

CÁLCULO DE AUTO-VALORES E AUTO-VETORES

Teorema1: Se $\{\mathbf{V}^1, \mathbf{V}^2, \dots, \mathbf{V}^n\}$ é um conjunto L.I. no \mathbb{R}^n então qualquer vetor $\mathbf{x} \in \mathbb{R}^n$ pode ser escrito unicamente como

$$\mathbf{x} = \beta_1 \mathbf{V}^1 + \beta_2 \mathbf{V}^2 + \dots + \beta_n \mathbf{V}^n$$

Teorema2: Seja $A_{n \times n}$ e $\lambda_1, \lambda_2, \dots, \lambda_n$ os auto-valores de A com respectivos autovetores $\mathbf{V}^1, \mathbf{V}^2, \dots, \mathbf{V}^n$. Então o conjunto $\{\mathbf{V}^1, \mathbf{V}^2, \dots, \mathbf{V}^n\}$ é um conjunto L.I. no \mathbb{R}^n .

MÉTODO DAS POTÊNCIAS

Esse é um método iterativo para determinar o maior auto-valor em módulo de uma matriz $A_{n \times n}$. Além de calcular o maior auto-valor, esse método fornece também o auto-vetor associado ao auto-valor encontrado.

Seja $A_{n \times n}$ com n -auto-valores $\lambda_1, \lambda_2, \dots, \lambda_n$ e $\{\mathbf{V}^1, \mathbf{V}^2, \dots, \mathbf{V}^n\}$ os auto-vetores associados ao respectivos auto-valores, isto é, $A\mathbf{V}^i = \lambda_i \mathbf{V}^i$ ($A\mathbf{V}^1 = \lambda_1 \mathbf{V}^1, A\mathbf{V}^2 = \lambda_2 \mathbf{V}^2, \dots, A\mathbf{V}^n = \lambda_n \mathbf{V}^n$).

Seja $\mathbf{x} \in \mathbb{R}^n$. Como $\{\mathbf{V}^1, \mathbf{V}^2, \dots, \mathbf{V}^n\}$ é L.I., existem $\beta_1, \beta_2, \dots, \beta_n$ tal que

$$\mathbf{x} = \sum_{j=1}^n \beta_j \mathbf{V}^j = \beta_1 \mathbf{V}^1 + \beta_2 \mathbf{V}^2 + \dots + \beta_n \mathbf{V}^n \quad (1)$$

Multiplicando (1) por A, A^2, A^3, \dots, A^k , temos:

$$A\mathbf{x} = A \left(\sum_{j=1}^n \beta_j \mathbf{V}^j = \beta_1 \mathbf{V}^1 + \beta_2 \mathbf{V}^2 + \dots + \beta_n \mathbf{V}^n \right) = \beta_1 A\mathbf{V}^1 + \beta_2 A\mathbf{V}^2 + \dots + \beta_n A\mathbf{V}^n$$

$$A\mathbf{x} = \beta_1 \lambda_1 A\mathbf{V}^1 + \beta_2 \lambda_2 A\mathbf{V}^2 + \dots + \beta_n \lambda_n A\mathbf{V}^n$$

$$A\mathbf{x} = \sum_{j=1}^n \beta_j \lambda_j \mathbf{V}^j$$

$$A^2\mathbf{x} = AA\mathbf{x} = A \left(\sum_{j=1}^n \beta_j \lambda_j \mathbf{V}^j \right) = \sum_{j=1}^n \beta_j \lambda_j A\mathbf{V}^j = \sum_{j=1}^n \beta_j \lambda_j (\lambda_j \mathbf{V}^j)$$

$$A^2\mathbf{x} = \sum_{j=1}^n \beta_j \lambda_j^2 \mathbf{V}^j$$

$$A^k\mathbf{x} = \sum_{j=1}^n \beta_j \lambda_j^k \mathbf{V}^j$$

Fatorando λ_1^k , vem:

$$A^k \mathbf{x} = \lambda_1^k \sum_{j=1}^n \beta_j \frac{\lambda_j^k}{\lambda_1^k} \mathbf{V}^j$$

Como $|\lambda_1| > |\lambda_j|, j = 2, 3, \dots, n$, temos que

$$\lim_{k \rightarrow \infty} A^k \mathbf{x} = \lambda_1^k \beta_1 \mathbf{V}^1 \quad (2)$$

que converge para 0 se $|\lambda_1| < 1$ e diverge se $|\lambda_1| > 1$ (se $\beta_1 \neq 0$). No entanto, podemos modificar eq. (2) de modo que o limite seja sempre finito e não-nulo como segue:

Seja \mathbf{x} um vetor unitário, digamos, $\mathbf{x}^{(0)}$ e $x_{p_0}^{(0)}$ a componente de $\mathbf{x}^{(0)}$ tal que

$$x_{p_0}^{(0)} = 1 = \|\mathbf{x}^{(0)}\|_{\infty} \text{hspace} * 1.0\text{cm} \left(\begin{array}{l} \text{ex: } \mathbf{x}^{(0)} = [0.2 \ 0.6 \ 1.0]^T \\ x_{p_0}^{(0)} = |x_3^{(0)}| = 1.0, \quad \therefore p_0 = 3 \end{array} \right)$$

Seja $\mathbf{y}^{(1)} = A\mathbf{x}^{(0)}$ e defina $\mu^{(1)} = y_{p_0}^{(1)}$. Então

$$\mu^{(1)} = y_{p_0}^{(1)} = \frac{y_{p_0}^{(1)}}{x_{p_0}^{(0)}} = \frac{\beta_1 \lambda_1 V_{p_0}^1 + \beta_2 \lambda_2 V_{p_0}^2 + \dots + \beta_n \lambda_n V_{p_0}^n}{\beta_1 V_{p_0}^1 + \sum_{j=2}^n \beta_j V_{p_0}^j} = \frac{\beta_1 \lambda_1 V_{p_0}^1 + \sum_{j=2}^n \beta_j \lambda_j V_{p_0}^j}{\beta_1 V_{p_0}^1 + \sum_{j=2}^n \beta_j V_{p_0}^j}$$

Seja p_1 o menor inteiro tal que

$$|y_{p_1}^{(1)}| = \|\mathbf{y}^{(1)}\|_{\infty}$$

e defina $\mathbf{x}^{(1)}$ como sendo

$$\mathbf{x}^{(1)} = \frac{1}{y_{p_1}^{(1)}} \mathbf{y}^{(1)} = \frac{1}{y_{p_1}^{(1)}} A\mathbf{x}^{(0)}$$

Então,

$$x_{p_1}^{(1)} = 1 = \|\mathbf{x}^{(1)}\|_{\infty}$$

Seja agora,

$$\mathbf{y}^{(2)} = A\mathbf{x}^{(1)} = \frac{1}{y_{p_1}^{(1)}} A^2 \mathbf{x}^{(0)}$$

e

$$\mu^{(2)} = y_{p_1}^{(2)} = \frac{y_{p_1}^{(2)}}{x_{p_1}^{(1)}} = \frac{\left[\beta_1 \lambda_1^2 V_{p_1}^1 + \sum_{j=2}^n \beta_j \lambda_j^2 V_{p_1}^j \right] / y_{p_1}^{(1)}}{\left[\beta_1 \lambda_1 V_{p_1}^1 + \sum_{j=2}^n \beta_j \lambda_j V_{p_1}^j \right] / y_{p_1}^{(1)}} \text{hspace} * 1.0\text{cm} = \lambda_1 \frac{\left[\beta_1 V_{p_1}^1 + \sum_{j=2}^n \beta_j \left(\frac{\lambda_j}{\lambda_1} \right)^2 V_{p_1}^j \right]}{\left[\beta_1 V_{p_1}^1 + \sum_{j=2}^n \beta_j \left(\frac{\lambda_j}{\lambda_1} \right) V_{p_1}^j \right]}$$

Seja p_2 o menor inteiro com

$$|y_{p_2}^{(2)}| = \|\mathbf{y}^{(2)}\|_{\infty}$$

e definamos

$$\mathbf{x}^{(2)} = \frac{1}{y_{p_2}^{(2)}} \mathbf{y}^{(2)} = \frac{1}{y_{p_2}^{(2)}} A \mathbf{x}^{(1)} = \frac{1}{y_{p_2}^{(2)} y_{p_1}^{(1)}} A^2 \mathbf{x}^{(0)}.$$

De maneira semelhante, podemos definir sequencias de vetores $\{\mathbf{x}^{(m)}\}_0^\infty$ e $\{\mathbf{y}^{(m)}\}_0^\infty$ e uma sequencia de escalares $\{\mu^{(m)}\}_0^\infty$, indutivamente por:

$$\mathbf{y}^{(m)} = A \mathbf{x}^{(m-1)} \quad (3)$$

$$\mu^{(m)} = y_{p_{m-1}}^{(m)} = \lambda_1 \left[\frac{\beta_1 V_{p_{m-1}}^1 + \sum_{j=2}^n \beta_j \left(\frac{\lambda_j}{\lambda_1}\right)^m V_{p_{m-1}}^j}{\beta_1 V_{p_{m-1}}^1 + \sum_{j=2}^n \beta_j \left(\frac{\lambda_j}{\lambda_1}\right)^{m-1} V_{p_{m-1}}^j} \right] \quad (4)$$

$$\mathbf{x}^{(m)} = \frac{\mathbf{y}^{(m)}}{y_{p_m}^{(m)}} = \frac{A^{(m)} \mathbf{x}^{(0)}}{\prod_{k=1}^m y_{p_k}^{(k)}} \quad (5)$$

onde em cada iteraçãõ, p_m é utilizado para representar o menor inteiro tal que

$$|y_{p_m}^{(m)}| = \|\mathbf{y}^{(m)}\|_\infty$$

Examinando Eq. (4), vemos que se $\mathbf{x}^{(0)}$ for escolhido de modo que tenhamos $\beta_1 \neq 0$ então teremos (desde que $|\lambda_j/\lambda_1| < 1, j = 2, 3, \dots, n$):

$$\lim_{m \rightarrow \infty} \mu^{(m)} = \lambda_1$$

Pode-se provar ainda que se sequencia de vetores $\{\mathbf{x}^{(m)}\}_0^\infty$ converge para o auto-vetor associado ao auto-valor λ_1 .

OBSERVAÇÕES:

1. No início, não se sabe se a matriz tem autovalor dominante único (por ex. a matriz pode ter autovalores $\lambda_1 = 10$ e $\lambda_3 = -10$).
2. Também não se sabe como escolher $\mathbf{x}^{(0)}$ de modo a assegurar que sua representação em termos dos autovetores $\{\mathbf{V}^1, \mathbf{V}^2, \dots, \mathbf{V}^n\}$ tenha contribuição não-nula de \mathbf{V}^1 (isto é, $\beta_1 \neq 0$).

Exemplo: A matriz

$$A = \begin{bmatrix} -4 & 14 & 0 \\ -5 & 13 & 0 \\ -1 & 0 & 2 \end{bmatrix},$$

tem autovalores $\lambda_1 = 6, \lambda_2 = 3, \lambda_3 = 2$. Logo, podemos aplicar o método das potências.

Seja $\mathbf{x}^{(0)} = (1 \ 1 \ 1)^T$. Então,

Cálculo de $\mathbf{y}^{(1)}, \mu^{(1)}, \mathbf{x}^{(1)}$

$$\mathbf{y}^{(1)} = A\mathbf{x}^{(0)} = \begin{bmatrix} -4 & 14 & 0 \\ -5 & 13 & 0 \\ -1 & 0 & 2 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 10 \\ 8 \\ 1 \end{bmatrix}$$

e assim,

$$\|\mathbf{y}^{(1)}\|_{\infty} = |y_1^{(1)}| = 10$$
$$p_1 = 1, \quad \mu^{(1)} = y_1^{(1)} = 10, \quad \mathbf{x}^{(1)} = \frac{\mathbf{y}^{(1)}}{y_1^{(1)}} = \frac{[10 \ 8 \ 1]^T}{10} = [1 \ 0.8 \ 0.1]^T$$

Cálculo de $\mathbf{y}^{(2)}, \mu^{(2)}, \mathbf{x}^{(2)}$

$$\mathbf{y}^{(2)} = A\mathbf{x}^{(1)} = \begin{bmatrix} -4 & 14 & 0 \\ -5 & 13 & 0 \\ -1 & 0 & 2 \end{bmatrix} \begin{bmatrix} 1 \\ 0.8 \\ 0.1 \end{bmatrix} = \begin{bmatrix} 7.2 \\ 5.4 \\ -0.8 \end{bmatrix}$$

e assim,

$$\|\mathbf{y}^{(2)}\|_{\infty} = |y_1^{(2)}| = 7.2$$
$$p_2 = 1, \quad \mu^{(2)} = y_{p_2}^{(2)} = 7.2, \quad \mathbf{x}^{(2)} = \frac{\mathbf{y}^{(1)}}{y_2^{(1)}} = \frac{[7.2 \ 5.4 \ 0.1]^T}{7.2} = [1 \ 0.75 \ -0.11111111]^T$$

Continuando dessa maneira, obtemos:

$$\begin{aligned} \mu^{(3)} &= 6.5, \text{hspace} * 1.0\text{cm} \mathbf{x}^{(3)} = [1 \ 0.730769, \ -0.188803]^T \\ \mu^{(4)} &= 6.230769, \text{hspace} * 1.0\text{cm} \mathbf{x}^{(4)} = [1 \ 0.722200 \ -0.220850]^T \\ \mu^{(5)} &= 6.111000, \text{hspace} * 1.0\text{cm} \mathbf{x}^{(5)} = [1 \ 0.718182 \ -0.235915]^T \\ \mu^{(6)} &= 6.054546, \text{hspace} * 1.0\text{cm} \mathbf{x}^{(6)} = [1 \ 0.716216 \ -0.243095]^T \\ \mu^{(7)} &= 6.027027, \text{hspace} * 1.0\text{cm} \mathbf{x}^{(7)} = [1 \ 0.715247 \ -0.246588]^T \\ \mu^{(8)} &= 6.013453, \text{hspace} * 1.0\text{cm} \mathbf{x}^{(8)} = [1 \ 0.714765 \ -0.248306]^T \\ \mu^{(9)} &= 6.006711, \text{hspace} * 1.0\text{cm} \mathbf{x}^{(9)} = [1 \ 0.714525 \ -0.249157]^T \\ &:\text{hspace} * 1.0\text{cm}:\text{hspace} * 1.0\text{cm}: \\ &:\text{hspace} * 1.0\text{cm}:\text{hspace} * 1.0\text{cm}: \\ &:\text{hspace} * 1.0\text{cm}:\text{hspace} * 1.0\text{cm}: \\ \mu^{(12)} &= 6.000837, \text{hspace} * 1.0\text{cm} \mathbf{x}^{(12)} = [1 \ 0.714316 \ -0.249895]^T \end{aligned}$$

Desses valores, vemos que a sequência de escalares $\mu^{(m)} \rightarrow 6.00000$ e a sequência de vetores $\mathbf{x}^{(m)} \rightarrow [1.0 \ 0.714316 \ -0.25]^T$.

Convergência do met. da potências: A taxa de convergência do método das potências é $O(|\lambda_2/\lambda_1|^m)$.

Deficiencia do metodo das potencias: se $\lambda_2/\lambda_1 \approx 1$ (ex. $\lambda_2/\lambda_1 = 0.9$) esse metodo pode requerer muitas iteracoes para convergir com uma precisão ϵ .

METODO DAS POTENCIAS SIMETRICO

Quando A é simétrica, uma variação na escolha dos vetores $\mathbf{x}^{(m)}$, $\mathbf{y}^{(m)}$ e $\mu^{(m)}$ pode ser feita de modo a aumentar a taxa de convergencia da sequencia $\mu^{(m)}$ para o auto-valor λ_1 . A taxa de convergencia do metodo modificado (p/ matrizes simetricas) é $O(|\lambda_2/\lambda_1|)^{2m}$. O algoritmo pode ser descrito como segue.

Algoritmo MÉTODO DAS POTÊNCIAS PARA MATRIZES SIMÉTRICAS

Calcula o autovalor dominante e o autovetor associado de uma matriz simetrica.

Parâmetros de ENTRADA: n , matriz $A_{n \times n}$, vetor não-nulo \mathbf{x} , tolerancia TOL , numero maximo de iteracoes $itmax$.

Parâmetros de SAIDA: Autovalor aproximado μ ; autovetor aproximado \mathbf{x} ou uma mensagem que o numero maximo de iteracoes foi excedido.

1. $k = 1$
 $\mathbf{x} = \mathbf{x}/\|\mathbf{x}\|_2$;
2. Enquanto $((k \leq itmax) \text{ AND } (ERR < TOL))$ faça
 - $\mathbf{y} = A\mathbf{x}$;
 - $\mu = \mathbf{x}^T \mathbf{y}$;
 - Se $(\|\mathbf{y}\|_2 = 0)$ Então
 - Escreva(A tem autovalor 0);
 - Faça $\mathbf{x} = \mathbf{y}$;
 - Escreva(Selecione novo vetor \mathbf{x} e reinicie);
 - Faça $ERR = 0$;
 - Fim-se
 - $ERR = \|\mathbf{x} - \frac{\mathbf{y}}{\|\mathbf{y}\|_2}\|_2$;
 - $\mathbf{x} = \frac{\mathbf{y}}{\|\mathbf{y}\|_2}$;
 - $k = k + 1$;
- Fim-enquanto
- Se $(ERR < TOL)$ Então
 - Escreva('Procedimento bem sucedido');
 - Escreva('Autovalor $\lambda_1 =$ ', μ);
 - Escreva('Autovetor $\mathbf{x} =$ ', \mathbf{x});
- Senão
 - Escreva('Procedimento nao foi bem-sucedido') ;
 - Escreva('Numero max. de iteracoes atingido - ITMAX = ', k);
- Fim-se

Exemplo: A matriz

$$A = \begin{bmatrix} 5 & 3 & 3 \\ 3 & 6 & 3 \\ 3 & 3 & 7 \end{bmatrix},$$

tem autovalores $\lambda_1 = 12.07377$, $\lambda_2 = 3.539929$, $\lambda_3 = 2.38693$. Logo, podemos aplicar o método das potências.

Seja $\mathbf{x}^{(0)} = (1 \ 1 \ 1)^T$. Então,

$$\text{norm}X = 1.732051$$

$$x = [0.577350 \ 0.577350 \ 0.577350]^T$$

Cálculo de $\mathbf{y}^{(1)}$, $\mu^{(1)}$, $\mathbf{x}^{(1)}$

$$\mathbf{y}^{(1)} = A\mathbf{x}^{(0)} = \begin{bmatrix} 5 & 3 & 3 \\ 3 & 6 & 3 \\ 3 & 3 & 7 \end{bmatrix} \begin{bmatrix} 0.577350 \\ 0.577350 \\ 0.577350 \end{bmatrix} = \begin{bmatrix} 6.3508529 \\ 6.9282032 \\ 7.505553 \end{bmatrix}$$

$$\mu = 12.000000000000$$

$$\text{norm}Y = 12.027745701779146$$

$$x = [0.5280168968 \ 0.576018432884 \ 0.6240199689]^T$$

Continuando dessa maneira, obtemos:

$$\begin{aligned} \mu^{(2)} &= 12.0691244, & \mathbf{x}^{(2)} &= [0.516965018 \ 0.572638174 \ 0.636264638]^T \\ \mu^{(3)} &= 12.07343918, & \mathbf{x}^{(3)} &= [0.514474111 \ 0.5711255 \ 0.63963426]^T \\ \mu^{(5)} &= 12.0737447, & \mathbf{x}^{(5)} &= [0.5138956817 \ 0.570582974 \ 0.6405827793]^T \end{aligned}$$