

Matrizes Hermitianas e Simétricas

①

Já vimos anteriormente que uma matriz é hermitiana se $A^H = A$, e simétrica se $A \in \mathbb{R}^{n \times n}$ e $A^T = A$. Vimos também que matrizes hermitianas são normais, e portanto, diagonalizáveis por transformações unitárias.

Matrizes hermitianas ocorrem frequentemente na prática, e as propriedades acima são amplamente utilizadas.

Exemplos de matrizes hermitianas:

1) Seja $f: D \rightarrow \mathbb{R}$ uma função duplamente continuamente derivável no domínio $D \subset \mathbb{R}^n$. A matriz

$$H(x) = [h_{ij}(x)] = \left[\frac{\partial^2 f(x)}{\partial x_i \partial x_j} \right] \in \mathbb{R}^{n \times n}$$

é conhecida como hessiano de $f(x)$. Com as definições de $f(\cdot)$ acima, $\frac{\partial^2 f(x)}{\partial x_i \partial x_j} = \frac{\partial^2 f(x)}{\partial x_j \partial x_i}$, ou seja, $H(x) = H^T(x)$.

O hessiano é útil no estudo de minimizações de funções diferenciáveis, tanto teoricamente quanto numericamente.

2) Seja \tilde{x}_n um vetor aleatório, e defina $R = E(\tilde{x}_n \tilde{x}_n^H)$, a matriz de autocorrelação de \tilde{x}_n .

(Matriz de autocovariância se $E\tilde{x}_n = \mathbf{0}$).

R é hermitiana, pois as operações

R é,

$E(\cdot)$ e $(\cdot)^H$ comutam.

Propriedades de matrizes hermitianas

(2)

Algumas propriedades úteis de matrizes hermitianas são

1) Se $A^H = A$, A é diagonalizável por uma transformação unitária: Existe U unitária tal que

$$U^H A U = \Lambda = \text{diag}(\lambda_i).$$

Prova: Teorema 1 sobre matrizes normais.

2) Se $A^H = A$, então

a) $\underline{x}^H A \underline{x} \in \mathbb{R}$ para todo $\underline{x} \in \mathbb{C}^n$,

b) Todos os autovalores de A são reais

c) $S^H A S$ é hermitiana para todo $S \in \mathbb{C}^{n \times n}$.

Prova: (a) $(\underline{x}^H A \underline{x})^H = \overline{\underline{x}^H A \underline{x}} = \underline{x}^H A^H \underline{x} = \underline{x}^H A \underline{x}$.

Como $\bar{a} = a \iff a \in \mathbb{R}$, o resultado está provado.

(b) Seja λ um autovalor de A , com autovetor \underline{x}

satisfazendo $\underline{x}^H \underline{x} = 1$. Então,

$\lambda = \lambda \underline{x}^H \underline{x} = \underline{x}^H A \underline{x} \in \mathbb{R}$, por (a).

(c) $(S^H A S)^H = S^H (S^H A)^H = S^H A^H S = S^H A S$. ■

Na verdade, as propriedades acima definem matrizes hermitianas ((b) precisa ser um pouco modificada):

Teorema 1: $A \in \mathbb{C}^{n \times n}$ é hermitiana se e somente se uma das condições abaixo for satisfeita:

(a) $\underline{x}^H A \underline{x} \in \mathbb{R}$ para todo $\underline{x} \in \mathbb{C}^n$,

(b) A é normal e todos os seus autovalores são reais,

(c) $S^H A S$ é hermitiana para todo $S \in \mathbb{C}^{n \times n}$.

(d) Existe uma transformação unitária U e uma matriz real e diagonal Λ tais que $A = U \Lambda U^H$.

Para matrizes hermitianas, pode-se definir autovalores de uma maneira alternativa, através de problemas de minimização e maximização. Esta caracterização levará à definição de valores singulares no futuro.

Teorema 2: Seja $A \in \mathbb{C}^{n \times n}$, e sejam $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$ os autovalores de A . Então vale para todo $\underline{x} \in \mathbb{C}^n$, com $\|\underline{x}\|_2 = 1$,

$$\lambda_1 \leq \underline{x}^H A \underline{x} \leq \lambda_n, \text{ ou } \lambda_{\max} = \lambda_n = \max_{\substack{\underline{x} \neq \underline{0} \\ \|\underline{x}\|_2 = 1}} \frac{\underline{x}^H A \underline{x}}{\underline{x}^H \underline{x}}$$

$$\lambda_{\min} = \lambda_1 = \min_{\substack{\underline{x} \neq \underline{0} \\ \|\underline{x}\|_2 = 1}} \frac{\underline{x}^H A \underline{x}}{\underline{x}^H \underline{x}}$$

Prova: Seja U unitária que diagonaliza A . Então $\underline{x}^H A \underline{x} = \underline{x}^H U \Lambda U^H \underline{x} \triangleq \underline{y}^H \Lambda \underline{y} = \sum_{i=1}^n \lambda_i |y_i|^2$

Como $|y_i|^2 \geq 0$, vem

$$(1) \quad \lambda_{\min} \cdot \sum_{i=1}^n |y_i|^2 \leq \sum_{i=1}^n \lambda_i |y_i|^2 = \underline{x}^H A \underline{x} \leq \lambda_{\max} \sum_{i=1}^n |y_i|^2$$

Como U é unitária, $\sum_{i=1}^n |y_i|^2 = \|\underline{y}\|_2^2 = \|\underline{x}\|_2^2$.

Assuma que $\Lambda = \begin{bmatrix} \lambda_1 & & \\ & \lambda_2 & \\ & & \ddots \\ & & & \lambda_n \end{bmatrix}$ (isto sempre pode

ser conseguido reordenando-se as colunas de U). Então, escolhendo \underline{x} tal que $U \underline{x} = \underline{e}_1 = \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$, temos

$$\underline{x}^H A \underline{x} = \lambda_1 \cdot 1^2 = \lambda_1 \cdot \|\underline{x}\|_2^2, \text{ ou seja a primeira}$$

desigualdade de (1) torna-se uma igualdade para esta particular escolha de \underline{x} . Portanto,

$$\lambda_1 = \min_{\substack{\underline{y} \neq \underline{0} \\ \|\underline{y}\|_2 = 1}} \frac{\sum_{i=1}^n \lambda_i |y_i|^2}{\|\underline{y}\|_2^2} = \min_{\substack{\underline{x} \neq \underline{0} \\ \|\underline{x}\|_2 = 1}} \frac{\underline{x}^H A \underline{x}}{\underline{x}^H \underline{x}}$$

Usando-se um argumento semelhante para λ_n , conclui-se a demonstração.

Matrizes Positivas - Definidas

Vamos começar esta seção definindo e apresentando algumas propriedades de matrizes positivas-definidas. Em seguida apresentaremos alguns exemplos.

Definição 1: Uma matriz hermitiana $A \in \mathbb{C}^{n \times n}$ é positiva-definida se

$$\underline{x}^H A \underline{x} > 0 \text{ para todo } \underline{x} \in \mathbb{C}^n.$$

Se valer apenas $\underline{x}^H A \underline{x} \geq 0$, diz-se que A é positiva-semidefinida. Analogamente, diz-se que

A é negativa (semi)definida se $(-A)$ for positiva (semi)definida.

Propriedades Básicas (as demonstrações ficam como exercícios)

1) Se $A \in \mathbb{C}^{n \times n}$ for positiva definida, todos os seus autovalores são reais e positivos (reais e não negativos se A for positiva semi definida)

2) Considere as seguintes submatrizes obtidas a partir de $A = [a_{ij}]$ tomando-se apenas algumas das linhas e colunas de A :

$$\begin{aligned} \text{Sejam } \alpha &= \{i_1, i_2, \dots, i_{n_\alpha}\}, 1 \leq i_1 < i_2 < \dots < i_{n_\alpha} \leq n \\ \beta &= \{j_1, j_2, \dots, j_{n_\beta}\}, 1 \leq j_1 < j_2 < \dots < j_{n_\beta} \leq n \\ n_\alpha, n_\beta &\leq n. \end{aligned}$$

A submatriz $A_{\alpha\beta}$ de A é a matriz formada tomando-se apenas os elementos a_{ikj_ℓ} , $\begin{cases} i_k \in \alpha, \text{ ou} \\ j_\ell \in \beta \end{cases}$

$$\text{ex: } A_{\alpha\beta} = [a_{ikj_\ell}] = \begin{bmatrix} a_{i_1 j_1} & a_{i_1 j_2} & \dots & a_{i_1 j_{n_\beta}} \\ \vdots & \vdots & \ddots & \vdots \\ a_{i_{n_\alpha} j_1} & a_{i_{n_\alpha} j_2} & \dots & a_{i_{n_\alpha} j_{n_\beta}} \end{bmatrix}$$

Por exemplo, se

$$A = \begin{bmatrix} 1 & 0 & 2 & 1 \\ -1 & 1 & 0 & 2 \\ -2 & 0 & 0 & 3 \\ 0 & 1 & 1 & 1 \end{bmatrix}$$

$$\alpha = \{2, 3\}$$
$$\beta = \{1, 2\}$$

(2)

então $A_{\alpha\beta} = \begin{bmatrix} -1 & 1 \\ -2 & 0 \end{bmatrix}$.

Caso $\alpha = \beta$, $A_{\alpha\beta}$ é chamada uma submatriz principal de A , e $\det(A_{\alpha\beta})$ é um menor principal de A .

Se A for positiva definida, toda submatriz principal de A também é positiva definida, e todo menor principal é positivo.

Se A for positiva semi-definida, as submatrizes principais também o serão, e os menores principais serão não-negativos.

- 3) Corolário de (1): Se A é positiva definida, A é invertível.
- 4) Corolário de (2): Se A é positiva definida, os elementos da diagonal principal são positivos. Em particular, $\text{Tr}(A) > 0$.
- 5) A soma de duas matrizes positivas-definidas também é positiva-definida.
- 6) Se $A \in \mathbb{C}^{n \times n}$ é positiva-definida, $C \in \mathbb{C}^{n \times m}$ é positiva-definida se e somente se $\text{posto}(C) = m$. Se $\text{posto}(C) < m$, então $C^H A C$ é positiva semi-definida. Se A é positiva semi-definida, então $C^H A C$ é sempre positiva semi-definida.
- 7) A é positiva-definida se e somente se A^{-1} for positiva-definida.
- 8) Seja $A \in \mathbb{C}^{n \times n}$ positiva-definida. Então para qualquer $k \in \mathbb{Z}, |k| \geq 1$, existe $B \in \mathbb{C}^{n \times n}$ tal que $B^k = A$.

Prova de 8

(3)

Seja A hermitiana, existem U unitária e Λ diagonal tais que $A = U \Lambda U^H$. Como $\lambda_i > 0$ (λ_i são os elementos da diagonal de Λ), podemos definir

$$B = U \begin{bmatrix} \lambda_1^{1/k} & & & \\ & \lambda_2^{1/k} & & \\ & & \ddots & \\ & & & \lambda_n^{1/k} \end{bmatrix} U^H \triangleq U \Lambda^{1/k} U^H.$$

Confirme que $B^k = A$. Note que sempre é possível escolher B positiva-definida também. ■

9) Decomposição de Cholesky.

Uma matriz $A \in \mathbb{C}^{n \times n}$ é positiva-definida se e somente se existir $L \in \mathbb{C}^{n \times n}$ (triangular inferior com elementos positivos na diagonal) tal que

$$A = L L^H.$$

Se A for real, L pode ser escolhida real também.

Prova: Por (8), existe B tal que $B^2 = A$, e podemos escolher B positiva-definida. Sejam Q e R as matrizes unitária e triangular superior tais que $B = QR$.

Então

$$A = B^2 = B^H B = R^H Q^H Q R = R^H R.$$

Como A é positiva-definida e R é triangular, temos $0 < \det(A) = |\det(R)|^2 = \prod_{i=1}^n |r_{ii}|^2$, mas em geral $r_{ii} \notin \mathbb{R}$ (e portanto, não podemos dizer que $r_{ii} > 0$). No entanto, podemos definir

$$L^H = \begin{bmatrix} e^{j\theta_1} & & & \\ & e^{j\theta_2} & & \\ & & \ddots & \\ & & & e^{j\theta_n} \end{bmatrix} \quad R = \begin{bmatrix} e^{j\theta_1} r_{11} & e^{j\theta_1} r_{12} & \dots & e^{j\theta_1} r_{1n} \\ 0 & e^{j\theta_2} r_{22} & \dots & e^{j\theta_2} r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & e^{j\theta_n} r_{nn} \end{bmatrix}$$

Se escolhermos θ_i de forma que

$$e^{j\theta_i} r_{ii} = |r_{ii}|, \text{ a matriz } L \text{ satisfaz as condições do teorema.} \quad \blacksquare$$

Exemplo: Análise de Filtro Adaptativo LMS.

Considere duas seqüências de variáveis aleatórias $\{x_k\}_{k=0}^{\infty}$, $x_k \in \mathbb{R}^m$, e $\{y(k)\}_{k=0}^{\infty}$, $y(k) \in \mathbb{R}$. Pode-se

demonstrar que, se $\{y(k), x_k\}$ for uma seqüência estacionária, ^{$E y(k)=0, E x_k=0$} então existe um vetor de parâmetros

w_* que relaciona x_k e $y(k)$ linearmente como abaixo:

$$y(k) = w_*^T x_k + v(k),$$

onde $v(k)$ é o erro de estimação (uma outra variável aleatória), e $v(k)$ é não correlacionado com x_k , isto é, $E v(k) x_k = 0$.

O filtro adaptativo LMS procura calcular uma estimativa para w_* através da recursão

$$w_{k+1} = w_k + \mu x_k (y(k) - w_k^T x_k). \quad (1)$$

A análise estocástica do filtro acima procura calcular para que valores a média e a matriz de autocorrelação de w_k convergem, isto é,

$$\lim_{k \rightarrow \infty} E \tilde{w}_k, \quad \text{e} \quad \lim_{k \rightarrow \infty} E \tilde{w}_k \tilde{w}_k^T, \quad \text{onde } \tilde{w}_k = w_k - w_*$$

Para tanto, usam-se ^{muitas vezes.} as hipóteses de independência, ou seja, assume-se que $\{y(k), x_k\}$ são brancos, isto é, que $\begin{cases} y(k) \text{ é independente de } x_j \text{ se } k \neq j. \\ y(k) \text{ é independente de } y(j) \text{ se } k \neq j \\ x_k \text{ é independente de } x_j \text{ se } k \neq j \\ v(k) \text{ é independente de todas as outras variáveis.} \end{cases}$

Neste caso, podemos calcular $E \tilde{w}_k$ e $E \tilde{w}_k \tilde{w}_k^T$ como a seguir. Primeiramente, vamos escrever a recursão (1) em termos de \tilde{w}_k :

$$\begin{aligned} w_{n*} - \tilde{w}_{k+1} &= w_{n*} - w_k - \mu x_k (y(k) - w_k^T x_k) \\ &= \tilde{w}_k - \mu x_k (w_{n*}^T x_k - w_k^T x_k) \\ &= \tilde{w}_k - \mu x_k x_k^T \tilde{w}_k = (I - \mu x_k x_k^T) \tilde{w}_k. \quad (2) \end{aligned}$$

Portanto,

$$E \tilde{w}_{k+1} = E \left[(I - \mu x_k x_k^T) \tilde{w}_k \right].$$

Como x_k é independente de x_j para $j < k$, e de $v(j)$ para $j \leq k$, e como \tilde{w}_k depende apenas de $x_j, v(j)$ para $j \leq k-1$, concluímos que \tilde{w}_k é independente de x_k . Portanto,

$$E \tilde{w}_{k+1} = E (I - \mu x_k x_k^T) E \tilde{w}_k.$$

Definindo $R = E x_k x_k^T$, temos

$$E \tilde{w}_{k+1} = (I - \mu R) E \tilde{w}_k,$$

$$\text{e } E \tilde{w}_{k+1} = (I - \mu R)^{k+1} E \tilde{w}_0.$$

Portanto, $E \tilde{w}_k \rightarrow 0$ se e somente se

$$(I - \mu R)^k \rightarrow 0.$$

Vimos anteriormente que isto ocorre se e somente se $\rho(I - \mu R) < 1$. Vamos então calcular $\rho(I - \mu R)$ (ou seja, o módulo máximo dos autovalores de $I - \mu R$).

Como R é normal, existe Q unitária tal (6)
que

$$Q^H R Q = \Lambda = \text{diag}(\lambda_i).$$

Portanto,

$$Q^H (I - \mu R) Q = I - \mu Q^H R Q = I - \mu \Lambda.$$

Concluímos que os autovalores de $I - \mu R$ são $1 - \mu \lambda_i$, $1 \leq i \leq n$, e que

$E \tilde{w}_k \rightarrow 0$ se e somente se

$$|1 - \mu \lambda_i| < 1 \text{ para todo } \lambda_i.$$

Como R é positiva-semidefinida (por ser uma matriz de autocorrelação), então $\lambda_i \geq 0$ para $1 \leq i \leq n$, e a condição acima fica

$$-1 < 1 - \mu \lambda_i < 1 \Leftrightarrow \begin{cases} 1 - \mu \lambda_i < 1 \Rightarrow \mu \lambda_i > 0 \text{ (A)} \\ -1 < 1 - \mu \lambda_i \Rightarrow \mu \lambda_i < 2 \text{ (B)} \end{cases}$$

A condição (A) é satisfeita se R for positiva-definida (ou seja, se R for invertível). (B) é satisfeita se μ for escolhido suficientemente pequeno.

Exemplo: Suponha que a e b são duas variáveis aleatórias ^{reais} com $Ea = Eb = 0$, (7)

$$Ea^2 = \sigma_a^2, \quad Eb^2 = \sigma_b^2, \quad Eab = \sigma_{ab} \neq 0.$$

Suponha também que $\{a, b\}$ são conjuntamente Gaussianas.

Como calcular $E(a^2b^2)$?

Solução: Defina $R = \begin{bmatrix} \sigma_a^2 & \sigma_{ab} \\ \sigma_{ab} & \sigma_b^2 \end{bmatrix}$. R é positiva-

semidefinida e normal, portanto existe Q ortogonal

tal que $Q^T R Q = \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix}$. (3)

Defina $x = q_1^T \begin{bmatrix} a \\ b \end{bmatrix}$, e $y = q_2^T \begin{bmatrix} a \\ b \end{bmatrix}$, onde

$$[q_1 \quad q_2] = Q \quad (\text{as colunas de } Q).$$

Como a e b são conjuntamente Gaussianas, x e y também serão conjuntamente Gaussianos, e (3) implica que x e y são independentes.

Por outro lado,

$$\begin{bmatrix} x \\ y \end{bmatrix} = Q^T \begin{bmatrix} a \\ b \end{bmatrix} \Rightarrow \begin{bmatrix} a \\ b \end{bmatrix} = Q \begin{bmatrix} x \\ y \end{bmatrix}, \text{ e}$$

$$a = q_{11}x + q_{12}y$$

$$b = q_{21}x + q_{22}y$$

$$a^2 = q_{11}^2 x^2 + 2q_{11}q_{12}xy + q_{12}^2 y^2$$

$$b^2 = q_{21}^2 x^2 + 2q_{21}q_{22}xy + q_{22}^2 y^2$$

e portanto,

$$Ea^2b^2 = (Ex^2) q_{11}^2 q_{21}^2 + 2(q_{11}q_{12} + q_{21}q_{22})$$

Com isto podemos agora calcular $E a^2 b^2$:

⑧

Como x e y têm média zero (verifique!),
e são independentes,

$$E(x \cdot y^3) = \overset{=0}{E x} \cdot E y^3 = 0$$

$$E(x^3 \cdot y) = E x^3 \cdot \underset{=0}{E y} = 0$$

$$E(x^2 \cdot y^2) = (E x^2)(E y^2) = \lambda_1 \cdot \lambda_2$$

Portanto, temos

$$E(a^2 \cdot b^2) = q_{11}^2 \cdot q_{21}^2 \cdot E x^4 + (q_{11}^2 \cdot q_{22}^2 + q_{21}^2 \cdot q_{12}^2 + 4 q_{11} q_{12} q_{21} q_{22}) \lambda_1 \lambda_2 \\ + q_{12}^2 \cdot q_{22}^2 \cdot E y^4.$$

Falta apenas calcular $E x^4$ e $E y^4$, mas isto

consegue-se de um livro qualquer sobre probabilidades
(por exemplo,):

Como x e y são Gaussianos com médias iguais a 0 e
variâncias λ_1 e λ_2 respectivamente, segue que

$$E x^4 = 3 \lambda_1^2$$

$$E y^4 = 3 \lambda_2^2.$$