



KTH Matematik

# 5B1817 Tillämpad icke linjär optimering

## Föreläsning 6

Kvadratisk programmering med likhetsbivillkor

## Kvadratisk programmering med likhetsbivillkor

Titta på modellproblem med kvadratisk målfunktion,

$$\begin{aligned} \min \quad & f(x) = \frac{1}{2}x^T H x + c^T x \\ (EQP) \quad \text{då} \quad & Ax = b, \\ & x \in I\!\!R^n. \end{aligned}$$

Vi antar att  $A \in I\!\!R^{m \times n}$  med rang  $m$ .

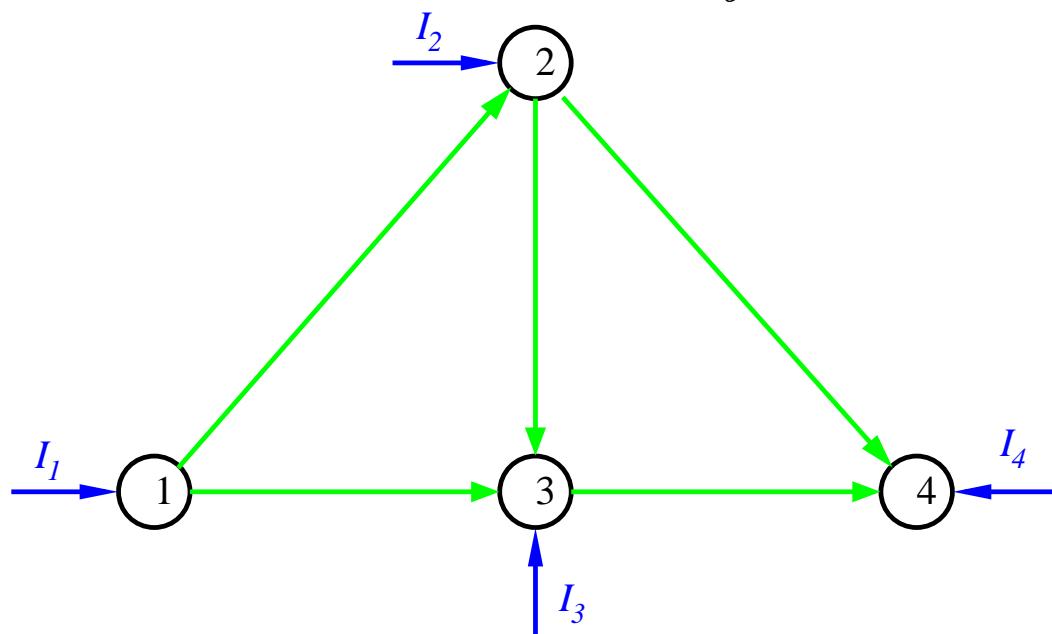
Första ordningens nödvändiga optimalitetsvillkor blir

$$\begin{aligned} Hx + c &= A^T \lambda, \\ Ax &= b. \end{aligned}$$

Detta är ett linjärt ekvationssystem.

## Exempelproblem, elektriskt nätverk

Antag att vi har ett elektiskt nätverk med  $m$  noder och ledningar  $(i, j) \in E$ . Ström med styrka  $I_i$  skickas in i nod  $i$ ,  $i = 1, \dots, m$  (där  $\sum_{i=1}^m I_i = 0$ ). Ledning  $(i, j)$  har resistans  $r_{ij}$ .



Vilken väg tar strömmen genom nätverket?

## Exempelproblem, elektriskt nätverk, forts.

Låt  $x_{ij}$  vara strömstyrkan i ledning  $(i, j)$  och låt  $u_i$  vara potentialen i nod  $i$ ,  $i = 1, \dots, m$ , där vi kan välja  $u_m = 0$ . Då får vi

$$u_i - u_j = r_{ij}x_{ij}, \quad (i, j) \in E,$$

$$\sum_{j:(i,j) \in E} x_{ij} - \sum_{j:(j,i) \in E} x_{ji} = I_i, \quad i = 1, \dots, m-1.$$

Ekvivalent med optimallösning och multiplikatorer till

$$\min \frac{1}{2} \sum_{(i,j) \in E} r_{ij} x_{ij}^2$$

$$\text{då} \quad \sum_{j:(i,j) \in E} x_{ij} - \sum_{j:(j,i) \in E} x_{ji} = I_i, \quad i = 1, \dots, m-1,$$

$$x_{ij} \in \mathbb{R}, \quad (i, j) \in E.$$

Totala effekten minimeras.

## Optimalitetsvillkor för kvadratisk programmering med likhetsbivillkor

Första ordningens nödvändiga optimalitetsvillkor kan skrivas

$$\begin{pmatrix} H & A^T \\ A & 0 \end{pmatrix} \begin{pmatrix} x \\ -\lambda \end{pmatrix} = \begin{pmatrix} -c \\ b \end{pmatrix}.$$

Låt  $Z$  vara en matris vars kolumner bildar bas för  $\text{null}(A)$ .

**Påstående.** En punkt  $x^* \in \mathbb{R}^n$  är en global minpunkt till (EQP) om och endast om det finns  $\lambda^* \in \mathbb{R}^m$  så att

$$\begin{pmatrix} H & A^T \\ A & 0 \end{pmatrix} \begin{pmatrix} x^* \\ -\lambda^* \end{pmatrix} = \begin{pmatrix} -c \\ b \end{pmatrix} \quad \text{och} \quad Z^T H Z \succeq 0.$$

## Kvadratisk programmering med likhetsbivillkor

Alternativt, låt  $x$  vara given punkt och  $p$  steget till optimum,

$$\begin{aligned} \min \quad & f(x + p) = \frac{1}{2}(x + p)^T H(x + p) + c^T(x + p) \\ (EQP') \quad \text{då} \quad & Ap = b - Ax, \\ & p \in \mathbb{R}^n. \end{aligned}$$

**Påstående.** En punkt  $x + p^* \in \mathbb{R}^n$  är en global minpunkt till  $(EQP)$  om och endast om det finns  $\lambda^* \in \mathbb{R}^m$  så att

$$\begin{pmatrix} H & A^T \\ A & 0 \end{pmatrix} \begin{pmatrix} p^* \\ -\lambda^* \end{pmatrix} = - \begin{pmatrix} Hx + c \\ Ax - b \end{pmatrix} \quad \text{och} \quad Z^T H Z \succeq 0.$$

OBS! Samma  $\lambda^*$  som tidigare.

## KKT-matrisen

Matrisen  $K = \begin{pmatrix} H & A^T \\ A & 0 \end{pmatrix}$  kallas *KKT-matrisen*.

**Påstående.** Om  $A \neq 0$  är  $K \not\succeq 0$ .

Detta medför att  $K$  är en indefinit matris.

**Påstående.** Om  $Z^T H Z \succ 0$  och  $\text{rank}(A) = m$  är  $K$  ickesingulär.

Om  $Z^T H Z \succ 0$  och  $\text{rank}(A) = m$  blir  $x^*$  och  $\lambda^*$  alltså unika.

Vi antar för resten av dagen att  $Z^T H Z \succ 0$  och  $\text{rank}(A) = m$ .

Hur räknar vi ut  $x^*$  och  $\lambda^*$ ?

Vi föredrar  $(EQP')$  framför  $(EQP)$ .

## Direkt lösning med $K$

Vi kan räkna ut  $p^*$  och  $\lambda^*$  direkt med hjälp av  $K$ , dvs

$$\begin{pmatrix} H & A^T \\ A & 0 \end{pmatrix} \begin{pmatrix} p^* \\ -\lambda^* \end{pmatrix} = - \begin{pmatrix} Hx + c \\ Ax - b \end{pmatrix}.$$

Vi behöver lösa ekvationssystem där matrisen är symmetrisk och indefinit.

## Lösning med partitionerad $K$

Låt  $p^* = Zp_Z^* + Yp_Y^*$ , där  $Y \in \mathbb{R}^{n \times m}$  väljs så att  $(Z \ Y)$  är ickesingulär.

Exempelvis  $Y = A^T$  eller  $Y = \begin{pmatrix} I \\ 0 \end{pmatrix}$  där  $A = \begin{pmatrix} B & N \end{pmatrix}$  med  $B \in \mathbb{R}^{m \times m}$ ,  $B$  ickesingulär.

Vi kan då skriva  $\begin{pmatrix} H & A^T \\ A & 0 \end{pmatrix} \begin{pmatrix} Z & Y & 0 \\ 0 & 0 & I \end{pmatrix} \begin{pmatrix} p_Z^* \\ p_Y^* \\ -\lambda^* \end{pmatrix} = - \begin{pmatrix} Hx + c \\ Ax - b \end{pmatrix}$ .

Multiplikation från vänster med  $\begin{pmatrix} Z^T & 0 \\ Y^T & 0 \\ 0 & I \end{pmatrix}$  ger symmetrisk matris.

## Lösning med partitionerad $K$ , forts.

Symmetrisering genom multiplikation från vänster ger

$$\begin{pmatrix} Z^T & 0 \\ Y^T & 0 \\ 0 & I \end{pmatrix} \begin{pmatrix} H & A^T \\ A & 0 \end{pmatrix} \begin{pmatrix} Z & Y & 0 \\ 0 & 0 & I \end{pmatrix} \begin{pmatrix} p_Z^* \\ p_Y^* \\ -\lambda^* \end{pmatrix} =$$
$$- \begin{pmatrix} Z^T & 0 \\ Y^T & 0 \\ 0 & I \end{pmatrix} \begin{pmatrix} Hx + c \\ Ax - b \end{pmatrix}.$$

Observera att ekvationssystemen är ekvivalenta, då vi multiplicerar med ickesingulär matris.

## Lösning med partitionerad $K$ , forts.

Förenkling ger

$$\begin{pmatrix} Z^T H Z & Z^T H Y & 0 \\ Y^T H Z & Y^T H Y & Y^T A^T \\ 0 & AY & 0 \end{pmatrix} \begin{pmatrix} p_Z^* \\ p_Y^* \\ -\lambda^* \end{pmatrix} = - \begin{pmatrix} Z^T(Hx + c) \\ Y^T(Hx + c) \\ Ax - b \end{pmatrix}.$$

Ekvationssystemet kan nu lösas i tre steg:

$$(i) \quad AYp_Y^* = b - Ax, \quad \text{tillåten punkt}$$

$$(ii) \quad Z^T H Z p_Z^* = -Z^T(H(x + Yp_Y^*) + c), \quad \text{optimal punkt}$$

$$(iii) \quad Y^T A^T \lambda^* = Y^T(H(x + Yp_Y^* + Zp_Z^*) + c). \quad \text{lagrangemultiplikator}$$

OBS!  $p_Y$  beror inte på  $H$  och  $c$ . Endast nollrumsssteget  $p_Z$  gör det.

## Nollrumsmetod

Antag speciellt att  $x$  är tillåten, dvs  $Ax = b$ . Då blir (i) trivial.

- (i)  $AYp_Y^* = 0$ , dvs  $p_Y^* = 0$  tillåten punkt
- (ii)  $Z^T H Z p_Z^* = -Z^T(Hx + c)$ , optimal punkt
- (iii)  $Y^T A^T \lambda^* = Y^T(H(x + Zp_Z^*) + c)$ . lagrangemultiplikator

Endast steget i nollrummet,  $p_Z$ , behöver bestämmas.

Den partitionerade metoden kallas därför ofta *nollrumsmetod*.

Om faktoriseringar av  $AY$  och  $Z^T H Z$  är kända, kan (i), (ii) och (iii) lösas.

## Val av metod

Alla metoder som löser  $(EQP)$  löser ekvationssystemet

$$\begin{pmatrix} Hx + c - A^T\lambda \\ Ax - b \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}.$$

Vi har tittat på två olika sätt att göra detta på.

Vilket sätt som är bäst beror på många faktorer.

En direkt metod kan utnyttja struktur i  $K$ , men måste hantera en indefinit matris.

En nollrumsmetod jobbar med matriser av mindre dimension. Det är dock svårare att ta hänsyn till strukturen i  $K$ .

## Alternativt synsätt

Vi kan alternativt direkt betrakta det linjära ekvationssystemet

$$\begin{pmatrix} Hx + c - A^T\lambda \\ Ax - b \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}.$$

För en given initialgissning  $x$  söker vi  $x + p^*$  och  $0 + \lambda^*$  så att

$$\begin{pmatrix} H(x + p^*) + c - A^T\lambda^* \\ A(x + p^*) - b \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix},$$

dvs

$$\begin{pmatrix} H & A^T \\ A & 0 \end{pmatrix} \begin{pmatrix} p^* \\ -\lambda^* \end{pmatrix} = - \begin{pmatrix} Hx + c \\ Ax - b \end{pmatrix}.$$

## Exempel, minstakvadratproblem

Betrakta ett minstakvadratproblem

$$\begin{aligned} \min \quad & \|A^T y - c\|_2^2 \\ \text{då} \quad & y \in I\!\!R^m. \end{aligned}$$

Normalekvationerna kan skrivas  $AA^T y^* = Ac$ .

Ekvivalent omskrivning

$$\begin{pmatrix} I & A^T \\ A & 0 \end{pmatrix} \begin{pmatrix} -r^* \\ -y^* \end{pmatrix} = - \begin{pmatrix} c \\ 0 \end{pmatrix}.$$

Ekvivalent problem

$$\begin{aligned} \min \quad & \|r - c\|_2^2 \\ \text{då} \quad & Ar = 0, \\ & r \in I\!\!R^n. \end{aligned}$$

## Observation relaterat till problem med olikhetsbivillkor

Antag att  $x^* = x + p^*$  med tillhörande  $\lambda^*$  är optimallösning till

$$\begin{aligned} \min \quad & \frac{1}{2}x^T H x + c^T x \\ \text{då} \quad & Ax = b, \\ & x \in I\!R^n, \end{aligned}$$

där  $H \succ 0$ . Om  $\lambda^* \geq 0$  är  $x^*$  då också optimallösning till

$$\begin{aligned} \min \quad & \frac{1}{2}x^T H x + c^T x \\ \text{då} \quad & Ax \geq b, \\ & x \in I\!R^n. \end{aligned}$$

Denna observation är basen för en *active set* metod för att lösa kvadratiska programmeringsproblem med olikhetsbivillkor.