



KTH Matematik

# 5B1817 Tillämpad icke linjär optimering

## Föreläsning 4

Metoder för problem utan bivillkor

# Ickelinjära programmeringsproblem utan bivillkor

Betrakta idag ett icke-linjärt programmeringsproblem utan bivillkor

$$(P) \quad \begin{array}{ll} \min & f(x) \\ \text{då} & x \in \mathbb{R}^n, \end{array} \quad \text{där } f \in C^2.$$

Önskvärt att hitta global minpunkt. I allmänhet för svårt.

Med förstaderivator: Hitta  $x^*$  så att  $\nabla f(x^*) = 0$ .

Med första- och andraderivator: Hitta  $x^*$  så att  $\nabla f(x^*) = 0$  och  $\nabla^2 f(x^*) \succeq 0$ .

Hur görs detta?

## Iterativa metoder

$$(P) \quad \begin{array}{ll} \min & f(x) \\ \text{då} & x \in \mathbb{R}^n, \end{array} \quad \text{där } f \in C^2.$$

En iterativ metod genererar  $x_0, x_1, x_2, \dots$  så att  $\lim_{k \rightarrow \infty} x_k = x^*$ , där  $x^*$  är en lösning till  $(P)$ .

Avbryter då lämpligt avbrottskriterium är uppfyllt, tex  $\|\nabla f(x_k)\| < \epsilon$ .

Idealt ska  $x^*$  vara en global minpunkt. Om  $(P)$  är ett konvext problem kan vi i allmänhet uppnå detta.

För ickekonvexa problem kommer "lösning" i allmänhet att bero på vilken derivatainformation som används.

För ickekonvexa problem är startpunkten speciellt viktig.

# Linjesökande metoder

En *linjesökande metod* genererar i varje iteration en *sökriktning* och utför *linjesökning* längs sökriktningen.

Iteration  $k$  tar följande form i punkten  $x_k$ .

- Beräkna sökriktning  $p_k$  så att  $\nabla f(x_k)^T p_k < 0$ .
- Lös approximativt  $\min_{\alpha \geq 0} f(x_k + \alpha p_k)$ , vilket ger  $\alpha_k$ .
- $x_{k+1} \leftarrow x_k + \alpha_k p_k$ .

Olika metoder baseras på olika val av  $p_k$  och  $\alpha_k$ .

## Några linjesökande metoder

Vi kommer idag initialt studera två fundamentala metoder.

- *Steepest-descentmetoden*, där  $p_k = -\nabla f(x_k)$ , och
- *Newtons metod*, där  $\nabla^2 f(x_k)p_k = -\nabla f(x_k)$ .

Steepest descent: + Sökriktningen billig att beräkna,  
– Långsam konvergens.

Newtons metod: – Sökriktningen tyngre att beräkna,  
+ Snabbare konvergens.

Vi kommer dessutom bland annat att titta på *kvasi-Newtonmetoder* som försöker efterlikna Newtons metod utan att räkna ut andraderivator.

## Kvadratisk målfunktion

Titta på modellproblem med kvadratisk målfunktion,

$$(QP) \quad \begin{array}{l} \min \quad f(x) = \frac{1}{2}x^T H x + c^T x \\ \text{då} \quad x \in \mathbb{R}^n. \end{array}$$

**Påstående.** Följande gäller för  $(QP)$  beroende på  $H$ :

(i) Om  $H \succ 0$  har  $(QP)$  en unik global minpunkt  $x^*$  som ges av  $Hx^* = -c$ .

(ii) Om  $H \succeq 0$ ,  $H \neq 0$  är varje  $x^*$  som uppfyller  $Hx^* = -c$  en global minpunkt till  $(QP)$ . (Eventuellt finns inga sådana  $x^*$ ).

(iii) Om  $H \not\succeq 0$  är  $f(x)$  obegränsad nedåt.

*Bevis.* Nödvändiga optimalitetsvillkor och konvexitet ger resultaten.  $\square$

Vi antar att  $H \succ 0$  i diskussionen.

## Linjesökning på kvadratisk målfunktion

Betrakta  $(QP)$  med  $f(x) = \frac{1}{2}x^T H x + c^T x$ , där  $H \succ 0$ . Vi får:

$x^*$  global minpunkt till  $(QP) \iff 0 = \nabla f(x^*) = Hx^* + c$ .

Antag att vi har sökriktning  $p_k$  så att  $\nabla f(x_k)^T p_k < 0$ .

Låt  $\varphi(\alpha) = f(x_k + \alpha p_k) = f(x_k) + \alpha \nabla f(x_k)^T p_k + \frac{\alpha^2}{2} p_k^T H p_k$ .

Då ger  $\alpha_k = -\frac{\nabla f(x_k)^T p_k}{p_k^T H p_k}$  global minpunkt till  $\min_{\alpha \geq 0} f(x_k + \alpha p_k)$  dvs vi kan utföra *exakt linjesökning*.

## Steepest descent på kvadratisk målfunktion

Antag att  $f(x) = \frac{1}{2}x^T H x + c^T x$ , där  $H \succ 0$ . Vi får:

Antag också att steepest descent med exakt linjesökning används, dvs

$$p_k = -\nabla f(x_k) \text{ och } \alpha_k = -\frac{\nabla f(x_k)^T p_k}{p_k^T H p_k}.$$

Det gäller då att  $f(x_{k+1}) - f(x^*) \leq \left( \frac{\text{cond}(H) - 1}{\text{cond}(H) + 1} \right)^2 (f(x_k) - f(x^*))$ ,

se Lemma 11.1 och Lemma 11.2 i Nash och Sofer.

$\text{cond}(H) \gg 1 \Rightarrow \frac{\text{cond}(H) - 1}{\text{cond}(H) + 1} \approx 1$ , dvs långsam *linjär konvergens*.

För ickelinjär målfunktion får vi typiskt sådan linjär konvergens om exakt linjesökning utförs, där  $H$  ersätts med  $\nabla^2 f(x_k)$ .



# Konvergensthastighet

**Definition.** Antag att  $x_k \in \mathbb{R}^n$ ,  $k = 0, 1, \dots$ , och att  $\lim_{k \rightarrow \infty} x_k = x^*$ . Vi säger att  $\{x_k\}_{k=0}^{\infty}$  konvergerar mot  $x^*$  med konvergensthastighet  $r$  om

$$\lim_{k \rightarrow \infty} \frac{\|x_{k+1} - x^*\|}{\|x_k - x^*\|^r} = C, \quad \text{där } C < \infty.$$

Vi får då  $\|x_{k+1} - x^*\| \approx C \cdot \|x_k - x^*\|^r$ .

Vi vill ha  $r$  stort (och  $C$  nära noll). Av intresse:

- $r = 1$ ,  $0 < C < 1$ , linjär konvergens. (Steepest descent.)
- $r = 1$ ,  $C = 0$ , superlinjär konvergens. (Kvasi-Newton.)
- $r = 2$ , kvadratisk konvergens. (Newtons metod.)

## Newton's method

Vi har  $f(x_k + p) = f(x_k) + \nabla f(x_k)^T p + \frac{1}{2} p^T \nabla^2 f(x_k) p + o(\|p\|^2)$ .

Newton's method är väldefinierad då  $\nabla^2 f(x_k) \succ 0$ . Sökriktningen  $p_k$  ges som lösningen till  $\min_{p \in \mathbb{R}^n} \nabla f(x_k)^T p + \frac{1}{2} p^T \nabla^2 f(x_k) p$ , dvs en kvadratisk approximation av målfunktionen minimeras.

Ekvivalent med att lösa  $\nabla^2 f(x_k) p_k = -\nabla f(x_k)$ .

Då  $p_k$  minimerar den kvadratiske funktionen till såväl riktning som belopp, är det naturligt att försöka välja  $\alpha = 1$  i en linjesökning.

Eftersom  $\nabla^2 f(x_k) \succ 0$  antagits får vi  $0 < p_k^T \nabla^2 f(x_k) p_k = -\nabla f(x_k)^T p_k$  om  $\nabla f(x_k) \neq 0$ , dvs  $p_k$  är en descentriktning.

En *modifierad Newtonmetod* hanterar också  $\nabla^2 f(x_k) \not\succeq 0$ .

Newton's method löser ett kvadratisk problem (med  $H \succ 0$ ) i en iteration.

## Konvergensthastighet för Newtons metod

**Sats.** Antag att  $f \in C^3$  på  $R^n$  och att  $x^*$  är en lokal minpunkt till  $(P)$  där  $\nabla^2 f(x^*) \succ 0$ . Om Newtons metod (med steglängd ett) startas i en punkt tillräckligt nära  $x^*$  så konvergerar den mot  $x^*$  med konvergensthastighet minst två.

*Bevis.* Då  $f \in C^3$ ,  $\nabla f(x^*) = 0$  och  $\nabla^2 f(x^*) \succ 0$  följer att det finns  $\rho > 0$ ,  $\beta_1 > 0$ ,  $\beta_2 > 0$  så att  $\|\nabla^2 f(x)^{-1}\| < \beta_1$  och  $\|\nabla f(x) + \nabla^2 f(x)(x^* - x)\| < \beta_2 \|x - x^*\|^2$  för alla  $x$  där  $\|x - x^*\| < \rho$ .

Välj  $\rho$  och  $x_k$  så att  $\|x_k - x^*\| < \rho$  och  $\beta_1 \beta_2 \rho < C$  för något  $C < 1$ . Då får vi

$$\begin{aligned}x_{k+1} - x^* &= x_k - \nabla^2 f(x_k)^{-1} \nabla f(x_k) - x^* \\ &= -\nabla^2 f(x_k)^{-1} (\nabla f(x_k) + \nabla^2 f(x_k)(x^* - x_k)),\end{aligned}$$

vilket ger  $\|x_{k+1} - x^*\| \leq \beta_1 \beta_2 \|x_k - x^*\|^2 \leq C \|x_k - x^*\|$ .  $\square$

## Modifierad Newtonmetod

Antag att  $\nabla f(x_k) \neq 0$ . Om vi definierar  $p_k$  ur  $B_k p_k = -\nabla f(x_k)$ , där  $B_k = B_k^T \succ 0$ , blir  $p_k$  en descentriktning.

$B_k = I \Rightarrow$  steepest descent,

$B_k = \nabla^2 f(x_k) \Rightarrow$  Newtons metod då  $\nabla^2 f(x_k) \succ 0$ .

I en modifierad Newtonmetod låter man  $B_k = \nabla^2 f(x_k)$  då  $\nabla^2 f(x_k)$  är "tillräckligt positivt definit", och låter  $B_k$  vara en positivt definit approximation av  $\nabla^2 f(x_k)$  om så inte är fallet.

Exempelvis kan man definiera en *modifierad Choleskyfaktorisering* så att  $\nabla^2 f(x_k) + E_k = L_k D_k L_k^T$ , där  $L_k$  är lågtriangulär med ettor på diagonalen,  $D_k$  är diagonal och positivt definit, samt  $E_k = 0$  om  $\nabla^2 f(x_k)$  är tillräckligt positivt definit.

# Choleskyfaktorisering

Låt  $B = B^T$ . Partitionera  $B = \begin{pmatrix} a & b^T \\ b & C \end{pmatrix}$ . Antag att  $a > 0$ . Då blir

$$\begin{aligned} B &= \begin{pmatrix} 1 & 0 \\ \frac{1}{a}b & I \end{pmatrix} \begin{pmatrix} a & 0 \\ 0 & C - \frac{1}{a}bb^T \end{pmatrix} \begin{pmatrix} 1 & \frac{1}{a}b^T \\ 0 & I \end{pmatrix} \\ &= \begin{pmatrix} 1 \\ \frac{1}{a}b \end{pmatrix} a \begin{pmatrix} 1 & \frac{1}{a}b^T \end{pmatrix} + \begin{pmatrix} 0 & 0 \\ 0 & C - \frac{1}{a}bb^T \end{pmatrix} \\ &= \begin{pmatrix} \sqrt{a} \\ \frac{1}{\sqrt{a}}b \end{pmatrix} \begin{pmatrix} \sqrt{a} & \frac{1}{\sqrt{a}}b^T \end{pmatrix} + \begin{pmatrix} 0 & 0 \\ 0 & C - \frac{1}{a}bb^T \end{pmatrix}. \end{aligned}$$

## Choleskyfaktorisering, forts.

Antag att  $B = B^T \succ 0$ . Då är  $a > 0$ . Dessutom  $C - \frac{1}{a}bb^T \succ 0$ , eftersom

$$C - \frac{1}{a}bb^T = \begin{pmatrix} -\frac{1}{a}b & I \end{pmatrix} \begin{pmatrix} a & b^T \\ b & C \end{pmatrix} \begin{pmatrix} -\frac{1}{a}b^T \\ I \end{pmatrix}.$$

Alltså, om  $B = B^T \succ 0$  kan vi skriva  $B = LDL^T$ , där  $L$  är lågtriangulär med ettor på diagonalen och  $D$  är diagonal med positiva diagonalelement.

Ekvivalent, låt  $R = D^{1/2}L^T$ . Då blir  $B = R^TR$ , där  $R$  är högtriangulär med positiva diagonalelement. Vi kallar  $R$  *Choleskyfaktorn* av  $B$ .

## Choleskyfaktorisering, forts.

Antag att  $B = B^T \succ 0$  och att vi vill lösa  $Bp = -\nabla f(x)$ .

- Bilda  $B = R^T R$ .
- Lös  $R^T u = -\nabla f(x)$ .
- Lös  $Rp = u$ .

Då  $R$  är triangulär är det enkelt att lösa med  $R$  och  $R^T$ .

Om  $B = B^T \not\succeq 0$  kan vi bilda  $B + E = R^T R$ , där  $E$  är diagonal med ickenegativa diagonalelement så att  $B + E = R^T R$ . Detta kallas *modifierad Choleskyfaktorisering*.

Vi kan då lösa  $(B + E)p = -\nabla f(x)$ , vilket leder till en form av *modifierad Newtonmetod*.

## Tillräcklig descentriktning

För att en sökriktning  $p_k$  ska garantera konvergens krävs att den ska vara en *tillräcklig descentriktning*. Typiskt villkor är

$$-\frac{\nabla f(x_k)^T p_k}{\|\nabla f(x_k)\| \|p_k\|} \geq \sigma, \quad \text{där } \sigma \text{ är en positiv konstant.}$$

Detta innebär att  $p_k$  ska uppföra sig “tillräckligt mycket” som minusgradienten.

För sökriktning  $p_k$  ur  $B_k p_k = -\nabla f(x_k)$  åstadkoms detta genom att se till att  $\|B_k\| \leq M_1$  och  $\|B_k^{-1}\| \leq M_2$ , där  $M_1$  och  $M_2$  är positiva konstanter.

För en modifierad Newtonmetod kan modifikation av  $\nabla^2 f(x_k)$  göras i modifierad Choleskyfaktorisering.



# Linjesökning

I linjesökningen bestäms  $\alpha_k$  som en approximativ lösning till  $\min_{\alpha \geq 0} \varphi(\alpha)$ , där  $\varphi(\alpha) = f(x_k + \alpha p_k)$ . Vi vill ha  $f(x_{k+1}) < f(x_k)$ , dvs  $\varphi(\alpha_k) < \varphi(0)$ . Detta villkor räcker dock ej för att visa konvergens.

Exempel på krav för att steget inte blir för långt:

$$\varphi(\alpha) \leq \varphi(0) + \mu\alpha\varphi'(0), \text{ dvs} \quad (\text{Armijo-villkor})$$

$$f(x_k + \alpha p_k) \leq f(x_k) + \mu\alpha \nabla f(x_k)^T p_k,$$

där  $\mu \in (0, \frac{1}{2})$ .

Exempel på krav för att steget inte blir för kort:

$$|\varphi'(\alpha)| \leq -\eta\varphi'(0), \text{ dvs} \quad (\text{Wolfe-villkor})$$

$$|\nabla f(x_k + \alpha p_k)^T p_k| \leq -\eta \nabla f(x_k)^T p_k,$$


där  $\eta \in (\mu, 1)$ . Alternativt krav för att steget inte blir för kort:

Tag minsta ickenegativa heltal  $i$  sådant att

$$f(x_k + 2^{-i} p_k) \leq f(x_k) + \mu 2^{-i} \nabla f(x_k)^T p_k. \quad (\text{"Backtracking"})$$

## Illustration av linjesökningsvillkoren

Linjesökningsvillkoren av Wolfe-Armijotyp illustreras i nedanstående figur.



## Linjesökningsvillkor

För att hitta  $\bar{\alpha}$  så att Wolfe och Armijo-villkoren är uppfyllda kan vi betrakta  $\hat{\varphi}(\alpha) = \varphi(\alpha) - \varphi(0) - \mu\alpha\varphi'(0)$ .

Då blir  $\hat{\varphi}(0) = 0$  och  $\hat{\varphi}'(0) < 0$ . Dessutom måste det finnas  $\bar{\alpha} > 0$  så att  $\hat{\varphi}(\bar{\alpha}) = 0$ , annars blir  $\varphi$  obegränsad nedåt.

Alltså finns enligt medelvärdessatsen  $\hat{\alpha} \in (0, \bar{\alpha})$  så att  $\hat{\varphi}(\hat{\alpha}) < 0$  och  $\hat{\varphi}'(\hat{\alpha}) = 0$ .

Då  $\mu < \eta$  får vi därmed  $\varphi(\alpha) \leq \varphi(0) + \mu\alpha\varphi'(0)$  och  $|\varphi'(\alpha)| \leq -\eta\varphi'(0)$  för  $\alpha$  i en omgivning av  $\hat{\alpha}$ .

Exempelvis kan intervallhalvering kombinerat med polynomiell interpolation användas på  $\hat{\varphi}$  för att hitta lämpligt  $\alpha$ .