

# Tentamen i TMA945 Tillämpad optimeringslära 980819

---

1. Matematisk modell:

$$\begin{aligned}x_j &= \text{antal enheter som körs i process } j, j = 1, 2; \\y &= \text{antal halvtimmar som fotomodellen anlitas}\end{aligned}$$

$$\begin{aligned}\text{maximera } f(x, y) &:= 50(3x_1 + tx_2) - 3(x_1 + 2x_2) \\ &\quad - 2(2x_1 + 3x_2) - 5000y,\end{aligned}$$

$$\begin{aligned}\text{då } x_1 + 2x_2 &\leq 20,000, \\ 2x_1 + 3x_2 &\leq 35,000, \\ 3x_1 + 5x_2 &\leq 1,000 + 200y \\ x_1 \geq 0, x_2 \geq 0, 0 \leq y &\leq\end{aligned}$$

---

2. Antag att  $x_1, \dots, x_m$  är startbas. Inför ett extra bivillkor

$$\sum_{j=m+1}^n x_j \geq M, \quad M \ll 0.$$

Låt  $s$  vara slackvariabel i villkoret. En baslösning är  $(x_1, \dots, x_m, s)$ . En dualt tillåten baslösning skapas nu som följer: välj som inkommande basvariabel  $x_{j^*}$ , där  $j^* \in \arg \min\{\bar{c}_j | j = m+1, \dots, n\}$ . Om  $c_{j^*} \geq 0$  är den nuvarande basen redan dualt tillåten, annars väljs  $s$  som utgående basvariabel. Nya reducerade kostnader är 0 för  $x_1, \dots, x_m, \bar{c}_j - \bar{c}_{j^*} (\leq 0)$  för  $x_{m+1}, \dots, x_n$  och  $-\bar{c}_{j^*}$  för  $s$ , och alltså gäller att den nya basen är dualt tillåten.

Detta är ekvivalent med stora  $M$ -metoden. Det framgår till exempel genom att studera dualen till det nya problemet.

$$[p] \quad \text{minimera } f(x) := c^T x$$

$$\begin{aligned}\text{då } Ax &= b \quad \mathbf{1} = (1, 1, \dots, 1)^T \\ \mathbf{1}^T x &\leq M \\ x &\geq 0\end{aligned}$$

har ett dualt problem som är ekvivalent med LP-problemet.

$$[D'] \quad \text{maximera } g(y, a) := b^T y - Ma,$$

$$\begin{aligned}\text{då } A^T y - \mathbf{1}a &\leq c, \\ a &\geq 0\end{aligned}$$

och de två pivoteringarna är dualt ekvivalenta, ty att pivotera in  $a$  i  $[D'']$  så att högerledet ( $\bar{c}$ ) blir positivt är precis detsamma som att pivotera ut  $s$  i  $[p']$ .

3. Fall I:  $\{\nabla f(x^t)\} \rightarrow 0^n$ ,  $\{x^t\}$  och  $\{f(x^t)\}$  divergerar.

Exempel:  $f(x) = -\log x$ ;  $\{x^t\} \rightarrow \infty$ ,  $\{f(x^t)\} \rightarrow -\infty$ ,  $\{f'(x^t)\} \rightarrow 0$

Fall II:  $\{\nabla f(x^t)\} \rightarrow 0^n$ ,  $\{x^t\}$  divergerar,  $\{f(x^t)\}$  konvergerar.

Exempel:  $f(x) = 1/x$ ;  $\{x^t\} \rightarrow \infty$ ,  $\{f(x^t)\} \rightarrow 0$ ,  $\{f'(x^t)\} \rightarrow 0$

Fall III:  $\{\nabla f(x^t)\} \rightarrow 0^n$ ,  $\{x^t\}$  är begränsad,  $\{f(x^t)\}$  är begränsad.

Exempel:  $f(x) = \frac{1}{3}x^3 - x$ ;  $x^t = \begin{cases} 1 + 1/t, & t \text{ udda} \\ -1 - 1/t & t \text{ jämna} \end{cases}$

$\{x^t\}$  har två hopningspunkter,  $\pm 1$ , och  $\{f(x^t)\}$  har två hopningspunkter  $\pm 2/3$ .

Fall IV:  $\{\nabla f(x^t)\} \rightarrow 0^n$ ,  $\{x^t\}$  är begränsad,  $\{f(x^t)\}$  konvergerar.

Exempel:  $f(x) = x^2 - 1$ ;  $x^t$  som ovan;  $\{f(x^t)\} \rightarrow 0$ .

Fall V:  $\{\nabla f(x^t)\} \rightarrow 0^n$ ,  $\{x^t\}$  och  $\{f(x^t)\}$  konvergerar.

Exempel:  $f$  som ovan,  $x^2 - 1 + 1/t$

4 a) I en baslösning  $(x_0, x_N)$  gäller att

$$BX_B + NX_N = b \Leftrightarrow X_B = B^{-1}b - B^{-1}NX_N. \quad \text{Om } x_j (j \in N)$$

ökar från noll fås därför att

$$X^{NY} = \begin{bmatrix} B^{-1} \\ \mathbf{0} \end{bmatrix} + \ell \begin{bmatrix} -B^{-1}a_j \\ e_j \end{bmatrix},$$

där  $a_j$  är kolumn  $j$  i  $N$  och  $e_j$  är den  $j$ :te enhetsvektorn  $\therefore p_j = \begin{bmatrix} -B^{-1}a_j \\ e_j \end{bmatrix}$

I baslösningen gäller också att den reducerade kostnaden är

$$\bar{C}_N^T = C_N^T - C_B^T B^{-1}N.$$

Vi har nu att

$$\begin{aligned} C^T \rho_j &= (C_B, C_N)^T \rho_j = -C_B^T B^{-1}a_j + C_N^T e_j \\ &= C_j - C_B^T B^{-1}a_j = \bar{C}_j. \end{aligned}$$

Att välja minsta värdet på  $\bar{C}_j$  är alltså detsamma som att välja minsta värdet av  $\rho_j$ .

- b) Inkommandekriteriet är skalningsberoende, och beror till exempel på längden hos varje halvlinjes riktningsvektor  $\rho_j$ . Ett skalningsoberoende mått är i stället

$$\min_{j \in N} \left\{ \frac{C^T \rho_j}{\|\rho_j\|} \right\}.$$

5. Antag att  $\hat{x} \in \hat{X}$ . Konvexiteten hos  $f$  ger att

$$\begin{aligned} f(x^*) &\geq f(\hat{x}) + \nabla f(\hat{x})^T(x^* - \hat{x}) = f(\hat{x}) + \nabla f(x^*)^T(x^* - \hat{x}) \\ &= f(\hat{x}). \text{ Alltså är } \hat{x} \in x^*, \text{ och } \hat{X} \leq X^* \text{ gäller.} \end{aligned}$$

Antag att  $\hat{x} \in X^*$ . Konvexiteten hos  $f$  ger att

$$\left. \begin{aligned} f(x^*) &\geq f(\hat{x}) + \nabla f(\hat{x})^T(x^* - \hat{x}) \\ f(\hat{x}) &\geq f(x^*) + \nabla f(x^*)^T(\hat{x} - x^*) \end{aligned} \right\} \Rightarrow [\nabla f(\hat{x}) = \nabla f(x^*)]^T(\hat{x} - x^*) \geq 0.$$

Men den omvända olikheten gäller också, eftersom

$$\begin{aligned} \hat{x} \in X^* &\Rightarrow \nabla f(\hat{x})^T(x^* - \hat{x}) \geq 0 \\ x^* \in X^* &\Rightarrow \nabla f(x^*)^T(\hat{x} - x^*) \geq 0 \end{aligned} \quad \text{enligt optimalitetsvillkor.}$$

Alltså gäller att  $[\nabla f(x^*) - \nabla f(\hat{x})]^T(x^* - \hat{x}) = 0$ . Vi får då ur konvexitet-solikheten

$$f(\hat{x}) \geq f(x^*) + \nabla f(x^*)^T(\hat{x} - x^*)$$

att  $\nabla f(x^*)^T(\hat{x} - x^*) = 0$  måste gälla, ty  $f(\hat{x}) = f(x^*)$  gäller och  $\nabla f(x^*)^T(\hat{x} - x^*) \geq 0$ . Från konvexiteten hos  $f$  fås nu att  $f(x) \geq f(x^*) + \nabla f(x^*)^T(x - x^*) = f(\hat{x}) + \nabla f(x^*)^T(x - \hat{x}), \forall x \in X$ , ty  $f(\hat{x}) = f(x^*)$ . Alltså är  $\nabla f(x^*) = \nabla f(\hat{x})$ .

Alltså är  $\hat{x} \in \hat{X}$ , och  $x^* = \hat{X}$  gäller. ■

- 6 a) Lös LP-problemet med målfunktionskoefficient  $c^2 + \lambda p$ , där  $p = C^1 - C^2$ , och lös först för  $\lambda = 0$ .

Givet optimalbasen  $B$  bestäms det högsta värdet för  $\lambda$  för vilket optimalitet bibehålls: vi skall ha

$$\begin{aligned} (C_N^2 + \lambda p_N)^T - (C_B^1 + \lambda p_B)^T B^{-1} N &\leq \mathbf{0} \Leftrightarrow \\ \lambda(p_N^T - p_B^T B^{-1} N) &\leq -(C_N^{2T} - C_B^{1T} B^{-1} N). \end{aligned}$$

Av intresse är de  $i$  för vilka  $(p_N^T - p_B^T B^{-1} N)_i > 0$ . Vi får:

$$\bar{\lambda} = \min_i \left\{ -\frac{(C_N^{2T} - C_B^{1T} B^{-1} N)_i}{(p_N^T - p_B^T B^{-1} N)_i} \mid (p_N^T - p_B^T B^{-1} N)_i > 0 \right\}.$$

Det index  $i$  som ger min motsvarar den inkommande basvariabeln vid bytet som sker då  $\lambda > \bar{\lambda}$ . Om inget index  $i$  finns betyder det att basen är optimal för alla  $\lambda \geq 0$ , annars pivoteras till en ny optimal bas är nådd, varefter förfarandet upprepas från nästa aktuella värde av  $\lambda(\bar{\lambda})$ .

Kompromisslösningarna består av de optimala lösningar som passerats då  $\lambda$  har ändrats från 0 till 1.

b) Geometrisk lösning ger att

$$x^* = \begin{bmatrix} 0 \\ 3 \end{bmatrix} \text{ för } \lambda \in [0, 1/2]$$

$$x^* = \begin{bmatrix} 2 \\ 4 \end{bmatrix} \text{ för } \lambda \in [1/2, 1]$$

7 a) Brantaste lutningsmetodens sökriktning ges till exempel av  $\min \nabla f(x^t)^T p + 1/(2\gamma)\|\rho\|^2$ , ty första ordningens villkor är att  $\nabla f(x^t) + (1/\gamma)\rho = 0^n$ , d.v.s.  $\rho = -\gamma\nabla f(x^t)$ . Motsvarande  $p$  från  $\min \nabla f(x^t)^T p$  då  $\|p\| \leq \Delta$  fås genom att betrakta det ekvivalenta problemet  $\min \nabla f(x^t)^T p$ . Eftersom målfunktionen då  $\|p\|^2 \leq \Delta^2$  är linjär är bivillkoret med nödvändighet bindande, varför vi får att, för något  $\lambda > 0$ ,

$$\nabla f(x^t) + 2\lambda \cdot \rho = 0^n \text{ eller } \rho = -1/(2\lambda)\nabla f(x^t),$$

dvs samma riktning som minus gradienten av  $f$  i  $x^t$  i båda fallen.

b) I. Ett ekvivalent problem är

$$\min \psi_t(p)$$

$$\text{då } \|p\|^2 \leq \Delta_t^2.$$

första ordningens nödvändiga krav ger att

$$\nabla \psi_t(\rho) + \lambda \rho = \mathbf{0}^n, \text{ dvs}$$

$$\nabla f(x^t) + \nabla^2 f(x^t)\rho + \lambda \rho = \mathbf{0}^n, \text{ eller}$$

$$[\nabla^2 f(x^t) + \lambda I^n]\rho = -\nabla f(x^t).$$

Andra ordningen nödvändiga krav ger att

$$\nabla^2 f(x^t) + \lambda I^n \text{ är positivt semidefinition 7.}$$

II. Om  $\lambda = 0$  fås att  $p$  är Newtonriktningen. Då  $\lambda$  ökar mot  $\infty$  fås i stället en sökriktning som i limes är brantaste lutningsriktningen. (Det förra händer om  $\Delta_t$  är start nog medan det senare inträffar när  $\Delta_t$  blir allt mindre. För att se det kan man använda relationen  $\Delta_t \geq \|p\| = \|(\nabla^2 f(x^t) + \lambda I)^{-1}\nabla f(x^t)\|$ .)

Fördelen med en trustregion är att medan en sökmetod fixerar sökningen så får den här variera (med  $\Delta_t$ ) så att metoden bättre anpassas till problemets egenskaper.