + \phi(x) \\ & \text{subject to} && Ax = b \end{aligned}$$


□ (此时, 假设  $x^*(t)$  存在且唯一)

□ 中心路径为  $\{x^*(t) \mid t > 0\}$

$$\begin{aligned} & \text{minimize} && c^T x \\ & \text{subject to} && a_i^T x \leq b_i, \quad i = 1, \dots, 6 \end{aligned}$$

□ 超平面  $c^T x = c^T x^*(t)$  与  $\phi$  的等值线

□ 相切于  $x^*(t)$





# 中心路径的对偶点

---





# 中心路径的对偶点



□  $x = x^*(t)$ , 若存在  $w$  满足



# 中心路径的对偶点



□  $x = x^*(t)$ , 若存在  $w$  满足

$$t \nabla f_0(x) + \sum_{i=1}^m \frac{1}{-f_i(x)} \nabla f_i(x) + A^T w = 0, \quad Ax = b$$



# 中心路径的对偶点



□  $x = x^*(t)$ , 若存在  $w$  满足

$$t \nabla f_0(x) + \sum_{i=1}^m \frac{1}{-f_i(x)} \nabla f_i(x) + A^T w = 0, \quad Ax = b$$

□ 因此,  $x^*(t)$  最小化 **Lagrangian** 函数



# 中心路径的对偶点



□  $x = x^*(t)$ , 若存在  $w$  满足

$$t \nabla f_0(x) + \sum_{i=1}^m \frac{1}{-f_i(x)} \nabla f_i(x) + A^T w = 0, \quad Ax = b$$

□ 因此,  $x^*(t)$  最小化 **Lagrangian** 函数

$$L(x, \lambda^*(t), \nu^*(t)) = f_0(x) + \sum_{i=1}^m \lambda_i^*(t) f_i(x) + \nu^*(t)^T (Ax - b)$$



# 中心路径的对偶点



□  $x = x^*(t)$ , 若存在  $w$  满足

$$t \nabla f_0(x) + \sum_{i=1}^m \frac{1}{-f_i(x)} \nabla f_i(x) + A^T w = 0, \quad Ax = b$$

□ 因此,  $x^*(t)$  最小化 **Lagrangian** 函数

$$L(x, \lambda^*(t), \nu^*(t)) = f_0(x) + \sum_{i=1}^m \lambda_i^*(t) f_i(x) + \nu^*(t)^T (Ax - b)$$

□ 其中, 定义  $\lambda_i^*(t) = 1/(-t f_i(x^*(t)))$  and  $\nu^*(t) = w/t$





# 中心路径的对偶点



□  $x = x^*(t)$ , 若存在  $w$  满足

$$t \nabla f_0(x) + \sum_{i=1}^m \frac{1}{-f_i(x)} \nabla f_i(x) + A^T w = 0, \quad Ax = b$$

□ 因此,  $x^*(t)$  最小化 **Lagrangian** 函数

$$L(x, \lambda^*(t), \nu^*(t)) = f_0(x) + \sum_{i=1}^m \lambda_i^*(t) f_i(x) + \nu^*(t)^T (Ax - b)$$

□ 其中, 定义  $\lambda_i^*(t) = 1/(-t f_i(x^*(t)))$  and  $\nu^*(t) = w/t$

□ 这确认了直观的想法:  $f_0(x^*(t)) \rightarrow p^*$



# 中心路径的对偶点



□  $x = x^*(t)$ , 若存在  $w$  满足

$$t \nabla f_0(x) + \sum_{i=1}^m \frac{1}{-f_i(x)} \nabla f_i(x) + A^T w = 0, \quad Ax = b$$

□ 因此,  $x^*(t)$  最小化 **Lagrangian** 函数

$$L(x, \lambda^*(t), \nu^*(t)) = f_0(x) + \sum_{i=1}^m \lambda_i^*(t) f_i(x) + \nu^*(t)^T (Ax - b)$$

□ 其中, 定义  $\lambda_i^*(t) = 1/(-t f_i(x^*(t)))$  and  $\nu^*(t) = w/t$

□ 这确认了直观的想法:  $f_0(x^*(t)) \rightarrow p^*$

$$\begin{aligned} p^* &\geq g(\lambda^*(t), \nu^*(t)) \\ &= L(x^*(t), \lambda^*(t), \nu^*(t)) \\ &= f_0(x^*(t)) - m/t \end{aligned}$$



# 基于KKT条件的解释

---





# 基于KKT条件的解释



□  $x = x^*(t), \lambda = \lambda^*(t), \nu = \nu^*(t)$  满足



# 基于KKT条件的解释



- $x = x^*(t), \lambda = \lambda^*(t), \nu = \nu^*(t)$  满足
- 原约束:  $f_i(x) \leq 0, i = 1, \dots, m, Ax = b$



# 基于KKT条件的解释



- $x = x^*(t), \lambda = \lambda^*(t), \nu = \nu^*(t)$  满足
- 原约束:  $f_i(x) \leq 0, i = 1, \dots, m, Ax = b$
- 对偶约束:  $\lambda \succeq 0$



# 基于KKT条件的解释



- $x = x^*(t), \lambda = \lambda^*(t), \nu = \nu^*(t)$  满足
- 原约束:  $f_i(x) \leq 0, i = 1, \dots, m, Ax = b$
- 对偶约束:  $\lambda \succeq 0$
- 互补松弛条件:  $-\lambda_i f_i(x) = 1/t, i = 1, \dots, m$



# 基于KKT条件的解释



- $x = x^*(t), \lambda = \lambda^*(t), \nu = \nu^*(t)$  满足
- 原约束:  $f_i(x) \leq 0, i = 1, \dots, m, Ax = b$
- 对偶约束:  $\lambda \succeq 0$
- 互补松弛条件:  $-\lambda_i f_i(x) = 1/t, i = 1, \dots, m$
- **Lagrangian**函数的梯度





# 基于KKT条件的解释



- $x = x^*(t), \lambda = \lambda^*(t), \nu = \nu^*(t)$  满足
- 原约束:  $f_i(x) \leq 0, i = 1, \dots, m, Ax = b$
- 对偶约束:  $\lambda \succeq 0$
- 互补松弛条件:  $-\lambda_i f_i(x) = 1/t, i = 1, \dots, m$
- **Lagrangian**函数的梯度

$$\nabla f_0(x) + \sum_{i=1}^m \lambda_i \nabla f_i(x) + A^T \nu = 0$$



# 基于KKT条件的解释



- $x = x^*(t), \lambda = \lambda^*(t), \nu = \nu^*(t)$  满足
- 原约束:  $f_i(x) \leq 0, i = 1, \dots, m, Ax = b$
- 对偶约束:  $\lambda \succeq 0$
- 互补松弛条件:  $-\lambda_i f_i(x) = 1/t, i = 1, \dots, m$
- **Lagrangian**函数的梯度

$$\nabla f_0(x) + \sum_{i=1}^m \lambda_i \nabla f_i(x) + A^T \nu = 0$$

- 和**KKT**的不同是条件**3**替换了  $\lambda_i f_i(x) = 0$



# 障碍法





# 障碍法



算法 11.1 障碍方法。

给定严格可行点  $x$ ,  $t := t^{(0)} > 0$ ,  $\mu > 1$ , 误差阈值  $\epsilon > 0$ 。

重复进行

1. 中心点步骤。

从  $x$  开始, 在  $Ax = b$  的约束下极小化  $tf_0 + \phi$ , 最终确定  $x^*(t)$ 。

2. 改进。  $x := x^*(t)$ 。

3. 停止准则。如果  $m/t < \epsilon$  则退出。

4. 增加  $t$ 。  $t := \mu t$ 。



# 障碍法



算法 11.1 障碍方法。

给定严格可行点  $x$ ,  $t := t^{(0)} > 0$ ,  $\mu > 1$ , 误差阈值  $\epsilon > 0$ 。

重复进行

1. 中心点步骤。

从  $x$  开始, 在  $Ax = b$  的约束下极小化  $tf_0 + \phi$ , 最终确定  $x^*(t)$ 。

2. 改进。  $x := x^*(t)$ 。

3. 停止准则。如果  $m/t < \epsilon$  则退出。

4. 增加  $t$ 。  $t := \mu t$ 。

□ 终结时,  $f_0(x) - p^* \leq \epsilon$  停止条件来自  $f_0(x^*(t)) - p^* \leq m/t$



# 障碍法



算法 11.1 障碍方法。

给定严格可行点  $x$ ,  $t := t^{(0)} > 0$ ,  $\mu > 1$ , 误差阈值  $\epsilon > 0$ 。

重复进行

1. 中心点步骤。

从  $x$  开始, 在  $Ax = b$  的约束下极小化  $tf_0 + \phi$ , 最终确定  $x^*(t)$ 。

2. 改进。  $x := x^*(t)$ 。

3. 停止准则。如果  $m/t < \epsilon$  则退出。

4. 增加  $t$ 。  $t := \mu t$ 。

- 终结时,  $f_0(x) - p^* \leq \epsilon$  停止条件来自  $f_0(x^*(t)) - p^* \leq m/t$
- 使用**Newton**方法完成中心点步骤, 从当前点 $x$ 开始



# 障碍法



## 算法 11.1 障碍方法。

给定严格可行点  $x$ ,  $t := t^{(0)} > 0$ ,  $\mu > 1$ , 误差阈值  $\epsilon > 0$ 。

重复进行

1. 中心点步骤。

从  $x$  开始, 在  $Ax = b$  的约束下极小化  $tf_0 + \phi$ , 最终确定  $x^*(t)$ 。

2. 改进。  $x := x^*(t)$ 。

3. 停止准则。如果  $m/t < \epsilon$  则退出。

4. 增加  $t$ 。  $t := \mu t$ 。

- 终结时,  $f_0(x) - p^* \leq \epsilon$  停止条件来自  $f_0(x^*(t)) - p^* \leq m/t$
- 使用**Newton**方法完成中心点步骤, 从当前点 $x$ 开始
- $\mu$ 的选择需要权衡: 取大表示较少的外部循环, 更多的内部训练; 通常设置为  $\mu = 10-20$



# 障碍法



## 算法 11.1 障碍方法。

给定严格可行点  $x$ ,  $t := t^{(0)} > 0$ ,  $\mu > 1$ , 误差阈值  $\epsilon > 0$ 。

重复进行

1. 中心点步骤。

从  $x$  开始, 在  $Ax = b$  的约束下极小化  $tf_0 + \phi$ , 最终确定  $x^*(t)$ 。

2. 改进。  $x := x^*(t)$ 。

3. 停止准则。如果  $m/t < \epsilon$  则退出。

4. 增加  $t$ 。  $t := \mu t$ 。

- 终结时,  $f_0(x) - p^* \leq \epsilon$  停止条件来自  $f_0(x^*(t)) - p^* \leq m/t$
- 使用**Newton**方法完成中心点步骤, 从当前点 $x$ 开始
- $\mu$ 的选择需要权衡: 取大表示较少的外部循环, 更多的内部训练; 通常设置为  $\mu = 10-20$
- 初始点选择有很多启发式策略





# 收敛性分析

---





# 收敛性分析



□ 外部训练的次数：精确的



# 收敛性分析



□ 外部训练的次数：精确的

$$\left\lceil \frac{\log(m/(\epsilon t^{(0)}))}{\log \mu} \right\rceil$$



# 收敛性分析



- 外部训练的次数：精确的

$$\left\lceil \frac{\log(m/(\epsilon t^{(0)}))}{\log \mu} \right\rceil$$

- 加上初始化中心点步骤

$$\text{minimize } t f_0(x) + \phi(x)$$



# 收敛性分析



- 外部训练的次数：精确的

$$\left\lceil \frac{\log(m/(\epsilon t^{(0)}))}{\log \mu} \right\rceil$$

- 加上初始化中心点步骤

- 中心点步骤 minimize  $t f_0(x) + \phi(x)$



# 收敛性分析



- 外部训练的次数：精确的

$$\left\lceil \frac{\log(m/(\epsilon t^{(0)}))}{\log \mu} \right\rceil$$

- 加上初始化中心点步骤
- 中心点步骤 minimize  $t f_0(x) + \phi(x)$
- 见**Newton**法的收敛性分析



# 收敛性分析



- 外部训练的次数：精确的

$$\left\lceil \frac{\log(m/(\epsilon t^{(0)}))}{\log \mu} \right\rceil$$

- 加上初始化中心点步骤
- 中心点步骤 minimize  $tf_0(x) + \phi(x)$
- 见**Newton**法的收敛性分析
- 对  $t \geq t^{(0)}$  ,  $tf_0 + \phi$  必须有闭的下水平集



# 收敛性分析



- 外部训练的次数：精确的

$$\left\lceil \frac{\log(m/(\epsilon t^{(0)}))}{\log \mu} \right\rceil$$

- 加上初始化中心点步骤
- 中心点步骤 minimize  $tf_0(x) + \phi(x)$
- 见**Newton**法的收敛性分析
- 对  $t \geq t^{(0)}$  ,  $tf_0 + \phi$  必须有闭的下水平集
- 经典分析需要强凸性、**Lipschitz**条件





# 收敛性分析



- 外部训练的次数：精确的

$$\left\lceil \frac{\log(m/(\epsilon t^{(0)}))}{\log \mu} \right\rceil$$

- 加上初始化中心点步骤
- 中心点步骤 minimize  $tf_0(x) + \phi(x)$
- 见**Newton**法的收敛性分析
- 对  $t \geq t^{(0)}$  ,  $tf_0 + \phi$  必须有闭的下水平集
- 经典分析需要强凸性、**Lipschitz**条件
- 基于自适应的分析需要  $tf_0 + \phi$  为自适应函数



# 例





# 例





- 不等式形式的线性规划 ( $m=100$ 个不等式,  $n=50$ 个优化变量)



# 例



□ 不等式形式的线性规划 ( $m=100$ 个不等式,  $n=50$ 个优化变量)







# 例



- 不等式形式的线性规划 ( $m=100$ 个不等式,  $n=50$ 个优化变量)





- 从中心路径的点 $x$ 开始 ( $t^{(0)} = 1$ , 对偶间隙为**100**)



# 例



- 不等式形式的线性规划 ( $m=100$ 个不等式,  $n=50$ 个优化变量)





- 从中心路径的点 $x$ 开始 ( $t^{(0)} = 1$ , 对偶间隙为**100**)
- 当 $t=10^8$ 时, 停止



# 例



- 不等式形式的线性规划 ( $m=100$ 个不等式,  $n=50$ 个优化变量)





- 从中心路径的点 $x$ 开始 ( $t^{(0)} = 1$ , 对偶间隙为**100**)
- 当 $t=10^8$ 时, 停止
- 中心点步骤使用带回溯的**Newton**法



# 例



- 不等式形式的线性规划 ( $m=100$ 个不等式,  $n=50$ 个优化变量)



- 从中心路径的点 $x$ 开始 ( $t^{(0)} = 1$ , 对偶间隙为**100**)
- 当 $t=10^8$ 时, 停止
- 中心点步骤使用带回溯的**Newton**法
- 若  $\mu \geq 10$ , **Newton**法的整体迭代次数不会太敏感





# 一簇标准的线性规划

---





# 一簇标准的线性规划



---

$$\begin{array}{ll} \text{minimize} & c^T x \\ \text{subject to} & Ax = b, \quad x \succeq 0 \end{array}$$




# 一簇标准的线性规划



$$\begin{aligned} & \text{minimize} && c^T x \\ & \text{subject to} && Ax = b, \quad x \succeq 0 \end{aligned}$$

□  $m=10, \dots, 1000$ ; 对每一个  $m$ , 求解100个随机生成的实例



□ 当问题维数变化比值为**100:1**时, 迭代次数增长的较为缓慢



# 可行性和阶段1方法

---





# 可行性和阶段1方法



□ 可行性问题：寻找 $x$ 满足  $f_i(x) \leq 0, \quad i = 1, \dots, m, \quad Ax = b$



# 可行性和阶段1方法



- 可行性问题：寻找 $x$ 满足  $f_i(x) \leq 0, \quad i = 1, \dots, m, \quad Ax = b$
- 阶段1:为障碍法计算研究可行的起始点



# 可行性和阶段1方法



- 可行性问题：寻找 $x$ 满足  $f_i(x) \leq 0, \quad i = 1, \dots, m, \quad Ax = b$
- 阶段1:为障碍法计算研究可行的起始点
- 基本阶段1方法



# 可行性和阶段1方法



- 可行性问题：寻找 $x$ 满足  $f_i(x) \leq 0, \quad i = 1, \dots, m, \quad Ax = b$
- 阶段1:为障碍法计算研究可行的起始点
- 基本阶段1方法

$$\begin{array}{ll} \text{minimize (over } x, s) & s \\ \text{subject to} & f_i(x) \leq s, \quad i = 1, \dots, m \\ & Ax = b \end{array}$$





# 可行性和阶段1方法



□ 可行性问题：寻找 $x$ 满足  $f_i(x) \leq 0, \quad i = 1, \dots, m, \quad Ax = b$

□ 阶段1:为障碍法计算研究可行的起始点

□ 基本阶段1方法

$$\begin{array}{ll} \text{minimize (over } x, s) & s \\ \text{subject to} & f_i(x) \leq s, \quad i = 1, \dots, m \\ & Ax = b \end{array}$$

□ 若 $x, s$ 可行，且 $s < 0$ ，则 $x$ 是严格可行的



# 可行性和阶段1方法



□ 可行性问题：寻找 $x$ 满足  $f_i(x) \leq 0, \quad i = 1, \dots, m, \quad Ax = b$

□ 阶段1:为障碍法计算研究可行的起始点

□ 基本阶段1方法

$$\begin{array}{ll} \text{minimize (over } x, s) & s \\ \text{subject to} & f_i(x) \leq s, \quad i = 1, \dots, m \\ & Ax = b \end{array}$$

□ 若 $x, s$ 可行，且 $s < 0$ ，则 $x$ 是严格可行的

□ 若最优值为正，则问题为非可行性的



# 可行性和阶段1方法



- 可行性问题：寻找 $x$ 满足  $f_i(x) \leq 0, \quad i = 1, \dots, m, \quad Ax = b$
- 阶段1:为障碍法计算研究可行的起始点
- 基本阶段1方法

$$\begin{array}{ll} \text{minimize (over } x, s) & s \\ \text{subject to} & f_i(x) \leq s, \quad i = 1, \dots, m \\ & Ax = b \end{array}$$

- 若 $x, s$ 可行，且 $s < 0$ ，则 $x$ 是严格可行的
- 若最优值为正，则问题为非可行性的
- 若最优值为0且存在，则问题为可行的（但不是严格可行的）



# 可行性和阶段1方法



- 可行性问题：寻找 $x$ 满足  $f_i(x) \leq 0, \quad i = 1, \dots, m, \quad Ax = b$
- 阶段1:为障碍法计算研究可行的起始点
- 基本阶段1方法

$$\begin{array}{ll} \text{minimize (over } x, s) & s \\ \text{subject to} & f_i(x) \leq s, \quad i = 1, \dots, m \\ & Ax = b \end{array}$$

- 若 $x, s$ 可行，且 $s < 0$ ，则 $x$ 是严格可行的
- 若最优值为正，则问题为非可行性的
- 若最优值为0且存在，则问题为可行的（但不是严格可行的）
- 若最优值为0且不可达，则问题为非可行的



# 不可行值之和





# 不可行值之和



---

minimize  $\mathbf{1}^T s$   
subject to  $s \succeq 0, \quad f_i(x) \leq s_i, \quad i = 1, \dots, m$   
 $Ax = b$





# 不可行值之和



$$\begin{aligned} & \text{minimize} && \mathbf{1}^T s \\ & \text{subject to} && s \succeq 0, \quad f_i(x) \leq s_i, \quad i = 1, \dots, m \\ & && Ax = b \end{aligned}$$

- 对不可行点，比基本阶段1方法产生满足更多不等式约束的解
- 例（由**50**个变量和**100**个线性不等式构成的不可行集）



- 左图：基本阶段1方法，满足**39**个不等式
- 右图：不可行值之和，满足**79**个不等式



# 例：一族线性不等式

---







# 例：一族线性不等式



$$Ax \preceq b + \gamma \Delta b$$



# 例：一族线性不等式



$$Ax \preceq b + \gamma \Delta b$$

□ 所需的数据对  $\gamma > 0$  是严格可行的，对  $\gamma \leq 0$  是不可行的



# 例：一族线性不等式



$$Ax \preceq b + \gamma \Delta b$$

- 所需的数据对  $\gamma > 0$  是严格可行的，对  $\gamma \leq 0$  是不可行的
- 使用基本阶段1方法，当  $s < 0$  或对偶目标为正时，结束




# 例：一族线性不等式





$$Ax \preceq b + \gamma \Delta b$$

- 所需的数据对  $\gamma > 0$  是严格可行的，对  $\gamma \leq 0$  是不可行的
- 使用基本阶段1方法，当  $s < 0$  或对偶目标为正时，结束



$\log(1/|\gamma|)$





# 基于自和谐条件的复杂性分析

---





# 基于自和谐条件的复杂性分析

---



□ 假设：



# 基于自和谐条件的复杂性分析

---



- 假设:
- 水平子集有界



# 基于自和谐条件的复杂性分析



- 假设：
- 水平子集有界
- 所有的  $tf_0 + \phi$  为自和谐函数，且是闭的





# 基于自和谐条件的复杂性分析



- 假设：
- 水平子集有界
- 所有的  $tf_0 + \phi$  为自和谐函数，且是闭的
  - 对线性规划、二次规划等很多问题均成立



# 基于自和谐条件的复杂性分析



- 假设：
- 水平子集有界
- 所有的  $tf_0 + \phi$  为自和谐函数，且是闭的
  - 对线性规划、二次规划等很多问题均成立
  - 或许需要重形式化问题，



# 基于自和谐条件的复杂性分析



- 假设：
- 水平子集有界
- 所有的  $tf_0 + \phi$  为自和谐函数，且是闭的
  - 对线性规划、二次规划等很多问题均成立
  - 或许需要重形式化问题，

$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n x_i \log x_i \\ \text{subject to} & Fx \preceq g \end{array} \quad \longrightarrow \quad \begin{array}{ll} \text{minimize} & \sum_{i=1}^n x_i \log x_i \\ \text{subject to} & Fx \preceq g, \quad x \succeq 0 \end{array}$$



# 基于自和谐条件的复杂性分析



- 假设：
- 水平子集有界
- 所有的  $tf_0 + \phi$  为自和谐函数，且是闭的
  - 对线性规划、二次规划等很多问题均成立
  - 或许需要重形式化问题，


$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n x_i \log x_i \\ \text{subject to} & Fx \preceq g \end{array} \quad \longrightarrow \quad \begin{array}{ll} \text{minimize} & \sum_{i=1}^n x_i \log x_i \\ \text{subject to} & Fx \preceq g, \quad x \succeq 0 \end{array}$$

- 可用于复杂性分析；当不采用自和谐条件时，障碍法仍然有效



# 中心点步骤的Newton迭代次数


---





# 中心点步骤的Newton迭代次数


---



- 根据自和谐理论



# 中心点步骤的Newton迭代次数




□ 根据自和谐理论

$$\# \text{Newton iterations} \leq \frac{\mu t f_0(x) + \phi(x) - \mu t f_0(x^+) - \phi(x^+)}{\gamma} + c$$



# 中心点步骤的Newton迭代次数



□ 根据自和谐理论


$$\# \text{Newton iterations} \leq \frac{\mu t f_0(x) + \phi(x) - \mu t f_0(x^+) - \phi(x^+)}{\gamma} + c$$

□ 以  $x = x^*(t)$  为起始点计算  $x^+ = x^*(\mu t)$  的代价上界





# 中心点步骤的Newton迭代次数




- 根据自和谐理论

$$\# \text{Newton iterations} \leq \frac{\mu t f_0(x) + \phi(x) - \mu t f_0(x^+) - \phi(x^+)}{\gamma} + c$$

- 以  $x = x^*(t)$  为起始点计算  $x^+ = x^*(\mu t)$  的代价上界
- $\gamma, c$  为常数（取决于很多Newton算法参数）



# 中心点步骤的Newton迭代次数



- 根据自和谐理论

$$\# \text{Newton iterations} \leq \frac{\mu t f_0(x) + \phi(x) - \mu t f_0(x^+) - \phi(x^+)}{\gamma} + c$$

- 以  $x = x^*(t)$  为起始点计算  $x^+ = x^*(\mu t)$  的代价上界
- $\gamma, c$  为常数（取决于很多Newton算法参数）
- 根据对偶性（其中,  $\lambda = \lambda^*(t), \nu = \nu^*(t)$ ）



# 中心点步骤的Newton迭代次数



□ 根据自和谐理论

$$\# \text{Newton iterations} \leq \frac{\mu t f_0(x) + \phi(x) - \mu t f_0(x^+) - \phi(x^+)}{\gamma} + c$$

□ 以  $x = x^*(t)$  为起始点计算  $x^+ = x^*(\mu t)$  的代价上界

□  $\gamma, c$  为常数（取决于很多Newton算法参数）

□ 根据对偶性（其中， $\lambda = \lambda^*(t), \nu = \nu^*(t)$ ）

$$\begin{aligned} & \mu t f_0(x) + \phi(x) - \mu t f_0(x^+) - \phi(x^+) \\ &= \mu t f_0(x) - \mu t f_0(x^+) + \sum_{i=1}^m \log(-\mu t \lambda_i f_i(x^+)) - m \log \mu \\ &\leq \mu t f_0(x) - \mu t f_0(x^+) - \mu t \sum_{i=1}^m \lambda_i f_i(x^+) - m - m \log \mu \\ &\leq \mu t f_0(x) - \mu t g(\lambda, \nu) - m - m \log \mu \\ &= m(\mu - 1 - \log \mu) \end{aligned}$$



# 总的Newton迭代次数

---





# 总的Newton迭代次数



$$\# \text{Newton iterations} \leq N = \left\lceil \frac{\log(m/(t^{(0)}\epsilon))}{\log \mu} \right\rceil \left( \frac{m(\mu - 1 - \log \mu)}{\gamma} + c \right)$$




figure shows  $N$  for typical values of  $\gamma, c$ ,

$$m = 100, \quad \frac{m}{t^{(0)}\epsilon} = 10^5$$



# 总的Newton迭代次数



$$\# \text{Newton iterations} \leq N = \left\lceil \frac{\log(m/(t^{(0)}\epsilon))}{\log \mu} \right\rceil \left( \frac{m(\mu - 1 - \log \mu)}{\gamma} + c \right)$$




figure shows  $N$  for typical values of  $\gamma, c$ ,

$$m = 100, \quad \frac{m}{t^{(0)}\epsilon} = 10^5$$

□ 确认关于参数  $\mu$  的权衡



# 总的Newton迭代次数



$$\# \text{Newton iterations} \leq N = \left\lceil \frac{\log(m/(t^{(0)}\epsilon))}{\log \mu} \right\rceil \left( \frac{m(\mu - 1 - \log \mu)}{\gamma} + c \right)$$




figure shows  $N$  for typical values of  $\gamma, c$ ,

$$m = 100, \quad \frac{m}{t^{(0)}\epsilon} = 10^5$$

- 确认关于参数  $\mu$  的权衡
- 实际上，迭代参数数十次的量，当  $\mu \geq 10$  不敏感



# 障碍法的多项式复杂度

---







# 障碍法的多项式复杂度



□ 根据  $\mu = 1 + 1/\sqrt{m}$ :



# 障碍法的多项式复杂度



□ 根据  $\mu = 1 + 1/\sqrt{m}$ :

$$N = O\left(\sqrt{m} \log\left(\frac{m/t^{(0)}}{\epsilon}\right)\right)$$



# 障碍法的多项式复杂度



□ 根据  $\mu = 1 + 1/\sqrt{m}$ :

$$N = O\left(\sqrt{m} \log\left(\frac{m/t^{(0)}}{\epsilon}\right)\right)$$

□ 固定间隙压缩的**Newton**法的迭代次数为  $O(\sqrt{m})$



# 障碍法的多项式复杂度



□ 根据  $\mu = 1 + 1/\sqrt{m}$ :

$$N = O\left(\sqrt{m} \log\left(\frac{m/t^{(0)}}{\epsilon}\right)\right)$$

- 固定间隙压缩的**Newton**法的迭代次数为  $O(\sqrt{m})$
- 乘以一次**Newton**迭代的代价，得到浮点运算次数的上界



# 障碍法的多项式复杂度



- 根据  $\mu = 1 + 1/\sqrt{m}$ :

$$N = O\left(\sqrt{m} \log\left(\frac{m/t^{(0)}}{\epsilon}\right)\right)$$

- 固定间隙压缩的**Newton**法的迭代次数为  $O(\sqrt{m})$
- 乘以一次**Newton**迭代的代价，得到浮点运算次数的上界
- $\mu$  的选择优化了最坏情况的复杂性；事实上，设置  $\mu$  为固定值



# 原-对偶内点法

---





# 原-对偶内点法



- 当需要高性能时，比障碍法更为有效



# 原-对偶内点法



- 当需要高性能时，比障碍法更为有效
- 每次迭代更新原问题和对偶问题的变量；不区分内部和外部迭代





# 原-对偶内点法



- 当需要高性能时，比障碍法更为有效
- 每次迭代更新原问题和对偶问题的变量；不区分内部和外部迭代
- 通常展现出超线性收敛性质



# 原-对偶内点法



- 当需要高性能时，比障碍法更为有效
- 每次迭代更新原问题和对偶问题的变量；不区分内部和外部迭代
- 通常展现出超线性收敛性质
- 搜索方向可以理解为**Newton**方向，来处理修改的**KKT**条件



# 原-对偶内点法



- 当需要高性能时，比障碍法更为有效
- 每次迭代更新原问题和对偶问题的变量；不区分内部和外部迭代
- 通常展现出超线性收敛性质
- 搜索方向可以理解为**Newton**方向，来处理修改的**KKT**条件
- 可以从非可行点开始



# 原-对偶内点法



- 当需要高性能时，比障碍法更为有效
- 每次迭代更新原问题和对偶问题的变量；不区分内部和外部迭代
- 通常展现出超线性收敛性质
- 搜索方向可以理解为**Newton**方向，来处理修改的**KKT**条件
- 可以从非可行点开始
- 每次迭代的计算代价和障碍法相同