

# KERTAUSTA

- 1 Gradientti — sen tulkinta  
Suunnattu derivaatta:
  - normalisointi on välttämätön
- 2 Ketjusäännöt
- 3 Pisteproksimaatiot
  - linearisointi
  - Taylorin polynomi
- 4 Rajoitoptimointi
  - Lagrangen kertoimet
  - epälineaarinen yhtälöryhmä
- 5 Taso- ja avaruusintegraali
  - muuttujanvaihto
  - koordinaatistomuunnokset
- 6 Massekeskipiste / Hitausmomentti
  - geometrinen hahmotus

Ensimmäiset sanat:

Eräs koe (ei välttämättä  
meidän)

- 1 Olkoon
- 2 Määritä
- 3 Funktioista
- 4 Määritä
- 5 Tarkestellään
  - a) Muodosta
  - b) laske
- 6 Olkoon

## Yhtälöryhmän ratkaisu gradienttimenetelmällä

$Ax = b$  ;  $A$  symmetrinen ja pos. def.

Yhtälöryhmän ratkaisu:  $x_*$

Alkuperäinen tehtävä voidaan esittää minimoimistehtävänä:

Etsi funktion

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

minimi!

Huomaa:  $\nabla \phi(x) = Ax - b$

Merkitään:  $x_e$  on ääriarvopisteen  
approksimaatio

Kysymys: Kuinka arvioida menetelmän  
laadua (ja tarkkuutta)?

Valiteen normi:  $\|v\|_A = \sqrt{v^T A v}$

$$\phi(x_c) = \frac{1}{2} x_c^T A x_c - x_c^T b \quad (*)$$

$$= \frac{1}{2} (x_c - x_*)^T A (x_c - x_*) \quad (**)$$
$$- \frac{1}{2} b^T A^{-1} b$$

$$= \frac{1}{2} \|x_c - x_*\|_A^2 + \phi(x_*)$$

Jos iteraatio suppenee, niin normin arvo  $\rightarrow 0$  iteraation edetessä.

Idea: Kuljetaan aina negatiivisen gradientin suuntaan!

$$(*) \quad b = A x_*$$

$$(**) \quad x_* = A^{-1} b$$

Esim.  $A = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$

$$\phi(x) = \frac{1}{2} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}^T \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

$$= \frac{1}{2} (x_1^2 + x_2^2)$$

$$\Rightarrow \nabla \phi(x) = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = A \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

Palautteen iteraatioon:

Uusi iteraatti:  $x_+ = x_c - \mu_c g_c$ ,

missä  $g_c = Ax_c - b$  ja  $\mu_c$  on ns. askelpituus,

jolle  $\phi(x_c - \mu_c g_c)$  minimoituu.

Suora lasku:

$$\begin{aligned} \phi(x_c - \mu_c g_c) &= \frac{1}{2} (x_c - \mu_c g_c)^T A (x_c - \mu_c g_c) \\ &\quad - (x_c - \mu_c g_c)^T b \end{aligned}$$

$$= \underbrace{\frac{1}{2} x_c^T A x_c - x_c^T b}_{\phi(x_c)}$$

Derivointi  $\mu_c$ :n suhteen:

$$\phi'(x_c - \mu_c g_c) = 0$$

$$\Leftrightarrow \mu_c = \frac{g_c^T g_c}{g_c^T A g_c}$$

$$- \frac{1}{2} x_c^T A \mu_c g_c - \frac{1}{2} \mu_c g_c^T A x_c \leftarrow$$

$$+ \frac{1}{2} \mu_c^2 g_c^T A g_c + \mu_c g_c^T b$$

$$= \phi(x_c) - \mu_c g_c^T (A x_c - b) + \frac{1}{2} \mu_c^2 g_c^T A g_c$$

$$= \phi(x_c) - \frac{1}{2} \frac{(g_c^T g_c)^2}{g_c^T A g_c}, \text{ valinnalle}$$

$$\mu_c = \frac{g_c^T g_c}{g_c^T A g_c}$$

Kysymys on ns. vääristys.

Suppenemisnopeus?

$$\kappa_c = \frac{g_c^T A g_c}{g_c^T g_c} \cdot \frac{g_c^T A^{-1} g_c}{g_c^T g_c} \leq \frac{\lambda_{\max}(A)}{\lambda_{\min}(A)}$$

$$= \kappa_2(A)$$