

2006-04-07

Kontinuerliga dynamiska system

$$\mathbf{x}' = A \mathbf{x}, \quad \mathbf{x} = \mathbf{x}(t) \in \mathbb{R}^n, \quad \mathbf{x}(0) = \mathbf{x}_0$$

EXEMPEL.

$$\mathbf{x}' = \begin{pmatrix} 1 & 2 \\ -2 & 1 \end{pmatrix} \mathbf{x}, \quad \mathbf{x}(0) = \mathbf{x}_0$$

$$A = \begin{pmatrix} 1 & 2 \\ -2 & 1 \end{pmatrix} \implies D = \begin{pmatrix} 1+2i & 0 \\ 0 & 1-2i \end{pmatrix}, \quad P = \begin{pmatrix} 1 & 1 \\ i & -i \end{pmatrix}$$

Lösningsformel:

$$\mathbf{x}(t) = c_1 e^{(1+2i)t} \begin{pmatrix} 1 \\ i \end{pmatrix} + c_2 e^{(1-2i)t} \begin{pmatrix} 1 \\ -i \end{pmatrix}$$

Detta är ett godtagbart svar (många gånger) men man kan få bättre uppfattning av lösningen genom Eulers formel: $e^{x+iy} = e^x(\cos y + i \sin y)$.

$$\begin{aligned} \mathbf{x}(t) &= c_1 e^t (\cos 2t + i \sin 2t) \begin{pmatrix} 1 \\ i \end{pmatrix} + c_2 e^t (\cos(-2t) + i \sin(-2t)) \begin{pmatrix} 1 \\ -i \end{pmatrix} = \\ &= e^t \left[(c_1 + c_2) \begin{pmatrix} \cos(2t) \\ -\sin(2t) \end{pmatrix} + (c_1 - c_2) i \begin{pmatrix} \sin(2t) \\ \cos(2t) \end{pmatrix} \right] = e^t \left[z_1 \begin{pmatrix} \cos(2t) \\ -\sin(2t) \end{pmatrix} + z_2 \begin{pmatrix} \sin(2t) \\ \cos(2t) \end{pmatrix} \right] \end{aligned}$$

z_1 och z_2 bestäms från begynnelsevärden.

Potensmetoden för dominerande egenpar $(\lambda_1, \mathbf{v}_1)$ till A .

$$\mathbf{x}_0 = \text{start}$$

$$\mathbf{y}_{k+1} = A \mathbf{x}_k$$

$$\mathbf{x}_{k+1} = \frac{\mathbf{y}_{k+1}}{\|\mathbf{y}_{k+1}\|}$$

Konvergerar mot \mathbf{u}_1 som är \mathbf{v}_1 normerad.

Deflation Anta att $\{\mathbf{u}_i\}_{i=1}^n$ är en ON-bas av egenvektorer och $(\lambda_1, \mathbf{u}_1)$ är beräknat med t.ex. potensmetoden. Då ger potensmetoden på

$$A_2 = A - \lambda_1 \mathbf{u}_1 \mathbf{u}_1^T$$

“Jag vill att ni visar det: det är en eller två rader.” Konvergens mot $(\lambda_2, \mathbf{u}_2)$ om $|\lambda_2| > |\lambda_3| \geq \dots$.
Ledning: Visa att A_2 har egenvärdena $0, \lambda_2, \dots, \lambda_n$ och egenvektorerna är inte ändrade alls.

ANMÄRKNING: Man behöver inte bilda matrisen A_2 eftersom vi bara behöver kunna räkna ut A_2 gånger en vektor \mathbf{v} : $A_2 \mathbf{v} = A \mathbf{v} - \lambda_1 \mathbf{u}_1 \mathbf{u}_1^T \mathbf{v}$. Notera skalärprodukten $\mathbf{u}_1^T \mathbf{v}$: vi slipper räkna ut en ny matris. $A \mathbf{v}$ har vi redan (som avbildning betraktat: det är inte säkert att vi behöver ta fram A).

$$A \mathbf{x} = \lambda \mathbf{x} \iff \mathbf{x} = \lambda A^{-1} \mathbf{x} \iff \frac{1}{\lambda} \mathbf{x} = A^{-1} \mathbf{x}$$

Inversiteration För (beloppsmässigt) minsta egenvärde av A använder vi potensmetoden på A^{-1} eftersom A^{-1} har egenvärdena $\{\lambda_i^{-1}\}_{i=1}^n$, fungerar om det minsta egenvärdet är strikt mindre än de övriga.

Potensmetoden på A^{-1} :

$$\mathbf{x}_0 = \text{start}$$

$$\mathbf{y}_{k+1} = A^{-1} \mathbf{x}_k$$

$$\mathbf{x}_{k+1} = \frac{\mathbf{y}_{k+1}}{\|\mathbf{y}_{k+1}\|}$$

Men i andra steget gör vi inte så i praktiken. Vi löser istället $A \mathbf{y}_{k+1} = \mathbf{x}_k$ för $k = 0, 1, \dots$. Obs: LU -faktorisering *en* gång, sedan lösning av triangulära system i varje iteration

$A - \sigma I$. A har egenvärden λ_i . $A \mathbf{x} = \lambda \mathbf{x}$:

$$A \mathbf{x} - \sigma \mathbf{x} = \lambda \mathbf{x} - \sigma \mathbf{x}$$

$$(A - \sigma I) \mathbf{x} = (\lambda - \sigma) \mathbf{x}$$

$A - \sigma I$ har egenvärden $\lambda_i - \sigma$. $(A - \sigma I)^{-1}$ har egenvärden $(\lambda_i - \sigma)^{-1}$. För att få det egenvärde till A som ligger närmast σ tar vi potensmetoden på matrisen $(A - \sigma I)^{-1}$.

Algoritmen blir:

$$\sigma \text{ givet, } \mathbf{x}_0 \text{ start}$$

$$(A - \sigma I) = LU$$

$$L \mathbf{z}_k = \mathbf{x}_k$$

$$U \mathbf{y}_{k+1} = \mathbf{z}_k$$

$$\mathbf{x}_{k+1} = \frac{\mathbf{y}_{k+1}}{\|\mathbf{y}_{k+1}\|}$$

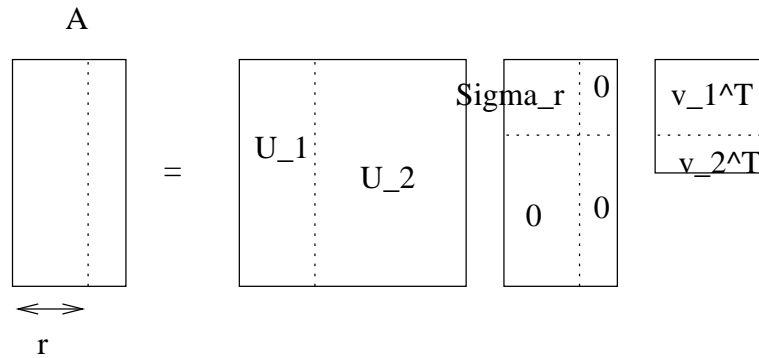
Detta kallas invers iteration med skift.

$\mathbf{x}_k \rightarrow \mathbf{u}_i$, den egenvektor till λ_i närmast σ . $\lambda_i = \mathbf{u}_i^T A \mathbf{u}_i$.

σ kan uppdateras under iterationerna eftersom $\mathbf{x}_k^T A \mathbf{x}_k \rightarrow \lambda_i$, nytt $\sigma = \mathbf{x}_k^T A \mathbf{x}_k$ efter några iterationer k . Bonusuppgift 7 är en utveckling av dessa idéer.

SVD

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



Figur 1.

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

Överbestämt system $A \mathbf{x} = \mathbf{b}$, minsta kvadrat $\min_{\mathbf{x}} \|A \mathbf{x} - \mathbf{b}\|$.

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

är en lösning. $r = \text{rang}(A)$.

ANMÄRKNING: Denna lösning är den lösning som har minsta norm $\|\cdot\|_2$. En allmän lösning är $\hat{\mathbf{x}} + \mathbf{h}$ där $\mathbf{h} \in \text{Nul}(A)$, dvs $\mathbf{h} = V_2 \mathbf{y}_2$ för något \mathbf{y}_2 (ty $\text{Nul}(A) = \text{Col}(V_2)$) och

$$\hat{\mathbf{x}} = V_1 \Sigma_r^{-1} U_1^T \mathbf{b} = V_1 \mathbf{y}_1$$

Vi har alltså

$$\begin{aligned} \|\hat{\mathbf{x}} + \mathbf{h}\| &= \|V_1 \mathbf{y}_1 + V_2 \mathbf{y}_2\|^2 = \|V \mathbf{y}\|^2 \quad \text{där } \mathbf{y} = \begin{pmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{pmatrix} \\ &= [V \text{ ortogonal}] = \|\mathbf{y}\|^2 = \|\mathbf{y}_1\|^2 + \|\mathbf{y}_2\|^2 \end{aligned}$$

som är minst om $\mathbf{y}_2 = \mathbf{0} \implies \mathbf{h} = \mathbf{0}$. Alltså är lösningen $\hat{\mathbf{x}}$ den med minst norm.

Trunkerad SVD ger bästa approximation av en matris. Vi har

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

Om vi trunkerar efter k termer får vi

$$A \approx A_k = \sum_{i=1}^k \sigma_i \mathbf{u}_i \mathbf{v}_i^T$$

Man kan visa att A_k är bästa approximation med k termer av rang-1 matriser. Felet

$$\|A - A_k\|_2 = \sigma_{k+1}$$

och

$$\kappa(A_k) = \frac{\sigma_1}{\sigma_k}, \quad \kappa(A) = \frac{\sigma_1}{\sigma_r}$$

Man kan alltså få ett mindre konditionstal genom en sådan approximation.

Tillämpningar

Bildkomprimering, skilja bruset från signaler, modellreduktion, komprimering av information.

Linjära rummet $C^0[0, 1]$, skalärprodukt

$$\langle f, g \rangle = \int_0^1 f(t) g(t) dt$$

Vad händer med vinkeln mellan $f(t) = t^n$ och $g(t) = t^{n+1}$ i $C^0[0, 1]$ då $n \rightarrow \infty$?

Lösning:

$$\langle f, g \rangle = \int_0^1 t^{2n+1} dt = \frac{1}{2n+2}$$

$$\|f\|^2 = \int_0^1 t^{2n} dt = \frac{1}{2n+1}$$

$$\|g\|^2 = \int_0^1 t^{2n+2} dt = \frac{1}{2n+3}$$

$$\cos\theta = \frac{\sqrt{2n+1} \sqrt{2n+3}}{2n+2} \rightarrow 1, n \rightarrow \infty$$

Vinkeln går mot noll: de blir nästan linjärt beroende. Slutsats: $\{t^j\}_{j=0}^{n+1}$ är ingen bra bas för \mathbb{P}_{n+1} . Men det finns polynom som är ortogonala, ger ON-bas i \mathbb{P}_{n+1} .

Spektralsatsen A symmetrisk $\Rightarrow \lambda$ reella. Visa att egenvektorererna kan väljas reella.

Lösning: $A\mathbf{v} = \lambda\mathbf{v}$, $\mathbf{v} \in \mathbb{C}^n$, $A \in \mathbb{R}^{n \times n}$, $\lambda \in \mathbb{R}$.

$$\mathbf{v} = \mathbf{x} + i\mathbf{y}: \quad A(\mathbf{x} + i\mathbf{y}) = \lambda(\mathbf{x} + i\mathbf{y})$$

$$A\mathbf{x} = \lambda\mathbf{x} \quad (\text{realdel}), \quad \mathbf{x} \in \mathbb{R}^n$$

$$A\mathbf{y} = \lambda\mathbf{y} \quad (\text{imaginärdel}), \quad \mathbf{y} \in \mathbb{R}^n$$

Jag kan ta \mathbf{x} eller \mathbf{y} , båda kan inte vara $\mathbf{0}$.