

Recuerda que clase 19 fue charla de Rodolfo sobre Algoritmo QR y convergencia del mismo basado en Ho Shub-Vasquez.

Clase 20
10/11/22
ALN 2022

→ Matrices reales simétricas $A \in \mathbb{R}^{m \times m} \mid A^T = A$

COCIENTE DE RAYLEIGH

El C.R. de un vector $x \in \mathbb{R}^m \setminus \{0\}$ (para una matriz A fija) se

define como
$$P_A(x) = \frac{x^T A x}{x^T x} = \frac{\langle Ax, x \rangle}{\langle x, x \rangle}, \quad x \neq 0.$$

Una forma de motivar ~~esta~~ el CR es que $P_A(x)$ es la solución al problema de minimizar $\| \alpha x - Ax \|^2$ con

$\alpha \in \mathbb{R}$ (que puede verse como un problema de mínimo cuadrados $\| \alpha x - b \|^2$)

Es fácil ver que la solución mínima se satisface para α /

$\alpha x - Ax \perp \alpha x$ y por lo tanto $\langle \alpha x, \alpha x - Ax \rangle = 0$

sea $\alpha \|x\|^2 = \langle Ax, x \rangle$.

Observa que P_A es invariante por cambios de escala:

$P_A(\theta x) = P_A(x)$ por lo que tiene sentido definir

$P_A: S^{m-1} \rightarrow \mathbb{R}$.

Proposición: Sean $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ los val. propios de A simétrica.


Entonces $\lambda_1 = \max_{x \in S^{m-1}} f_A(x)$, $\lambda_m = \min_{x \in S^{m-1}} f_A(x)$. Además los

puntos críticos de f_A en S^{m-1} son los vectores propios.

Dem: Una forma sencilla de ver esto es observar que

dado $x \in S^{m-1}$ y $\hat{x} \in x^\perp$ (|| \hat{x} ||=1) entonces podemos

considerar la función $t \mapsto f_A(\underbrace{\cos t x + \sin t \hat{x}}_{\gamma(t)})$



luego se tiene $Df_A(x)\hat{x} = \frac{d}{dt} f_A(\gamma(t)) \Big|_{t=0} = \frac{d}{dt} f_A(\gamma(t)) \Big|_{t=0}$ $\gamma(0) = x, \gamma'(0) = \hat{x}$

que no es otra cosa que $\frac{d}{dt} f_A$

$$\frac{d}{dt} f(\gamma(t)) \Big|_{t=0} = \frac{d}{dt} \langle A(\cos t x + \sin t \hat{x}), \cos t x + \sin t \hat{x} \rangle$$

$$= \frac{d}{dt} \left[\cos^2 t \langle Ax, x \rangle + \cos t \sin t \langle Ax, \hat{x} \rangle + \sin^2 t \langle A\hat{x}, \hat{x} \rangle \right]$$

$$\textcircled{*} = \left[-2 \cos t \sin t \langle Ax, \hat{x} \rangle + (\cos^2 t - \sin^2 t) \langle Ax, \hat{x} \rangle + 2 \sin t \cos t \langle A\hat{x}, \hat{x} \rangle \right]_{t=0}$$

$$= \langle Ax, \hat{x} \rangle$$

Por lo tanto, $Df_A(x)\hat{x} = 0$ si $\hat{x} \perp Ax \forall \hat{x} \in x^\perp$.

por lo que $Ax = \alpha x$ para algún $\alpha \in \mathbb{R}$, i.e.

x es crítico si es vector propio de f_A . \square

Si queremos poder clasificar los puntos críticos considerando el "Hessiano", en nuestro caso se puede hacer estudiando $\frac{d^2}{dt^2} \Big|_{t=0} P_A(\gamma_i(t))$ variando $\dot{x} \in x^\perp$.

De $\textcircled{*}$ resulta $\frac{d^2}{dt^2} \Big|_{t=0} P_A(\gamma_i(t)) = -2 \langle Ax, x \rangle + 2 \langle A\dot{x}, \dot{x} \rangle$

i.e. $\text{Hess}_x(x, \dot{x}) = 2 [\langle A\dot{x}, \dot{x} \rangle - \langle Ax, x \rangle]$.

Siendo x vector propio, γ x^\perp invariante resulta en $x = v_1$, $\text{Hess}_x \begin{cases} < 0 & \text{(máx)} \\ > 0 & \text{(mín)} \end{cases}$ y el resto es punto silla.



Un punto interesante del cociente de Rayleigh

es que ~~se~~ si x se acerca a vector propio v_j entonces (utilizando la función $f(t) = P_A(\gamma_i(t))$ podemos ver Taylor de orden 1 a

$$|P_A(x) - P_A(v_j)| = O(\|x - v_j\|^2).$$

Por lo tanto si tenemos una buena aproximación de un vector propio, P_A nos da una muy buena aproximación del valor propio.

Recordar que el método de la potencia aproxima el vector propio dominante, pero la velocidad de aproximación es lineal:

$$\frac{\|A^k(v) - \lambda_1 v\|}{\|A^k(v)\|} \approx \left| \frac{\lambda_2}{\lambda_1} \right|^k$$

Y además solo serviría para el vector propio dominante. Pero una simple observación puede convertir el método de la potencia en un algoritmo muy útil.

Si $\mu \in \mathbb{R}$ es cercano a λ_j (val. propio de A), entonces $A - \mu I_m$ tiene a v_j como vector propio y $\lambda_j - \mu$ como valor propio.

Por analogía $(A - \mu I_m)^{-1}$ tiene mismos vectores propios y los valores propios son $(\lambda_j - \mu)^{-1}$.

Por lo tanto si $\mu \approx \lambda_{j_0} \Rightarrow \lambda_{j_0} - \mu \approx 0$ y $(\lambda_{j_0} - \mu)^{-1}$ es gigante. En otras palabras si μ es muy cercano a un valor propio ($\min_i |\mu - \lambda_i| = |\mu - \lambda_{j_0}|$) $\Rightarrow v_{j_0}$ es el vector propio dominante de $(A - \mu I_m)^{-1}$ y por lo tanto el método de la potencia sirve para aproximarlos.

Una idea se viene a la mente, si tenemos una buena estimativa del valor propio λ_{j_0} , entonces tendremos una buena estimativa del vector propio, y utilizando el cociente de Rayleigh tendremos

una mejor estimativa del valor propio.

Este análisis requiere un algoritmo conocido con 1

Iteración de Rayleigh Quotient (de cociente de Ray)

(1) Elegir $v^{(0)} \in \mathbb{R}^n$

For $k=0, 1, 2, \dots$

(2) Si $(A - \rho_A(v^{(k)}) I_m)$ singular, resolver para encontrar vector

propio w Resolver $(A - \rho_A(v^{(k)}) I_m)w = 0$

(3) Normaliza $v^{(k+1)} := \frac{w}{\|w\|}$

Teo (Kahan-Ostrowski) Si $\phi_k = d_{\mathbb{R}}(v^{(k)}, v_{j_0}^{(0)})$ vector propio
mejor aproximación
próximo.

Entonces $v^{(k)} \rightarrow v_{j_0}^{(0)}$ vector propio

$\lim_k \frac{\phi_{k+1}}{\phi_k^3} \leq 1$. (Caso simétrico)

Por mucho tiempo se pensó que este algoritmo siempre convergía en el caso de matrices no simétricas. Pero:

Teo: (Batterson-Smith) $\forall n \geq 3 \exists$ un abierto de matrices donde el algoritmo falla (en conjunto porción de $v^{(0)}$ iniciales el algoritmo no converge.)

Desde 1960 el algoritmo más utilizado hasta 1990 es el siguiente

"Practical" QR Algorithm (Francis)

(1) $(Q^{(0)})^T A^{(0)} Q^{(0)} = A \Rightarrow A^{(0)}$ Hessenberg de A (tridional)

(2) for $k=1, 2, \dots$

elegimos $\mu^{(k)}$

\gg por ejemplo $\mu^{(k)} = A_{mm}^{(k-1)}$ o valor propio de bloques $\begin{pmatrix} A_{m-2, m-1}^{(k-1)} & A_{m-1, m}^{(k-1)} \\ A_{m, m-1}^{(k-1)} & A_{m, m}^{(k-1)} \end{pmatrix}$ más cercano a $A_{mm}^{(k-1)}$

$$Q^{(k)} R^{(k)} = A^{(k-1)} - \mu^{(k)} I_m$$

$$A^{(k)} = R^{(k)} Q^{(k)} + \mu^{(k)} I_m$$

(dimo Q y R y shift μ)

(3) Si $A_{jj}^{(k)}$ cercanos a cero,

$$\begin{pmatrix} * & * & 0 & - \\ * & * & * & 0 \\ \hline 0 & 0 & + & * \\ & & * & * \\ & & & \ddots \end{pmatrix}$$

redefinimos $A^{(k)} = \begin{bmatrix} A_1 & 0 \\ 0 & A_2 \end{bmatrix}$

y aplicamos algoritmo anterior a cada factor por separado

¿Qué podemos decir de la convergencia?

Conjetura Shub: el algoritmo falla en un abierto de condiciones iniciales.