

## 2006–04–06

**Lay 7.3** Gränser för kvadratiske former, enkelt optimeringsproblem.

**SATS:** (6): Om  $A$  är reell och symmetrisk:  $Q(\mathbf{x}) = \mathbf{x}^T A \mathbf{x}$  kvadratisk form.

$$\lambda_{\min} \leq \frac{\mathbf{x}^T A \mathbf{x}}{\mathbf{x}^T \mathbf{x}} \leq \lambda_{\max}$$

där  $\lambda_{\min}$  och  $\lambda_{\max}$  är minsta respektive största egenvärde till  $A$ .

**Bevis.** Bygger på ortogonal diagonalisering.

$$Q(\mathbf{x}) = \mathbf{x}^T A \mathbf{x} = \mathbf{y}^T D \mathbf{y}, \quad \mathbf{y} = P^{-1} \mathbf{x} = P^T \mathbf{x}$$

$$\mathbf{x}^T \mathbf{x} = (P \mathbf{y})^T (P \mathbf{y}) = \mathbf{y}^T P^T P \mathbf{y} = [P \text{ ortogonal}] = \mathbf{y}^T \mathbf{y}$$

$$\text{Med } D = \begin{pmatrix} \lambda_1 & & \mathbf{0} \\ & \ddots & \\ \mathbf{0} & & \lambda_n \end{pmatrix}$$

$$Q(P \mathbf{y}) = \mathbf{y}^T D \mathbf{y} = \lambda_1 \mathbf{y}_1^2 + \lambda_2 \mathbf{y}_2^2 + \dots + \lambda_n \mathbf{y}_n^2 \geq \lambda_{\min} (\mathbf{y}_1^2 + \dots + \mathbf{y}_n^2) = \lambda_{\min} \mathbf{y}^T \mathbf{y} = \lambda_{\min} \mathbf{x}^T \mathbf{x}$$

Därmed har vi visat att  $\mathbf{x}^T A \mathbf{x} \geq \lambda_{\min} \mathbf{x}^T \mathbf{x}$ . När får vi likhet i denna olikhet? Jo, om alla  $y_i = 0$  för alla  $\lambda_i > \lambda_{\min}$ , dvs för

$$\mathbf{x} = P \mathbf{y} = \sum_{\lambda_i = \lambda_{\min}} y_i \mathbf{u}_i = \lambda_{\min} \mathbf{x}$$

där  $\mathbf{u}_i$  är en ortonormal egenvektor. Vi ser att  $\mathbf{x}$  är egenvektor till  $\lambda_{\min}$ . På samma sätt visas den övre gränsen. Likhet om  $\mathbf{x}$  är egenvektor till motsvarande  $\lambda_{\max}$ .  $\square$

**EXEMPEL.** Bestäm max och min för  $Q(\mathbf{x}) = 4x_1^2 + 4x_2^2 + 10x_3^2 + 8x_1x_3 + 8x_2x_3$  då  $\|\mathbf{x}\| = 3$ . För vilka  $\mathbf{x}$  antas dessa max/min?

Lösning:  $Q(\mathbf{x}) = \mathbf{x}^T A \mathbf{x}$  med

$$A = \begin{pmatrix} 4 & 2 & 4 \\ 2 & 4 & 4 \\ 4 & 4 & 10 \end{pmatrix}, \quad \text{egenvärden } D = \begin{pmatrix} 2 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 14 \end{pmatrix}, \quad \text{egenvektorer } P = \begin{pmatrix} -2 & -1 & 1 \\ 0 & 1 & 1 \\ 1 & 0 & 2 \end{pmatrix}$$

Detta ger

$$2 \leq \frac{\mathbf{x}^T A \mathbf{x}}{\mathbf{x}^T \mathbf{x}} \leq 14$$

$\mathbf{x}^T \mathbf{x} = 9$  ger

$$18 \leq \mathbf{x}^T A \mathbf{x} \leq 126$$

Maximum antas för

$$\mathbf{x} = t \begin{pmatrix} 1 \\ 1 \\ 2 \end{pmatrix} \text{ normerad så att } \|\mathbf{x}\| = 3$$
$$\mathbf{x} = \frac{\sqrt{6}}{2} \begin{pmatrix} 1 \\ 1 \\ 2 \end{pmatrix}$$

Minimum antas för (se beviset)

$$\mathbf{x} = y_1 \begin{pmatrix} -2 \\ 0 \\ 1 \end{pmatrix} + y_2 \begin{pmatrix} -1 \\ 1 \\ 0 \end{pmatrix} = \begin{pmatrix} -2y_1 - y_2 \\ y_2 \\ y_1 \end{pmatrix} \text{ normerad så att } \|\mathbf{x}\| = 3$$

$$\|\mathbf{x}\|^2 = (-2y_1 - y_2)^2 + y_2^2 + y_1^2 \stackrel{!}{=} 3^2$$

dvs  $\begin{pmatrix} y_1 \\ y_2 \end{pmatrix}$  på ellipsen  $5y_1^2 + 2y_2^2 + 4y_1y_2 = 9$ .

||.

Betrakta optimeringsproblemet

$(P_1)$  max  $\mathbf{x}^T A \mathbf{x}$  då  $\mathbf{x}^T \mathbf{x} = 1$  och  $\mathbf{x}^T \mathbf{u}_1 = 0$ , där vi har ordnade egenvärden  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$  med tillhörande normerade egenvektorer  $\mathbf{u}_1, \dots, \mathbf{u}_n$ .  $A$  är symmetrisk:  $A = P D P^T$  (ortogonal diagonalisering).

$$D = \begin{pmatrix} \lambda_1 & & \mathbf{0} \\ & \ddots & \\ \mathbf{0} & & \lambda_n \end{pmatrix}, \quad P = \begin{pmatrix} | & & | \\ \mathbf{u}_1 & \dots & \mathbf{u}_n \\ | & & | \end{pmatrix}$$

**SATS:** (7): Lösning till  $(P_1)$  är  $\mathbf{x} = \mathbf{u}_2$  och maximala värdet är  $\mathbf{u}_2^T A \mathbf{u}_2 = \lambda_2$ .  $\mathbf{u}_2$  är den egenvektor som hör till näst största egenvärde.

$(P_{k-1})$  max  $\mathbf{x}^T A \mathbf{x}$  då  $\mathbf{x}^T \mathbf{x} = 1$ ,  $\mathbf{x}^T \mathbf{u}_1 = 0, \dots, \mathbf{x}^T \mathbf{u}_{k-1} = 0$

**SATS:** (8): Lösning till  $(P_{k-1})$  är  $\mathbf{x} = \mathbf{u}_k$  och maxvärde  $\mathbf{u}_k^T A \mathbf{u}_k = \lambda_k$ .

**Tentauppgift.** Betrakta  $Q(\mathbf{x}) = 7x_1^2 + 3x_2^2 + 3x_1x_2$

a) bestäm största värde på  $Q(\mathbf{x})$  då  $\mathbf{x}^T \mathbf{x} = 1$ .

b) bestäm en vektor  $\mathbf{u}$  med  $\mathbf{u}^T \mathbf{u} = 1$  så att  $Q(\mathbf{u})$  blir maximal.

c) bestäm max  $Q(\mathbf{x})$  under villkor  $\mathbf{x}^T \mathbf{x} = 1$ ,  $\mathbf{x}^T \mathbf{u} = 0$ .

Lösning:  $Q(\mathbf{x}) = \mathbf{x}^T A \mathbf{x}$  med

$$A = \begin{pmatrix} 7 & \frac{3}{2} \\ \frac{3}{2} & 3 \end{pmatrix}, \quad \text{egenvärden } D = \begin{pmatrix} 2.5 & 0 \\ 0 & 7.5 \end{pmatrix}, \quad \text{egenvektorer } P = \frac{1}{\sqrt{10}} \begin{pmatrix} 1 & 3 \\ -3 & 1 \end{pmatrix}$$

a) max =  $\lambda_1 = \lambda_{\max} = 7.5$

b)  $\mathbf{u} = \mathbf{u}_1 = \frac{1}{\sqrt{10}} \begin{pmatrix} 3 \\ 1 \end{pmatrix}$

c) max =  $\lambda_2 = 2.5$  enligt sats 7.

“Ja, i och med detta är vi klara med Lays bok.”

**Potensmetoden** är en numerisk metod för egenvärden/egenvektorer. Heath 4.5.1.

Från diskreta dynamiska system:  $\mathbf{x}_{k+1} = A \mathbf{x}_k$ ,  $\mathbf{x}_0$  start.

Vi vet att om  $|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_n|$  (notera: strikt olikhet i det första). Då har vi:

$$\mathbf{x}_k \longrightarrow c_1 (\lambda_1)^k \mathbf{v}_1 \quad \text{då } k \rightarrow \infty$$

där  $A \mathbf{v}_1 = \lambda_1 \mathbf{v}_1$ . Egenparet  $(\lambda_1, \mathbf{v}_1)$  kallas dominerande. Om vi normerar i varje steg så får vi konvergens mot en normerad egenvektor  $\mathbf{u}_1$ .

Detta är potensmetoden.

–  $\mathbf{x}_0$  är start

–  $\mathbf{y}_{k+1} = A \mathbf{x}_k, \quad k = 0, 1, \dots$

–  $\mathbf{x}_{k+1} = \frac{\mathbf{y}_{k+1}}{\|\mathbf{y}_{k+1}\|}$  (för att undvika “overflow” i datorn).

Konvergens mot  $\mathbf{u}_1$  (nästan alltid). Efter konvergens kan man beräkna  $\lambda_1$  genom  $\lambda_1 = \mathbf{u}_1^T A \mathbf{u}_1$ , där  $\mathbf{u}_1$  är en normerad egenvektor.

Detta är ett specialfall av Rayleigh-kvoten. Om  $A \mathbf{x} = \lambda \mathbf{x}$  så gäller  $\mathbf{x}^T A \mathbf{x} = \lambda \mathbf{x}^T \mathbf{x} \implies$

$$\lambda = \frac{\mathbf{x}^T A \mathbf{x}}{\mathbf{x}^T \mathbf{x}}$$

**Singulärvärdesuppdelning** (svd) Lay7.4 eller Heath 3.6

**Inledning** Diagonalisering av symmetrisk matris

$$A = P D P^T = \sum_{i=1}^n \lambda_i \mathbf{u}_i \mathbf{u}_i^T$$

Spektraluppdelning:

**DEFINITION:** De singulära värdena  $\sigma_1, \dots, \sigma_n$  till en  $m \times n$ -matris är  $\sigma_i = \sqrt{\lambda_i}$  där  $\lambda_i$  är egenvärden till  $A^T A$ .

Låt  $r = \text{rang}(A)$ . Då kan  $A \in \mathbb{R}^{m \times n}$  faktoriseras:

$$A = U \Sigma V^T$$

(fig12)

$$= U_1 \Sigma_r V_1^T = \sum_{i=1}^r \sigma_i \mathbf{u}_i \mathbf{v}_i^T$$

$U$  och  $V$  är ortogonala,  $\Sigma_r$  är diagonal med  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r$  singulära värdena. Kolonnerna i  $U$  kallas vänstersingulära vektorer. Vidare gäller

$$A^T A = (V \Sigma^T U^T) (U \Sigma V^T) = V \Sigma^T \Sigma V^T$$

där

$$\Sigma^T \Sigma = \begin{pmatrix} \sigma_1^2 & & & & & \mathbf{0} \\ & \sigma_2^2 & & & & \\ & & \ddots & & & \\ & & & \sigma_r^2 & & \\ & & & & 0 & \\ \mathbf{0} & & & & & \ddots \\ & & & & & & 0 \end{pmatrix}$$

diagonalisering av  $A^T A$ .

Relation till viktiga underrumen:

$$\text{Col}(A) = \text{Col}(U_1) \quad \text{ty } A = U_1 \Sigma_r V_1^T$$

$$\text{Nul}(A) = \text{Col}(V_2) \quad \text{ty } A V_2 = \mathbf{0} \quad (A V = U \Sigma)$$

$$\text{Col}(A^T) = \text{Col}(V_1) \quad \text{ty } A^T = V_1 \Sigma_r U_1^T$$

$$\text{Nul}(A^T) = \text{Col}(U_2) \quad \text{ty } A^T U_2 = \mathbf{0}$$

### Minsta-kvadrat och SVD

Problem: minimera  $\|A \mathbf{x} - \mathbf{b}\|_2$ . Lösningen kan skrivas

$$\hat{\mathbf{x}} = V_1 \Sigma_r^{-1} U_1^T \mathbf{b} = \sum_{i=1}^r \sigma_i^{-1} \mathbf{v}_i \mathbf{u}_i^T \mathbf{b}$$

**Bevis.**

$$A \hat{\mathbf{x}} = (U_1 \Sigma_r V_1^T) (V_1 \Sigma_r^{-1} U_1^T \mathbf{b}) = U_1 U_1^T \mathbf{b}$$

dvs  $A \hat{\mathbf{x}}$  är bästa approximation av  $\mathbf{b}$  i  $\text{Col}(A) = \text{Col}(U_1)$ .  $U_1 U_1^T \mathbf{b}$  är projektionen av  $\mathbf{b}$  på underrummet.  $\square$

Överbestämt ekvationssystem  $A \mathbf{x} = \mathbf{b}$  i minsta-kvadrat-mening löses genom

$$\hat{\mathbf{x}} = V_1 \Sigma_r^{-1} U_1^T \mathbf{b}$$

$V_1 \Sigma_r^{-1} U_1^T$  kallas för en *pseudoinvers*. Betecknas  $A^+$  eller  $A^\dagger$ .  $\hat{\mathbf{x}} = A^\dagger \mathbf{b}$ .