



---

# 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)



# 等式约束优化




- 等式约束优化问题
- 消去等式约束
- 带有等式约束的**Newton**方法
- 不可行初始点的**Newton**方法
- 实现



# 等式约束优化问题

---





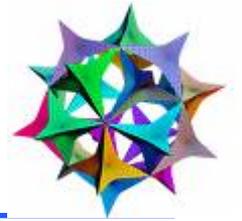
# 等式约束优化问题



$$\begin{array}{ll} \text{minimize} & f(x) \\ \text{subject to} & Ax = b \end{array}$$



# 等式约束优化问题



$$\begin{array}{ll} \text{minimize} & f(x) \\ \text{subject to} & Ax = b \end{array}$$

- 函数 $f$ 为凸函数，二次连续可微



# 等式约束优化问题




$$\begin{array}{ll} \text{minimize} & f(x) \\ \text{subject to} & Ax = b \end{array}$$

- 函数 $f$ 为凸函数，二次连续可微
- $A \in R^{p \times n}$ ，秩 $\text{rank}A = p$



# 等式约束优化问题



$$\begin{array}{ll} \text{minimize} & f(x) \\ \text{subject to} & Ax = b \end{array}$$

- 函数 $f$ 为凸函数，二次连续可微
- $A \in R^{p \times n}$ ，秩 $\text{rank}A = p$
- 假设最优值 $p^*$ 有限且存在



# 等式约束优化问题



$$\begin{array}{ll} \text{minimize} & f(x) \\ \text{subject to} & Ax = b \end{array}$$

- 函数 $f$ 为凸函数，二次连续可微
- $A \in R^{p \times n}$ ，秩 $\text{rank}A = p$
- 假设最优值 $p^*$ 有限且存在
- 最优条件： $x^*$ 为最优解，当且仅当存在 $v^*$ 满足



# 等式约束优化问题



$$\begin{array}{ll} \text{minimize} & f(x) \\ \text{subject to} & Ax = b \end{array}$$


- 函数 $f$ 为凸函数，二次连续可微
- $A \in R^{p \times n}$ ，秩 $\text{rank}A = p$
- 假设最优值 $p^*$ 有限且存在
- 最优条件： $x^*$ 为最优解，当且仅当存在 $\nu^*$ 满足

$$\nabla f(x^*) + A^T \nu^* = 0, \quad Ax^* = b$$



# 等式约束凸二次规划

---





# 等式约束凸二次规划



---

$$\begin{array}{ll} \text{minimize} & (1/2)x^T P x + q^T x + r \\ \text{subject to} & A x = b \end{array}$$



# 等式约束凸二次规划



$$\begin{array}{ll} \text{minimize} & (1/2)x^T P x + q^T x + r \\ \text{subject to} & Ax = b \end{array}$$

□ 最优化条件：



# 等式约束凸二次规划




$$\begin{aligned} & \text{minimize} && (1/2)x^T P x + q^T x + r \\ & \text{subject to} && A x = b \end{aligned}$$

□ 最优化条件:

$$\begin{bmatrix} P & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} x^* \\ \nu^* \end{bmatrix} = \begin{bmatrix} -q \\ b \end{bmatrix}$$



# 等式约束凸二次规划



$$\begin{aligned} & \text{minimize} && (1/2)x^T P x + q^T x + r \\ & \text{subject to} && Ax = b \end{aligned}$$


□ 最优化条件:

$$\begin{bmatrix} P & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} x^* \\ \nu^* \end{bmatrix} = \begin{bmatrix} -q \\ b \end{bmatrix}$$

□ 系数矩阵成为**KKT**矩阵



# 等式约束凸二次规划



$$\begin{aligned} & \text{minimize} && (1/2)x^T P x + q^T x + r \\ & \text{subject to} && A x = b \end{aligned}$$

□ 最优化条件:


$$\begin{bmatrix} P & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} x^* \\ \nu^* \end{bmatrix} = \begin{bmatrix} -q \\ b \end{bmatrix}$$

□ 系数矩阵成为**KKT**矩阵

□ **KKT**矩阵为非奇异，当且仅当



# 等式约束凸二次规划



$$\begin{aligned} & \text{minimize} && (1/2)x^T P x + q^T x + r \\ & \text{subject to} && A x = b \end{aligned}$$

□ 最优化条件:

$$\begin{bmatrix} P & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} x^* \\ \nu^* \end{bmatrix} = \begin{bmatrix} -q \\ b \end{bmatrix}$$


□ 系数矩阵成为**KKT**矩阵

□ **KKT**矩阵为非奇异, 当且仅当

$$A x = 0, \quad x \neq 0 \quad \implies \quad x^T P x > 0$$



# 等式约束凸二次规划



$$\begin{array}{ll} \text{minimize} & (1/2)x^T P x + q^T x + r \\ \text{subject to} & A x = b \end{array}$$

□ 最优化条件:

$$\begin{bmatrix} P & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} x^* \\ \nu^* \end{bmatrix} = \begin{bmatrix} -q \\ b \end{bmatrix}$$

□ 系数矩阵成为**KKT**矩阵

□ **KKT**矩阵为非奇异, 当且仅当

$$A x = 0, \quad x \neq 0 \quad \implies \quad x^T P x > 0$$

□ 非奇异的等价条件:



# 等式约束凸二次规划



$$\begin{aligned} & \text{minimize} && (1/2)x^T P x + q^T x + r \\ & \text{subject to} && A x = b \end{aligned}$$

□ 最优化条件:

$$\begin{bmatrix} P & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} x^* \\ \nu^* \end{bmatrix} = \begin{bmatrix} -q \\ b \end{bmatrix}$$

□ 系数矩阵成为**KKT**矩阵

□ **KKT**矩阵为非奇异, 当且仅当

$$A x = 0, \quad x \neq 0 \quad \implies \quad x^T P x > 0$$

□ 非奇异的等价条件:  $P + A^T A \succ 0$



# 消除等式约束





# 消除等式约束



□ 将  $\{x | Ax = b\}$  的求解表示为



# 消除等式约束



□ 将  $\{x \mid Ax = b\}$  的求解表示为

$$\{x \mid Ax = b\} = \{Fz + \hat{x} \mid z \in \mathbf{R}^{n-p}\}$$



# 消除等式约束



□ 将  $\{x \mid Ax = b\}$  的求解表示为

$$\{x \mid Ax = b\} = \{Fz + \hat{x} \mid z \in \mathbf{R}^{n-p}\}$$

□  $\hat{x}$  为任意一特定解



# 消除等式约束



□ 将  $\{x \mid Ax = b\}$  的求解表示为

$$\{x \mid Ax = b\} = \{Fz + \hat{x} \mid z \in \mathbf{R}^{n-p}\}$$

□  $\hat{x}$  为任意一特定解

□  $F \in \mathbf{R}^{n \times (n-p)}$  的值域为矩阵  $A$  的零空间



# 消除等式约束



□ 将  $\{x \mid Ax = b\}$  的求解表示为

$$\{x \mid Ax = b\} = \{Fz + \hat{x} \mid z \in \mathbf{R}^{n-p}\}$$


□  $\hat{x}$  为任意一特定解

□  $F \in \mathbf{R}^{n \times (n-p)}$  的值域为矩阵  $A$  的零空间

□  $\text{rank } F = n - p$  且  $AF = 0$



# 消除等式约束



□ 将  $\{x \mid Ax = b\}$  的求解表示为

$$\{x \mid Ax = b\} = \{Fz + \hat{x} \mid z \in \mathbf{R}^{n-p}\}$$

□  $\hat{x}$  为任意一特定解

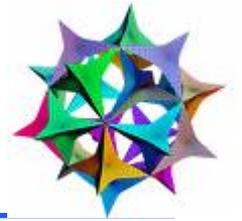
□  $F \in \mathbf{R}^{n \times (n-p)}$  的值域为矩阵  $A$  的零空间

□  $\text{rank } F = n - p$  且  $AF = 0$

□ 消去约束后的问题 minimize  $f(Fz + \hat{x})$



# 消除等式约束



□ 将  $\{x \mid Ax = b\}$  的求解表示为

$$\{x \mid Ax = b\} = \{Fz + \hat{x} \mid z \in \mathbf{R}^{n-p}\}$$

□  $\hat{x}$  为任意一特定解

□  $F \in \mathbf{R}^{n \times (n-p)}$  的值域为矩阵  $A$  的零空间

□  $\text{rank } F = n - p$  且  $AF = 0$

□ 消去约束后的问题 minimize  $f(Fz + \hat{x})$

□ 为无约束问题，其优化变量为  $z \in \mathbf{R}^{n-p}$



# 消除等式约束



□ 将  $\{x \mid Ax = b\}$  的求解表示为

$$\{x \mid Ax = b\} = \{Fz + \hat{x} \mid z \in \mathbf{R}^{n-p}\}$$

□  $\hat{x}$  为任意一特定解

□  $F \in \mathbf{R}^{n \times (n-p)}$  的值域为矩阵  $A$  的零空间

□  $\text{rank } F = n - p$  且  $AF = 0$

□ 消去约束后的问题 minimize  $f(Fz + \hat{x})$

□ 为无约束问题，其优化变量为  $z \in \mathbf{R}^{n-p}$

□ 根据解  $z^*$ ，可获取  $x^*$  和  $v^*$



# 消除等式约束



□ 将  $\{x \mid Ax = b\}$  的求解表示为

$$\{x \mid Ax = b\} = \{Fz + \hat{x} \mid z \in \mathbf{R}^{n-p}\}$$

□  $\hat{x}$  为任意一特定解

□  $F \in \mathbf{R}^{n \times (n-p)}$  的值域为矩阵  $A$  的零空间

□  $\text{rank } F = n - p$  且  $AF = 0$

□ 消去约束后的问题 minimize  $f(Fz + \hat{x})$

□ 为无约束问题，其优化变量为  $z \in \mathbf{R}^{n-p}$

□ 根据解  $z^*$ ，可获取  $x^*$  和  $\nu^*$

$$x^* = Fz^* + \hat{x}, \quad \nu^* = -(AA^T)^{-1}A\nabla f(x^*)$$



# 例：受资源约束的最优配置

---





# 例：受资源约束的最优配置



---

$$\begin{array}{ll} \text{minimize} & f_1(x_1) + f_2(x_2) + \cdots + f_n(x_n) \\ \text{subject to} & x_1 + x_2 + \cdots + x_n = b \end{array}$$



# 例：受资源约束的最优配置



$$\text{minimize } f_1(x_1) + f_2(x_2) + \cdots + f_n(x_n)$$

$$\text{subject to } x_1 + x_2 + \cdots + x_n = b$$

□ 消去  $x_n = b - x_1 - \cdots - x_{n-1}$ ，指选择



# 例：受资源约束的最优配置



$$\text{minimize} \quad f_1(x_1) + f_2(x_2) + \cdots + f_n(x_n)$$


$$\text{subject to} \quad x_1 + x_2 + \cdots + x_n = b$$

□ 消去  $x_n = b - x_1 - \cdots - x_{n-1}$ ，指选择

$$\hat{x} = be_n, \quad F = \begin{bmatrix} I \\ -\mathbf{1}^T \end{bmatrix} \in \mathbf{R}^{n \times (n-1)}$$



# 例：受资源约束的最优配置



$$\text{minimize } f_1(x_1) + f_2(x_2) + \cdots + f_n(x_n)$$

$$\text{subject to } x_1 + x_2 + \cdots + x_n = b$$

□ 消去  $x_n = b - x_1 - \cdots - x_{n-1}$ ，指选择

$$\hat{x} = be_n, \quad F = \begin{bmatrix} I \\ -\mathbf{1}^T \end{bmatrix} \in \mathbf{R}^{n \times (n-1)}$$

□ 消去后的问题



# 例：受资源约束的最优配置



$$\text{minimize } f_1(x_1) + f_2(x_2) + \cdots + f_n(x_n)$$

$$\text{subject to } x_1 + x_2 + \cdots + x_n = b$$

□ 消去  $x_n = b - x_1 - \cdots - x_{n-1}$ ，指选择

$$\hat{x} = be_n, \quad F = \begin{bmatrix} I \\ -\mathbf{1}^T \end{bmatrix} \in \mathbf{R}^{n \times (n-1)}$$

□ 消去后的问题

$$\text{minimize } f_1(x_1) + \cdots + f_{n-1}(x_{n-1}) + f_n(b - x_1 - \cdots - x_{n-1})$$



# Newton方向

---





# Newton方向



□ 函数 $f$ 在可行点 $x$ 的**Newton**方向  $\Delta x_{nt}$  由解 $v$ 给出



# Newton方向



□ 函数 $f$ 在可行点 $x$ 的**Newton**方向  $\Delta x_{nt}$  由解 $v$ 给出

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = \begin{bmatrix} -\nabla f(x) \\ 0 \end{bmatrix}$$



# Newton方向




- 函数 $f$ 在可行点 $x$ 的**Newton**方向  $\Delta x_{nt}$  由解 $v$ 给出

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = \begin{bmatrix} -\nabla f(x) \\ 0 \end{bmatrix}$$

- $\Delta x_{nt}$ 解决了二阶近似问题（优化变量为 $v$ ）



# Newton方向



□ 函数 $f$ 在可行点 $x$ 的**Newton**方向  $\Delta x_{nt}$  由解 $v$ 给出


$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = \begin{bmatrix} -\nabla f(x) \\ 0 \end{bmatrix}$$

□  $\Delta x_{nt}$ 解决了二阶近似问题（优化变量为 $v$ ）

$$\begin{array}{ll} \text{minimize} & \hat{f}(x+v) = f(x) + \nabla f(x)^T v + (1/2)v^T \nabla^2 f(x)v \\ \text{subject to} & A(x+v) = b \end{array}$$



# Newton方向



- 函数 $f$ 在可行点 $x$ 的**Newton**方向  $\Delta x_{nt}$  由解 $v$ 给出

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = \begin{bmatrix} -\nabla f(x) \\ 0 \end{bmatrix}$$

- $\Delta x_{nt}$ 解决了二阶近似问题（优化变量为 $v$ ）

$$\begin{aligned} \text{minimize} \quad & \hat{f}(x+v) = f(x) + \nabla f(x)^T v + (1/2)v^T \nabla^2 f(x)v \\ \text{subject to} \quad & A(x+v) = b \end{aligned}$$

- $\Delta x_{nt}$  等式来源于线性化最优条件



# Newton方向



□ 函数 $f$ 在可行点 $x$ 的**Newton**方向  $\Delta x_{nt}$  由解 $v$ 给出

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = \begin{bmatrix} -\nabla f(x) \\ 0 \end{bmatrix}$$

□  $\Delta x_{nt}$ 解决了二阶近似问题（优化变量为 $v$ ）

$$\begin{aligned} \text{minimize} \quad & \hat{f}(x+v) = f(x) + \nabla f(x)^T v + (1/2)v^T \nabla^2 f(x)v \\ \text{subject to} \quad & A(x+v) = b \end{aligned}$$

□  $\Delta x_{nt}$  等式来源于线性化最优条件

$$\nabla f(x+v) + A^T w \approx \nabla f(x) + \nabla^2 f(x)v + A^T w = 0, \quad A(x+v) = b$$



# Newton減量

---





# Newton減量



$$\lambda(x) = (\Delta x_{\text{nt}}^T \nabla^2 f(x) \Delta x_{\text{nt}})^{1/2} = (-\nabla f(x)^T \Delta x_{\text{nt}})^{1/2}$$



# Newton 减量



$$\lambda(x) = (\Delta x_{\text{nt}}^T \nabla^2 f(x) \Delta x_{\text{nt}})^{1/2} = (-\nabla f(x)^T \Delta x_{\text{nt}})^{1/2}$$

□ 给出了  $f(x) - p^*$  的一个估计，使用了二次近似：



# Newton 减量



$$\lambda(x) = (\Delta x_{\text{nt}}^T \nabla^2 f(x) \Delta x_{\text{nt}})^{1/2} = (-\nabla f(x)^T \Delta x_{\text{nt}})^{1/2}$$

□ 给出了  $f(x) - p^*$  的一个估计，使用了二次近似：

$$f(x) - \inf_{Ay=b} \hat{f}(y) = \frac{1}{2} \lambda(x)^2$$



# Newton 减量



$$\lambda(x) = (\Delta x_{\text{nt}}^T \nabla^2 f(x) \Delta x_{\text{nt}})^{1/2} = (-\nabla f(x)^T \Delta x_{\text{nt}})^{1/2}$$

□ 给出了  $f(x) - p^*$  的一个估计，使用了二次近似：

$$f(x) - \inf_{Ay=b} \hat{f}(y) = \frac{1}{2} \lambda(x)^2$$

□ **Newton** 方向的方向导数：



# Newton 减量



$$\lambda(x) = (\Delta x_{\text{nt}}^T \nabla^2 f(x) \Delta x_{\text{nt}})^{1/2} = (-\nabla f(x)^T \Delta x_{\text{nt}})^{1/2}$$

□ 给出了  $f(x) - p^*$  的一个估计，使用了二次近似：

$$f(x) - \inf_{Ay=b} \hat{f}(y) = \frac{1}{2} \lambda(x)^2$$

□ **Newton** 方向的方向导数：

$$\left. \frac{d}{dt} f(x + t \Delta x_{\text{nt}}) \right|_{t=0} = -\lambda(x)^2$$



# Newton 减量



$$\lambda(x) = (\Delta x_{\text{nt}}^T \nabla^2 f(x) \Delta x_{\text{nt}})^{1/2} = (-\nabla f(x)^T \Delta x_{\text{nt}})^{1/2}$$

□ 给出了  $f(x) - p^*$  的一个估计，使用了二次近似：

$$f(x) - \inf_{Ay=b} \hat{f}(y) = \frac{1}{2} \lambda(x)^2$$

□ **Newton** 方向的方向导数：


$$\left. \frac{d}{dt} f(x + t \Delta x_{\text{nt}}) \right|_{t=0} = -\lambda(x)^2$$

□ 一般的， $\lambda(x) \neq (\nabla f(x)^T \nabla^2 f(x)^{-1} \nabla f(x))^{1/2}$



# 带有等式约束的Newton方法

---





# 带有等式约束的Newton方法



**算法 10.1** 等式约束优化问题的 Newton 方法。

给定 满足  $Ax = b$  的初始点  $x \in \text{dom } f$ , 误差阈值  $\epsilon > 0$ 。

**重复进行**

1. 计算 Newton 方向和 Newton 减量  $\Delta x_{nt}, \lambda(x)$ 。
2. 停止准则。如果  $\lambda^2/2 \leq \epsilon$  则退出。
3. 直线搜索。通过回溯直线搜索确定步长  $t$ 。
4. 修改。  $x := x + t\Delta x_{nt}$ 。



# 带有等式约束的Newton方法



**算法 10.1** 等式约束优化问题的 Newton 方法。

给定 满足  $Ax = b$  的初始点  $x \in \text{dom } f$ , 误差阈值  $\epsilon > 0$ 。

重复进行

1. 计算 Newton 方向和 Newton 减量  $\Delta x_{\text{nt}}, \lambda(x)$ 。
2. 停止准则。如果  $\lambda^2/2 \leq \epsilon$  则退出。
3. 直线搜索。通过回溯直线搜索确定步长  $t$ 。
4. 修改。  $x := x + t\Delta x_{\text{nt}}$ 。

□ 可行的下降方法:  $x^{(k)}$  可行且  $f(x^{(k+1)}) < f(x^{(k)})$

□ 仿射不变性




# Newton方法和消除法

---





# Newton方法和消除法



- 面向简化问题的**Newton**方法



# Newton方法和消除法



□ 面向简化问题的**Newton**方法

$$\text{minimize } \tilde{f}(z) = f(Fz + \hat{x})$$



# Newton方法和消除法



- 面向简化问题的**Newton**方法

$$\text{minimize } \tilde{f}(z) = f(Fz + \hat{x})$$

- 优化变量  $z \in \mathbf{R}^{n-p}$



# Newton方法和消除法



- 面向简化问题的**Newton**方法

$$\text{minimize } \tilde{f}(z) = f(Fz + \hat{x})$$

- 优化变量  $z \in \mathbf{R}^{n-p}$

- $\hat{x}$  满足  $A\hat{x} = b$ ;  $\text{rank } F = n - p$  and  $AF = 0$



# Newton方法和消除法



- 面向简化问题的**Newton**方法

$$\text{minimize } \tilde{f}(z) = f(Fz + \hat{x})$$

- 优化变量  $z \in \mathbf{R}^{n-p}$

- $\hat{x}$  满足  $A\hat{x} = b$ ;  $\text{rank } F = n - p$  and  $AF = 0$

- 对函数执行**Newton**方法，起始点为  $z^{(0)}$  进行迭代



# Newton方法和消除法



- 面向简化问题的**Newton**方法

$$\text{minimize } \tilde{f}(z) = f(Fz + \hat{x})$$

- 优化变量  $z \in \mathbf{R}^{n-p}$

- $\hat{x}$  满足  $A\hat{x} = b$ ;  $\text{rank } F = n - p$  and  $AF = 0$

- 对函数执行**Newton**方法，起始点为  $z^{(0)}$  进行迭代

- 带有等式约束的**Newton**方法



# Newton方法和消除法



- 面向简化问题的**Newton**方法

$$\text{minimize } \tilde{f}(z) = f(Fz + \hat{x})$$

- 优化变量  $z \in \mathbf{R}^{n-p}$

- $\hat{x}$  满足  $A\hat{x} = b$ ;  $\text{rank } F = n - p$  and  $AF = 0$

- 对函数执行**Newton**方法，起始点为  $z^{(0)}$  进行迭代

- 带有等式约束的**Newton**方法

- 当起始点为  $x^{(0)} = Fz^{(0)} + \hat{x}$  时，迭代为



# Newton方法和消除法



- 面向简化问题的**Newton**方法

$$\text{minimize } \tilde{f}(z) = f(Fz + \hat{x})$$

- 优化变量  $z \in \mathbf{R}^{n-p}$

- $\hat{x}$  满足  $A\hat{x} = b$ ;  $\text{rank } F = n - p$  and  $AF = 0$

- 对函数执行**Newton**方法，起始点为  $z^{(0)}$  进行迭代

- 带有等式约束的**Newton**方法

- 当起始点为  $x^{(0)} = Fz^{(0)} + \hat{x}$  时，迭代为

$$x^{(k+1)} = Fz^{(k)} + \hat{x}$$



# Newton方法和消除法



- 面向简化问题的**Newton**方法

$$\text{minimize } \tilde{f}(z) = f(Fz + \hat{x})$$

- 优化变量  $z \in \mathbf{R}^{n-p}$

- $\hat{x}$  满足  $A\hat{x} = b$ ;  $\text{rank } F = n - p$  and  $AF = 0$

- 对函数执行**Newton**方法，起始点为  $z^{(0)}$  进行迭代

- 带有等式约束的**Newton**方法

- 当起始点为  $x^{(0)} = Fz^{(0)} + \hat{x}$  时，迭代为


$$x^{(k+1)} = Fz^{(k)} + \hat{x}$$

- 因此，不需要分离的收敛分析



# 不可行初始点的**Newton**方法

---






# 不可行初始点的Newton方法



- 在不可行点 $x$ 线性化最优条件



# 不可行初始点的Newton方法




□ 在不可行点 $x$ 线性化最优条件

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x_{\text{nt}} \\ w \end{bmatrix} = - \begin{bmatrix} \nabla f(x) \\ Ax - b \end{bmatrix}$$



# 不可行初始点的Newton方法



- 在不可行点 $x$ 线性化最优条件

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x_{\text{nt}} \\ w \end{bmatrix} = - \begin{bmatrix} \nabla f(x) \\ Ax - b \end{bmatrix}$$

- 原对偶Newton方向的解释



# 不可行初始点的Newton方法




- 在不可行点 $x$ 线性化最优条件

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x_{\text{nt}} \\ w \end{bmatrix} = - \begin{bmatrix} \nabla f(x) \\ Ax - b \end{bmatrix}$$

- 原对偶Newton方向的解释
- 最优条件为  $r(y) = 0$  , 其中



# 不可行初始点的Newton方法



- 在不可行点 $x$ 线性化最优条件

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x_{\text{nt}} \\ w \end{bmatrix} = - \begin{bmatrix} \nabla f(x) \\ Ax - b \end{bmatrix}$$


- 原对偶Newton方向的解释

- 最优条件为  $r(y) = 0$  , 其中

$$y = (x, \nu), \quad r(y) = (\nabla f(x) + A^T \nu, Ax - b)$$



# 不可行初始点的Newton方法



- 在不可行点 $x$ 线性化最优条件

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x_{\text{nt}} \\ w \end{bmatrix} = - \begin{bmatrix} \nabla f(x) \\ Ax - b \end{bmatrix}$$

- 原对偶Newton方向的解释


- 最优条件为  $r(y) = 0$  , 其中

$$y = (x, \nu), \quad r(y) = (\nabla f(x) + A^T \nu, Ax - b)$$

- 线性化  $r(y) = 0$  可得



# 不可行初始点的Newton方法



- 在不可行点 $x$ 线性化最优条件

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x_{\text{nt}} \\ w \end{bmatrix} = - \begin{bmatrix} \nabla f(x) \\ Ax - b \end{bmatrix}$$

- 原对偶Newton方向的解释

- 最优条件为  $r(y) = 0$  , 其中

$$y = (x, \nu), \quad r(y) = (\nabla f(x) + A^T \nu, Ax - b)$$

- 线性化  $r(y) = 0$  可得  $r(y + \Delta y) \approx r(y) + Dr(y)\Delta y = 0$ :



# 不可行初始点的Newton方法



- 在不可行点 $x$ 线性化最优条件

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x_{\text{nt}} \\ w \end{bmatrix} = - \begin{bmatrix} \nabla f(x) \\ Ax - b \end{bmatrix}$$

- 原对偶Newton方向的解释

- 最优条件为  $r(y) = 0$  , 其中


$$y = (x, \nu), \quad r(y) = (\nabla f(x) + A^T \nu, Ax - b)$$

- 线性化  $r(y) = 0$  可得  $r(y + \Delta y) \approx r(y) + Dr(y)\Delta y = 0$ :

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x_{\text{nt}} \\ \Delta \nu_{\text{nt}} \end{bmatrix} = - \begin{bmatrix} \nabla f(x) + A^T \nu \\ Ax - b \end{bmatrix}$$



# 不可行初始点的Newton方法



- 在不可行点 $x$ 线性化最优条件

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x_{\text{nt}} \\ w \end{bmatrix} = - \begin{bmatrix} \nabla f(x) \\ Ax - b \end{bmatrix}$$

- 原对偶Newton方向的解释

- 最优条件为  $r(y) = 0$  , 其中

$$y = (x, \nu), \quad r(y) = (\nabla f(x) + A^T \nu, Ax - b)$$

- 线性化  $r(y) = 0$  可得  $r(y + \Delta y) \approx r(y) + Dr(y)\Delta y = 0$ :

$$\begin{bmatrix} \nabla^2 f(x) & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x_{\text{nt}} \\ \Delta \nu_{\text{nt}} \end{bmatrix} = - \begin{bmatrix} \nabla f(x) + A^T \nu \\ Ax - b \end{bmatrix} \quad w = \nu + \Delta \nu_{\text{nt}}$$



# 不可行初始点Newton方法

---





# 不可行初始点Newton方法



算法 10.2 不可行初始点 Newton 方法。

给定 初始点  $x \in \text{dom } f$ ,  $\nu$ , 误差阈值  $\epsilon > 0$ ,  $\alpha \in (0, 1/2)$ ,  $\beta \in (0, 1)$ 。

重复进行

1. 计算原对偶 Newton 方向  $\Delta x_{nt}$ ,  $\Delta \nu_{nt}$ 。

2. 对  $\|r\|_2$  进行回溯直线搜索。

$t := 1$ 。

只要  $\|r(x + t\Delta x_{nt}, \nu + t\Delta \nu_{nt})\|_2 > (1 - \alpha t)\|r(x, \nu)\|_2$ ,  $t := \beta t$ 。

3. 改进。  $x := x + t\Delta x_{nt}$ ,  $\nu := \nu + t\Delta \nu_{nt}$ 。

直到  $Ax = b$  并且  $\|r(x, \nu)\|_2 \leq \epsilon$ 。



# 不可行初始点Newton方法



算法 10.2 不可行初始点 Newton 方法。

给定 初始点  $x \in \text{dom } f$ ,  $\nu$ , 误差阈值  $\epsilon > 0$ ,  $\alpha \in (0, 1/2)$ ,  $\beta \in (0, 1)$ 。

重复进行

1. 计算原对偶 Newton 方向  $\Delta x_{\text{nt}}$ ,  $\Delta \nu_{\text{nt}}$ 。

2. 对  $\|r\|_2$  进行回溯直线搜索。

$t := 1$ 。

只要  $\|r(x + t\Delta x_{\text{nt}}, \nu + t\Delta \nu_{\text{nt}})\|_2 > (1 - \alpha t)\|r(x, \nu)\|_2$ ,  $t := \beta t$ 。

3. 改进。  $x := x + t\Delta x_{\text{nt}}$ ,  $\nu := \nu + t\Delta \nu_{\text{nt}}$ 。

直到  $Ax = b$  并且  $\|r(x, \nu)\|_2 \leq \epsilon$ 。

□ 不是下降法：可能存在  $f(x^{(k+1)}) > f(x^{(k)})$



# 不可行初始点Newton方法



算法 10.2 不可行初始点 Newton 方法。

给定 初始点  $x \in \text{dom } f$ ,  $\nu$ , 误差阈值  $\epsilon > 0$ ,  $\alpha \in (0, 1/2)$ ,  $\beta \in (0, 1)$ 。

重复进行

1. 计算原对偶 Newton 方向  $\Delta x_{\text{nt}}$ ,  $\Delta \nu_{\text{nt}}$ 。

2. 对  $\|r\|_2$  进行回溯直线搜索。

$t := 1$ 。

只要  $\|r(x + t\Delta x_{\text{nt}}, \nu + t\Delta \nu_{\text{nt}})\|_2 > (1 - \alpha t)\|r(x, \nu)\|_2$ ,  $t := \beta t$ 。

3. 改进。  $x := x + t\Delta x_{\text{nt}}$ ,  $\nu := \nu + t\Delta \nu_{\text{nt}}$ 。

直到  $Ax = b$  并且  $\|r(x, \nu)\|_2 \leq \epsilon$ 。

□ 不是下降法：可能存在  $f(x^{(k+1)}) > f(x^{(k)})$

□  $\|r(y)\|_2$  的有向导数在方向上  $\Delta y = (\Delta x_{\text{nt}}, \Delta \nu_{\text{nt}})$  为

$$\left. \frac{d}{dt} \|r(y + t\Delta y)\|_2 \right|_{t=0} = -\|r(y)\|_2$$



# 求解KKT系统

---





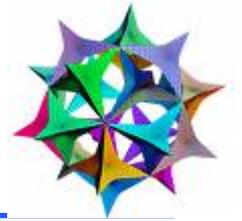
# 求解KKT系统



$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$



# 求解KKT系统




$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

□ 求解方法



# 求解KKT系统



$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

- 求解方法
- **LDL<sup>T</sup>**因式分解



# 求解KKT系统



$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

- 求解方法
- **LDL<sup>T</sup>**因式分解
- 消去（若 $H$ 非奇异）：



# 求解KKT系统



$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

□ 求解方法

□ **LDL<sup>T</sup>**因式分解

□ 消去（若 $H$ 非奇异）：

$$AH^{-1}A^T w = h - AH^{-1}g, \quad Hv = -(g + A^T w)$$



# 求解KKT系统



$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

□ 求解方法

□ **LDL<sup>T</sup>**因式分解

□ 消去（若 $H$ 非奇异）：

$$AH^{-1}A^T w = h - AH^{-1}g, \quad Hv = -(g + A^T w)$$

□ 消去奇异矩阵 $H$ ：



# 求解KKT系统



$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

□ 求解方法

□ **LDL<sup>T</sup>**因式分解

□ 消去（若 $H$ 非奇异）：

$$AH^{-1}A^T w = h - AH^{-1}g, \quad Hv = -(g + A^T w)$$

□ 消去奇异矩阵 $H$ ：

$$\begin{bmatrix} H + A^T Q A & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g + A^T Q h \\ h \end{bmatrix}$$



# 求解KKT系统



$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

□ 求解方法

□ **LDL<sup>T</sup>**因式分解

□ 消去（若 $H$ 非奇异）：

$$AH^{-1}A^T w = h - AH^{-1}g, \quad Hv = -(g + A^T w)$$

□ 消去奇异矩阵 $H$ ：


$$\begin{bmatrix} H + A^T Q A & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g + A^T Q h \\ h \end{bmatrix}$$

□ 其中， $Q \succeq 0$ ，满足  $H + A^T Q A \succ 0$



# 等式约束的解析中心

---





# 等式约束的解析中心



□ 原问题： minimize  $-\sum_{i=1}^n \log x_i$  subject to  $Ax = b$



# 等式约束的解析中心



- 原问题: minimize  $-\sum_{i=1}^n \log x_i$  subject to  $Ax = b$
- 对偶问题: maximize  $-b^T \nu + \sum_{i=1}^n \log(A^T \nu)_i + n$



# 等式约束的解析中心



- 原问题: minimize  $-\sum_{i=1}^n \log x_i$  subject to  $Ax = b$
- 对偶问题: maximize  $-b^T \nu + \sum_{i=1}^n \log(A^T \nu)_i + n$
- 使用三种方法求解  $A \in \mathbf{R}^{100 \times 500}$  中的例子, 三个不同起始点



# 等式约束的解析中心




- 原问题: minimize  $-\sum_{i=1}^n \log x_i$  subject to  $Ax = b$
- 对偶问题: maximize  $-b^T \nu + \sum_{i=1}^n \log(A^T \nu)_i + n$
- 使用三种方法求解  $A \in \mathbf{R}^{100 \times 500}$  中的例子, 三个不同起始点
- 带有等式约束的**Newton**方法, 需  $x^{(0)} \succ 0, Ax^{(0)} = b$



# 等式约束的解析中心




- 原问题: minimize  $-\sum_{i=1}^n \log x_i$  subject to  $Ax = b$
- 对偶问题: maximize  $-b^T \nu + \sum_{i=1}^n \log(A^T \nu)_i + n$
- 使用三种方法求解  $A \in \mathbf{R}^{100 \times 500}$  中的例子, 三个不同起始点
- 带有等式约束的**Newton**方法, 需  $x^{(0)} \succ 0, Ax^{(0)} = b$





# 其他两个方法

---






# 其他两个方法




□ **Newton**方法应用于对偶问题，需  $A^T \nu^{(0)} \succ 0$



# 其他两个方法




□ **Newton**方法应用于对偶问题，需  $A^T \nu^{(0)} \succ 0$






# 其他两个方法



□ **Newton**方法应用于对偶问题，需  $A^T \nu^{(0)} \succ 0$




□ 不可行初始点的**Newton**方法，需  $x^{(0)} \succ 0$




# 其他两个方法



□ **Newton**方法应用于对偶问题，需  $A^T \nu^{(0)} \succ 0$



□ 不可行初始点的**Newton**方法，需  $x^{(0)} \succ 0$





# 三个方法每次迭代的复杂度

---






# 三个方法每次迭代的复杂度



- 使用分块消元求解**KKT**系统



# 三个方法每次迭代的复杂度




□ 使用分块消元求解**KKT**系统

$$\begin{bmatrix} \mathbf{diag}(x)^{-2} & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ w \end{bmatrix} = \begin{bmatrix} \mathbf{diag}(x)^{-1} \mathbf{1} \\ 0 \end{bmatrix}$$



# 三个方法每次迭代的复杂度



- 使用分块消元求解**KKT**系统

$$\begin{bmatrix} \mathbf{diag}(x)^{-2} & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ w \end{bmatrix} = \begin{bmatrix} \mathbf{diag}(x)^{-1} \mathbf{1} \\ 0 \end{bmatrix}$$

- 简化为求解  $A \mathbf{diag}(x)^2 A^T w = b$



# 三个方法每次迭代的复杂度



- 使用分块消元求解**KKT**系统


$$\begin{bmatrix} \mathbf{diag}(x)^{-2} & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ w \end{bmatrix} = \begin{bmatrix} \mathbf{diag}(x)^{-1} \mathbf{1} \\ 0 \end{bmatrix}$$

- 简化为求解  $A \mathbf{diag}(x)^2 A^T w = b$

- 求解**Newton**系统  $A \mathbf{diag}(A^T \nu)^{-2} A^T \Delta \nu = -b + A \mathbf{diag}(A^T \nu)^{-1} \mathbf{1}$



# 三个方法每次迭代的复杂度




- 使用分块消元求解**KKT**系统

$$\begin{bmatrix} \mathbf{diag}(x)^{-2} & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ w \end{bmatrix} = \begin{bmatrix} \mathbf{diag}(x)^{-1} \mathbf{1} \\ 0 \end{bmatrix}$$

- 简化为求解  $A \mathbf{diag}(x)^2 A^T w = b$
- 求解**Newton**系统  $A \mathbf{diag}(A^T \nu)^{-2} A^T \Delta \nu = -b + A \mathbf{diag}(A^T \nu)^{-1} \mathbf{1}$
- 使用分块消元求解**KKT**系统



# 三个方法每次迭代的复杂度



- 使用分块消元求解**KKT**系统

$$\begin{bmatrix} \mathbf{diag}(x)^{-2} & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ w \end{bmatrix} = \begin{bmatrix} \mathbf{diag}(x)^{-1} \mathbf{1} \\ 0 \end{bmatrix}$$

- 简化为求解  $A \mathbf{diag}(x)^2 A^T w = b$

- 求解**Newton**系统  $A \mathbf{diag}(A^T \nu)^{-2} A^T \Delta \nu = -b + A \mathbf{diag}(A^T \nu)^{-1} \mathbf{1}$

- 使用分块消元求解**KKT**系统

$$\begin{bmatrix} \mathbf{diag}(x)^{-2} & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ \Delta \nu \end{bmatrix} = \begin{bmatrix} \mathbf{diag}(x)^{-1} \mathbf{1} - A^T \nu \\ b - Ax \end{bmatrix}$$



# 三个方法每次迭代的复杂度



- 使用分块消元求解**KKT**系统

$$\begin{bmatrix} \mathbf{diag}(x)^{-2} & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ w \end{bmatrix} = \begin{bmatrix} \mathbf{diag}(x)^{-1} \mathbf{1} \\ 0 \end{bmatrix}$$

- 简化为求解  $A \mathbf{diag}(x)^2 A^T w = b$

- 求解**Newton**系统  $A \mathbf{diag}(A^T \nu)^{-2} A^T \Delta \nu = -b + A \mathbf{diag}(A^T \nu)^{-1} \mathbf{1}$


- 使用分块消元求解**KKT**系统

$$\begin{bmatrix} \mathbf{diag}(x)^{-2} & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ \Delta \nu \end{bmatrix} = \begin{bmatrix} \mathbf{diag}(x)^{-1} \mathbf{1} - A^T \nu \\ b - Ax \end{bmatrix}$$

- 简化为求解  $A \mathbf{diag}(x)^2 A^T w = 2Ax - b$



# 三个方法每次迭代的复杂度



- 使用分块消元求解**KKT**系统

$$\begin{bmatrix} \mathbf{diag}(x)^{-2} & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ w \end{bmatrix} = \begin{bmatrix} \mathbf{diag}(x)^{-1} \mathbf{1} \\ 0 \end{bmatrix}$$

- 简化为求解  $A \mathbf{diag}(x)^2 A^T w = b$

- 求解**Newton**系统  $A \mathbf{diag}(A^T \nu)^{-2} A^T \Delta \nu = -b + A \mathbf{diag}(A^T \nu)^{-1} \mathbf{1}$

- 使用分块消元求解**KKT**系统

$$\begin{bmatrix} \mathbf{diag}(x)^{-2} & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ \Delta \nu \end{bmatrix} = \begin{bmatrix} \mathbf{diag}(x)^{-1} \mathbf{1} - A^T \nu \\ b - Ax \end{bmatrix}$$

- 简化为求解  $A \mathbf{diag}(x)^2 A^T w = 2Ax - b$

- 结论：求解带有正对角矩阵 $D$ 的  $ADA^T w = h$




# 最优网络流

---





# 最优网络流



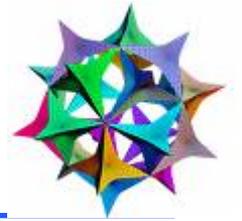
---

$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n \phi_i(x_i) \\ \text{subject to} & Ax = b \end{array}$$





# 最优网络流




$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n \phi_i(x_i) \\ \text{subject to} & Ax = b \end{array}$$

□ 有向图带有 $n$ 条边和 $p+1$ 个结点



# 最优网络流



$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n \phi_i(x_i) \\ \text{subject to} & Ax = b \end{array}$$

- 有向图带有 $n$ 条边和 $p+1$ 个结点
- $x_i$ : 通过边 $i$ 的流量;  $\phi_i$ : 边 $i$ 的流程成本函数 (  $\phi_i''(x) > 0$  )



# 最优网络流

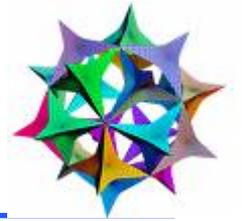


$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n \phi_i(x_i) \\ \text{subject to} & Ax = b \end{array}$$

- 有向图带有 $n$ 条边和 $p+1$ 个结点
- $x_i$ : 通过边 $i$ 的流量;  $\phi_i$ : 边 $i$ 的流程成本函数 (  $\phi_i''(x) > 0$  )
- 结点进入矩阵  $\tilde{A} \in \mathbf{R}^{(p+1) \times n}$



# 最优网络流



$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n \phi_i(x_i) \\ \text{subject to} & Ax = b \end{array}$$

- 有向图带有  $n$  条边和  $p+1$  个结点
- $x_i$ : 通过边  $i$  的流量;  $\phi_i$ : 边  $i$  的流程成本函数 (  $\phi_i''(x) > 0$  )
- 结点进入矩阵  $\tilde{A} \in \mathbf{R}^{(p+1) \times n}$

$$\tilde{A}_{ij} = \begin{cases} 1 & \text{arc } j \text{ leaves node } i \\ -1 & \text{arc } j \text{ enters node } i \\ 0 & \text{otherwise} \end{cases}$$



# 最优网络流



$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n \phi_i(x_i) \\ \text{subject to} & Ax = b \end{array}$$

- 有向图带有  $n$  条边和  $p+1$  个结点
- $x_i$ : 通过边  $i$  的流量;  $\phi_i$ : 边  $i$  的流程成本函数 (  $\phi_i''(x) > 0$  )
- 结点进入矩阵  $\tilde{A} \in \mathbf{R}^{(p+1) \times n}$

$$\tilde{A}_{ij} = \begin{cases} 1 & \text{arc } j \text{ leaves node } i \\ -1 & \text{arc } j \text{ enters node } i \\ 0 & \text{otherwise} \end{cases}$$

- 简化结点进入矩阵  $A \in \mathbf{R}^{p \times n}$ , 去除最后一行的  $\tilde{A} \in \mathbf{R}^{(p+1) \times n}$



# 最优网络流



$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n \phi_i(x_i) \\ \text{subject to} & Ax = b \end{array}$$

- 有向图带有  $n$  条边和  $p+1$  个结点
- $x_i$ : 通过边  $i$  的流量;  $\phi_i$ : 边  $i$  的流程成本函数 (  $\phi_i''(x) > 0$  )
- 结点进入矩阵  $\tilde{A} \in \mathbf{R}^{(p+1) \times n}$

$$\tilde{A}_{ij} = \begin{cases} 1 & \text{arc } j \text{ leaves node } i \\ -1 & \text{arc } j \text{ enters node } i \\ 0 & \text{otherwise} \end{cases}$$

- 简化结点进入矩阵  $A \in \mathbf{R}^{p \times n}$ , 去除最后一行的  $\tilde{A} \in \mathbf{R}^{(p+1) \times n}$
- (简化的) 资源向量  $b \in \mathbf{R}^p$



# 最优网络流



$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n \phi_i(x_i) \\ \text{subject to} & Ax = b \end{array}$$

- 有向图带有  $n$  条边和  $p+1$  个结点
- $x_i$ : 通过边  $i$  的流量;  $\phi_i$ : 边  $i$  的流程成本函数 (  $\phi_i''(x) > 0$  )
- 结点进入矩阵  $\tilde{A} \in \mathbf{R}^{(p+1) \times n}$

$$\tilde{A}_{ij} = \begin{cases} 1 & \text{arc } j \text{ leaves node } i \\ -1 & \text{arc } j \text{ enters node } i \\ 0 & \text{otherwise} \end{cases}$$

- 简化结点进入矩阵  $A \in \mathbf{R}^{p \times n}$ , 去除最后一行的  $\tilde{A} \in \mathbf{R}^{(p+1) \times n}$
- (简化的) 资源向量  $b \in \mathbf{R}^p$
- 若图是连接的,  $\text{rank } A = p$



# 最优网络流



$$\begin{array}{ll} \text{minimize} & \sum_{i=1}^n \phi_i(x_i) \\ \text{subject to} & Ax = b \end{array}$$


- 有向图带有  $n$  条边和  $p+1$  个结点
- $x_i$ : 通过边  $i$  的流量;  $\phi_i$ : 边  $i$  的流程成本函数 ( $\phi_i''(x) > 0$ )
- 结点进入矩阵  $\tilde{A} \in \mathbf{R}^{(p+1) \times n}$

$$\tilde{A}_{ij} = \begin{cases} 1 & \text{arc } j \text{ leaves node } i \\ -1 & \text{arc } j \text{ enters node } i \\ 0 & \text{otherwise} \end{cases}$$

- 简化结点进入矩阵  $A \in \mathbf{R}^{p \times n}$ , 去除最后一行的  $\tilde{A} \in \mathbf{R}^{(p+1) \times n}$
- (简化的) 资源向量  $b \in \mathbf{R}^p$
- 若图是连接的,  $\text{rank } A = p$



# 最优控制





# 最优控制



□ **KKT**系统 
$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$



# 最优控制



□ KKT系统 
$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

□  $H = \text{diag}(\phi_1''(x_1), \dots, \phi_n''(x_n))$ , 正对角矩阵



# 最优控制



□ **KKT**系统 
$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

□  $H = \mathbf{diag}(\phi_1''(x_1), \dots, \phi_n''(x_n))$ , 正对角矩阵

□ 通过消元法求解:



# 最优控制



□ **KKT**系统 
$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

□  $H = \mathbf{diag}(\phi_1''(x_1), \dots, \phi_n''(x_n))$ , 正对角矩阵

□ 通过消元法求解:

$$AH^{-1}A^T w = h - AH^{-1}g, \quad Hv = -(g + A^T w)$$



# 最优控制



□ **KKT**系统 
$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

□  $H = \mathbf{diag}(\phi_1''(x_1), \dots, \phi_n''(x_n))$ , 正对角矩阵

□ 通过消元法求解:

$$AH^{-1}A^T w = h - AH^{-1}g, \quad Hv = -(g + A^T w)$$

□ 系数矩阵的稀疏模式通过图的连接性获取



# 最优控制



□ **KKT**系统 
$$\begin{bmatrix} H & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} = - \begin{bmatrix} g \\ h \end{bmatrix}$$

□  $H = \mathbf{diag}(\phi_1''(x_1), \dots, \phi_n''(x_n))$ , 正对角矩阵

□ 通过消元法求解:

$$AH^{-1}A^T w = h - AH^{-1}g, \quad Hv = -(g + A^T w)$$

□ 系数矩阵的稀疏模式通过图的连接性获取

$$(AH^{-1}A^T)_{ij} \neq 0 \iff (AA^T)_{ij} \neq 0$$

$\iff$  结点*i*和*j*存在边连接




# 线性矩阵不等式的解析中心

---





# 线性矩阵不等式的解析中心



$$\begin{array}{ll} \text{minimize} & -\log \det X \\ \text{subject to} & \mathbf{tr}(A_i X) = b_i, \quad i = 1, \dots, p \end{array}$$



# 线性矩阵不等式的解析中心



minimize  $-\log \det X$

subject to  $\mathbf{tr}(A_i X) = b_i, \quad i = 1, \dots, p$

□ 优化变量  $X \in \mathbf{S}^n$



# 线性矩阵不等式的解析中心



minimize  $-\log \det X$

subject to  $\mathbf{tr}(A_i X) = b_i, \quad i = 1, \dots, p$

- 优化变量  $X \in \mathbf{S}^n$
- 优化条件



# 线性矩阵不等式的解析中心



$$\begin{aligned} & \text{minimize} && -\log \det X \\ & \text{subject to} && \mathbf{tr}(A_i X) = b_i, \quad i = 1, \dots, p \end{aligned}$$

□ 优化变量  $X \in \mathbf{S}^n$

□ 优化条件

$$X^* \succ 0, \quad -(X^*)^{-1} + \sum_{j=1}^p \nu_j^* A_j = 0, \quad \mathbf{tr}(A_i X^*) = b_i, \quad i = 1, \dots, p$$



# 线性矩阵不等式的解析中心



$$\begin{aligned} & \text{minimize} && -\log \det X \\ & \text{subject to} && \mathbf{tr}(A_i X) = b_i, \quad i = 1, \dots, p \end{aligned}$$

□ 优化变量  $X \in \mathbf{S}^n$

□ 优化条件

$$X^* \succ 0, \quad -(X^*)^{-1} + \sum_{j=1}^p \nu_j^* A_j = 0, \quad \mathbf{tr}(A_i X^*) = b_i, \quad i = 1, \dots, p$$

□ 在可行点 $X$ 的**Newton**等式



# 线性矩阵不等式的解析中心



$$\begin{aligned} & \text{minimize} && -\log \det X \\ & \text{subject to} && \mathbf{tr}(A_i X) = b_i, \quad i = 1, \dots, p \end{aligned}$$

□ 优化变量  $X \in \mathbf{S}^n$

□ 优化条件

$$X^* \succ 0, \quad -(X^*)^{-1} + \sum_{j=1}^p \nu_j^* A_j = 0, \quad \mathbf{tr}(A_i X^*) = b_i, \quad i = 1, \dots, p$$

□ 在可行点 $X$ 的**Newton**等式

$$X^{-1} \Delta X X^{-1} + \sum_{j=1}^p w_j A_j = X^{-1}, \quad \mathbf{tr}(A_i \Delta X) = 0, \quad i = 1, \dots, p$$



# 线性矩阵不等式的解析中心



$$\begin{aligned} & \text{minimize} && -\log \det X \\ & \text{subject to} && \mathbf{tr}(A_i X) = b_i, \quad i = 1, \dots, p \end{aligned}$$

□ 优化变量  $X \in \mathbf{S}^n$

□ 优化条件

$$X^* \succ 0, \quad -(X^*)^{-1} + \sum_{j=1}^p \nu_j^* A_j = 0, \quad \mathbf{tr}(A_i X^*) = b_i, \quad i = 1, \dots, p$$


□ 在可行点 $X$ 的**Newton**等式

$$X^{-1} \Delta X X^{-1} + \sum_{j=1}^p w_j A_j = X^{-1}, \quad \mathbf{tr}(A_i \Delta X) = 0, \quad i = 1, \dots, p$$

□ 根据线性近似  $(X + \Delta X)^{-1} \approx X^{-1} - X^{-1} \Delta X X^{-1}$   
得到  $n(n+1)/2 + p$  个变量  $\Delta X, w$



# 分块消元求解





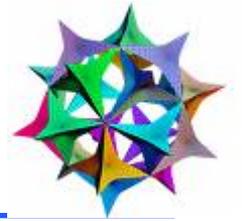
# 分块消元求解



□ 从第一个方程中消去  $\Delta X$ :  $\Delta X = X - \sum_{j=1}^p w_j X A_j X$



# 分块消元求解



- 从第一个方程中消去  $\Delta X$ :  $\Delta X = X - \sum_{j=1}^p w_j X A_j X$
- 将  $\Delta X$  带入第二个方程



# 分块消元求解



- 从第一个方程中消去  $\Delta X$ :  $\Delta X = X - \sum_{j=1}^p w_j X A_j X$
- 将  $\Delta X$  带入第二个方程

$$\sum_{j=1}^p \text{tr}(A_i X A_j X) w_j = b_i, \quad i = 1, \dots, p$$



# 分块消元求解



□ 从第一个方程中消去  $\Delta X$ :  $\Delta X = X - \sum_{j=1}^p w_j X A_j X$

□ 将  $\Delta X$  带入第二个方程

$$\sum_{j=1}^p \text{tr}(A_i X A_j X) w_j = b_i, \quad i = 1, \dots, p$$

□ 为一个密集正定的线性方程组，变量为  $w \in \mathbf{R}^p$



# 分块消元求解



□ 从第一个方程中消去  $\Delta X$ :  $\Delta X = X - \sum_{j=1}^p w_j X A_j X$

□ 将  $\Delta X$  带入第二个方程

$$\sum_{j=1}^p \text{tr}(A_i X A_j X) w_j = b_i, \quad i = 1, \dots, p$$

□ 为一个密集正定的线性方程组，变量为  $w \in \mathbf{R}^p$

□ 使用 **Cholesky** 因式分解  $X = LL^T$  的浮点运算次数:



# 分块消元求解



□ 从第一个方程中消去  $\Delta X$ :  $\Delta X = X - \sum_{j=1}^p w_j X A_j X$

□ 将  $\Delta X$  带入第二个方程

$$\sum_{j=1}^p \text{tr}(A_i X A_j X) w_j = b_i, \quad i = 1, \dots, p$$

□ 为一个密集正定的线性方程组，变量为  $w \in \mathbf{R}^p$

□ 使用 **Cholesky** 因式分解  $X = LL^T$  的浮点运算次数:

□ 计算  $p$  个乘积  $L^T A_j L$ :  $(3/2)pn^3$



# 分块消元求解



□ 从第一个方程中消去  $\Delta X$ :  $\Delta X = X - \sum_{j=1}^p w_j X A_j X$

□ 将  $\Delta X$  带入第二个方程

$$\sum_{j=1}^p \text{tr}(A_i X A_j X) w_j = b_i, \quad i = 1, \dots, p$$

□ 为一个密集正定的线性方程组，变量为  $w \in \mathbf{R}^p$

□ 使用 **Cholesky** 因式分解  $X = LL^T$  的浮点运算次数:

□ 计算  $p$  个乘积  $L^T A_j L$ :  $(3/2)pn^3$

□ 计算  $p(p+1)/2$  个内积:  $\text{tr}((L^T A_i L)(L^T A_j L))$ :  $(1/2)p^2 n^2$



# 分块消元求解



□ 从第一个方程中消去  $\Delta X$ :  $\Delta X = X - \sum_{j=1}^p w_j X A_j X$

□ 将  $\Delta X$  带入第二个方程

$$\sum_{j=1}^p \text{tr}(A_i X A_j X) w_j = b_i, \quad i = 1, \dots, p$$

□ 为一个密集正定的线性方程组，变量为  $w \in \mathbf{R}^p$

□ 使用 **Cholesky** 因式分解  $X = LL^T$  的浮点运算次数:

□ 计算  $p$  个乘积  $L^T A_j L$ :  $(3/2)pn^3$

□ 计算  $p(p+1)/2$  个内积:  $\text{tr}((L^T A_i L)(L^T A_j L))$ :  $(1/2)p^2 n^2$

□ 通过 **Cholesky** 因式分解求解:  $(1/3)p^3$