

Kap. 4: del III.

minimering uten betingelser

Nødvendige og tilstrekkelige betingelser for at x^* er minifor.

Teorem 14.1: Anta $f: \mathbb{R}^n \rightarrow \mathbb{R}$ kont. part. de, x^* lokalt min

1. Da er $\nabla f(x^*) = 0$
2. Hvis f også har andreorders kont. part. de
Da er $\nabla^2 f(x^*)$ pos. semidefinit.

førsteorders bet.
andreorders bet.

Bevis: 1. Anta x^* lokalt min og anta for motsigelse at $\nabla f(x^*) \neq 0$
Sett $\vec{h} = -\alpha \nabla f(x^*)$, $\alpha > 0$

$$\nabla f(x^*)^T \vec{h} = -\alpha \nabla f(x^*)^T \nabla f(x^*) = -\alpha \|\nabla f(x^*)\|^2 < 0$$

$\Rightarrow \nabla f(x^*)^T \vec{h} < 0$ for alle \vec{x} tilstrekkelig nær x^* .

Førsteorders Taylor om x^* : Finnes en $\epsilon \in (0, 1)$ s.a.

$$f(x^* + h) - f(x^*) = \nabla f(x^* + \epsilon h)^T h < 0 \quad \text{for } h \text{ liten nok}$$

$\Rightarrow f(x^* + h) < f(x^*)$, motsigelse siden x^* antas lokalt min.

2. andreorders Taylor:
 $f(x^* + h) = f(x^*) + \underbrace{\nabla f(x^*)^T}_{=0} h + \frac{1}{2} h^T \nabla^2 f(x^* + \epsilon h) h \quad (\epsilon \in (0, 1))$

$$= f(x^*) + \frac{1}{2} h^T \nabla^2 f(x^* + \epsilon h) h$$

$$\leq f(x^* + h) + \frac{1}{2} h^T \nabla^2 f(x^* + \epsilon h) h$$

$$\frac{1}{2} h^T \nabla^2 f(x^* + \epsilon h) h \geq 0 \Rightarrow \nabla^2 f(x^* + \epsilon h) \text{ pos semidefinit.}$$

$$\Rightarrow \nabla^2 f(x^*) \text{ pos semidefinit. (La } h \rightarrow 0)$$

$$f(x) = \frac{1}{2} x^T A x - b^T x$$

A symmetrisk

A invertierbar
kan kun være et min,

førsteorders bet:

$$\nabla f(x) = Ax - b = 0$$

$$Ax = b \Rightarrow x = A^{-1} b$$

andreorders bet:

$$\nabla^2 f(x) = A, \text{ må være pos semidefinit.}$$

Lemma 14.2 Anta $A^{n \times n}$ symmetrisk pos. def., La $\lambda_n > 0$ være minste egenverdi. Da er

$$h^T A h \geq \lambda_n \|h\|^2 \text{ for alle } h \in \mathbb{R}^{n \times 1}$$

Bevis: A er ort. diagonaliserbar $\Rightarrow A = P D P^T$, D diagonal, P ortogonal

$$h^T A h = h^T P D P^T h = (P^T h)^T D P^T h = y^T D y = \sum_{i=1}^n \lambda_i y_i^2 \geq \sum_{i=1}^n \lambda_n y_i^2$$

$$= \lambda_n \sum_{i=1}^n y_i^2 = \lambda_n \|y\|^2 = \lambda_n \|P^T h\|^2 = \lambda_n \|h\|^2$$

Teorem 14.3: Anta f kont. andrerordens part. der i et område rundt x^*
 Anta ogs at $Df(x^*) = 0$, $D^2 f(x^*)$ pos. def.
 Da er x^* lokalt min.

Bevis: Lemma 14.2 + andrerordens Taylor:

$$f(x^* + h) = f(x^*) + \underbrace{Df(x^*)^T}_0 h + \frac{1}{2} h^T \overbrace{D^2 f(x^*)}^A h + \varepsilon(h) \|h\|^2$$

$$\geq \frac{1}{2} \lambda_n \|h\|^2, \lambda_n \text{ minste egenverdi i } D^2 f(x^*)$$

$$\geq f(x^*) + \frac{1}{2} \lambda_n \|h\|^2 + \varepsilon(h) \|h\|^2$$

$$\frac{f(x^* + h) - f(x^*)}{\|h\|^2} \geq \frac{1}{2} \lambda_n + \varepsilon(h) \quad \left| \text{velger } h \text{ s\u00e5 liten at } |\varepsilon(h)| < \frac{1}{4} \lambda_n \right.$$

$$\frac{f(x^* + h) - f(x^*)}{\|h\|^2} \geq \frac{1}{2} \lambda_n - \frac{1}{4} \lambda_n = \frac{1}{4} \lambda_n > 0 \Rightarrow f(x^* + h) > f(x^*) \Rightarrow x^* \text{ lokalt min}$$

Teorem 14.4 Anta $f: \mathbb{R}^n \rightarrow \mathbb{R}$ konveks

1. Hvis x^* er lokalt min, så er x^* et globalt min.
2. Hvis f også er deriverbar så gjelder at
 f lokalt min $\Leftrightarrow \nabla f(x^*) = 0$

Bevis: 1. Anta x_1 lokalt min. Hvis x_1 ikke er globalt min så finnes en x_2 s.o. $f(x_2) < f(x_1)$

For $0 < \lambda < 1$ har vi da

$$f((1-\lambda)x_1 + \lambda x_2) \leq (1-\lambda)f(x_1) + \lambda f(x_2) < (1-\lambda)f(x_1) + \lambda f(x_1) = f(x_1)$$

kan velges vilkårlig nær x_1 (velg λ liten)

så x_1 er ikke lokalt min, motsigelse \Rightarrow x_1 er globalt min.

2. \Rightarrow er allerede vist

\Leftarrow : Anta $\nabla f(x^*) = 0$

Teorem 12.10: f konveks så er $f(x) \geq f(x^*) + \underbrace{\nabla f(x^*)}_0^T (x - x^*)$

$\Rightarrow x^*$ lokalt min. $= f(x^*)$

14.2 Linjesøkmeter:

Gitt tilnærming x_k til min for f .

Finne bedre tilnærming x_{k+1} ved først å finne en søkevektning d_k , så en steglengde $\alpha_k > 0$, og sett

$$x_{k+1} = x_k + \alpha_k d_k$$

Eksekt linjesøk betyr at α_k velges som den α som gir minst verdi for $f(x_k + \alpha d_k)$

Hovedmetoder for linjesøk:

1. Steepest descent: Velg $d_k = -\nabla f(x_k)$ → artar raskere.

$$x_{k+1} = x_k - \alpha_k \nabla f(x_k)$$

Andreordens Taylor: $f(x+h) = \underbrace{f(x) + \nabla f(x)^T h}_{\text{dominerer for små } h} + \frac{1}{2} h^T \nabla^2 f(x) h$

$$\nabla f(x)^T h \geq -\|\nabla f(x)\| \|h\|$$

Likehet når $h = -\alpha \nabla f(x) \Rightarrow$ denne h gir mest reduksjon
 (er steglengde, gir mest mulig reduksjon i f)

2. Newton: $f(x_k+h) \approx \underbrace{f(x_k) + \nabla f(x_k)^T h + \frac{1}{2} h^T \nabla^2 f(x_k) h}_{\text{for et valg av } h, d_k}$

La oss finne min for denne:

$$\text{gradient: } \nabla f(x_k) + \nabla^2 f(x_k) \vec{h}$$

$$\text{Hessmatrise: } \nabla^2 f(x_k)$$

for et valg av h, d_k

Teorem 14.3: hvis $\nabla^2 f(x_k)$ er pos. def. og gradient = 0, så er punktet lokalt min.

$$\nabla f(x_k) + \nabla^2 f(x_k) \vec{h} = 0$$

$$\vec{h} = -(\nabla^2 f(x_k))^{-1} \nabla f(x_k)$$

$$x_{k+1} = x_k - (\nabla^2 f(x_k))^{-1} \nabla f(x_k) = x_k + \alpha_k d_k \quad \text{med} \quad \begin{aligned} \alpha_k &= 1 \\ d_k &= -(\nabla^2 f(x_k))^{-1} \nabla f(x_k) \end{aligned}$$

fullt Newton steg, dvs. $\alpha_k = 1$

$$\text{Newton med steglengde: } x_{k+1} = x_k - \alpha_k (\nabla^2 f(x_k))^{-1} \nabla f(x_k)$$

Def 14.5 "Backtracking" linjesøk

Anta vi har valgt $s \leq 1$, $0 < \beta < 1$, $0 < \sigma < 1$

Vi setter

$$M_k = \min \{ m : m \geq 0 \mid \underbrace{f(x_k) - f(x_k + \beta^m s d_k)}_{\text{stoppbetingelse}} \geq -\sigma \beta^m \nabla f(x_k)^T d_k \}$$

$$x_k = \beta^{m_k} s$$

Teorem 14.8

Anta $f(x) = x^T A x$, A pos. def ($\min f(0) = 0$)
steepst descent med eksakt linjesøk gir at \rightarrow startveier

$$f(x_{k+1}) \leq m_A f(x_k), \text{ der } m_A = \frac{(\lambda_1 - \lambda_n)^2}{\lambda_1 + \lambda_n} < 1, \text{ minste egeverdi}$$

Bevis ikke

linear konvergens mot 0

$$|f(x_{k+1}) - \hat{f}(0)| \leq m_A |f(x_k) - \hat{f}(0)|$$