

Autovalores e Autovetores

Prof. Afonso Paiva

Departamento de Matemática Aplicada e Estatística
Instituto de Ciências Matemáticas e de Computação
USP – São Carlos

Métodos Numéricos e Computacionais I – SME0305

Definição (autovalor e autovetor)

Seja \mathbf{A} uma matriz em $\mathcal{M}(n, n)$. Um escalar $\lambda \in \mathbb{C}$ é um **autovalor** de \mathbf{A} se existir um vetor $\mathbf{v} \in \mathbb{R}^n$, com $\mathbf{v} \neq \bar{\mathbf{0}}$, tal que:

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v}.$$

O vetor \mathbf{v} é chamado de **autovetor** associado a λ .

Definição (autovalor e autovetor)

Seja \mathbf{A} uma matriz em $\mathcal{M}(n, n)$. Um escalar $\lambda \in \mathbb{C}$ é um **autovalor** de \mathbf{A} se existir um vetor $\mathbf{v} \in \mathbb{R}^n$, com $\mathbf{v} \neq \bar{\mathbf{0}}$, tal que:

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v}.$$

O vetor \mathbf{v} é chamado de **autovetor** associado a λ .

Como calcular λ ?

Definição (autovalor e autovetor)

Seja \mathbf{A} uma matriz em $\mathcal{M}(n, n)$. Um escalar $\lambda \in \mathbb{C}$ é um **autovalor** de \mathbf{A} se existir um vetor $\mathbf{v} \in \mathbb{R}^n$, com $\mathbf{v} \neq \bar{\mathbf{0}}$, tal que:

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v}.$$

O vetor \mathbf{v} é chamado de **autovetor** associado a λ .

Como calcular λ ? Através das raízes do **polinômio característico** $P(\lambda)$!

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v} = \lambda\mathbf{I}\mathbf{v} \Leftrightarrow (\mathbf{A} - \lambda\mathbf{I})\mathbf{v} = \bar{\mathbf{0}} \Leftrightarrow \underbrace{\det(\mathbf{A} - \lambda\mathbf{I})}_{P(\lambda)} = 0$$

Definição (autovalor e autovetor)

Seja \mathbf{A} uma matriz em $\mathcal{M}(n, n)$. Um escalar $\lambda \in \mathbb{C}$ é um **autovalor** de \mathbf{A} se existir um vetor $\mathbf{v} \in \mathbb{R}^n$, com $\mathbf{v} \neq \bar{\mathbf{0}}$, tal que:

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v}.$$

O vetor \mathbf{v} é chamado de **autovetor** associado a λ .

Como calcular λ ? Através das raízes do **polinômio característico** $P(\lambda)$!

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v} = \lambda\mathbf{I}\mathbf{v} \Leftrightarrow (\mathbf{A} - \lambda\mathbf{I})\mathbf{v} = \bar{\mathbf{0}} \Leftrightarrow \underbrace{\det(\mathbf{A} - \lambda\mathbf{I})}_{P(\lambda)} = 0$$

Definição (espectro)

O **espectro** de $\mathbf{A} \in \mathcal{M}(n, n)$ é o conjunto formado pelo seus autovalores, isto é, $\Lambda(\mathbf{A}) = \{\lambda_1, \lambda_2, \dots, \lambda_n\}$.

Matriz Ortogonal

Definição (matriz ortogonal)

Uma matriz $\mathbf{A} \in \mathcal{M}(n, n)$ cujas n colunas (e linhas) formam um conjunto ortonormal é dita **ortogonal**.

Matriz Ortogonal

Definição (matriz ortogonal)

Uma matriz $\mathbf{A} \in \mathcal{M}(n, n)$ cujas n colunas (e linhas) formam um conjunto ortonormal é dita **ortogonal**.

Proposição

Se $\mathbf{A} \in \mathcal{M}(n, n)$ é ortogonal então:

- 1 $\mathbf{A}^T = \mathbf{A}^{-1}$;
- 2 $\|\mathbf{A}\mathbf{v}\|_2 = \|\mathbf{v}\|_2, \forall \mathbf{v} \in \mathbb{R}^n$;
- 3 Os autovalores de \mathbf{A} são ± 1 ;
- 4 $\det(\mathbf{A}) = \pm 1$.

Matriz Ortogonal

1 $\mathbf{A}^T = \mathbf{A}^{-1}$.

Matriz Ortogonal

1 $\mathbf{A}^\top = \mathbf{A}^{-1}$. Seja \mathbf{a}_j a j -ésima coluna de \mathbf{A} . Logo,

$$\mathbf{A}^\top \mathbf{A} = \begin{bmatrix} \mathbf{a}_1^\top \\ \mathbf{a}_2^\top \\ \vdots \\ \mathbf{a}_n^\top \end{bmatrix} \left[\mathbf{a}_1 \mid \mathbf{a}_2 \mid \cdots \mid \mathbf{a}_n \right] = \begin{bmatrix} \mathbf{a}_1 \cdot \mathbf{a}_1 & \mathbf{a}_1 \cdot \mathbf{a}_2 & \cdots & \mathbf{a}_1 \cdot \mathbf{a}_n \\ \mathbf{a}_1 \cdot \mathbf{a}_2 & \mathbf{a}_2 \cdot \mathbf{a}_2 & \cdots & \mathbf{a}_2 \cdot \mathbf{a}_n \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{a}_1 \cdot \mathbf{a}_n & \mathbf{a}_2 \cdot \mathbf{a}_n & \cdots & \mathbf{a}_n \cdot \mathbf{a}_n \end{bmatrix} = \mathbf{I}$$

Matriz Ortogonal

1 $\mathbf{A}^\top = \mathbf{A}^{-1}$. Seja \mathbf{a}_j a j -ésima coluna de \mathbf{A} . Logo,

$$\mathbf{A}^\top \mathbf{A} = \begin{bmatrix} \mathbf{a}_1^\top \\ \mathbf{a}_2^\top \\ \vdots \\ \mathbf{a}_n^\top \end{bmatrix} \left[\mathbf{a}_1 \mid \mathbf{a}_2 \mid \cdots \mid \mathbf{a}_n \right] = \begin{bmatrix} \mathbf{a}_1 \cdot \mathbf{a}_1 & \mathbf{a}_1 \cdot \mathbf{a}_2 & \cdots & \mathbf{a}_1 \cdot \mathbf{a}_n \\ \mathbf{a}_1 \cdot \mathbf{a}_2 & \mathbf{a}_2 \cdot \mathbf{a}_2 & \cdots & \mathbf{a}_2 \cdot \mathbf{a}_n \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{a}_1 \cdot \mathbf{a}_n & \mathbf{a}_2 \cdot \mathbf{a}_n & \cdots & \mathbf{a}_n \cdot \mathbf{a}_n \end{bmatrix} = \mathbf{I}$$

2 $\|\mathbf{A}\mathbf{v}\|_2 = \|\mathbf{v}\|_2, \forall \mathbf{v} \in \mathbb{R}^n$

Matrizes Ortogonais

1 $\mathbf{A}^\top = \mathbf{A}^{-1}$. Seja \mathbf{a}_j a j -ésima coluna de \mathbf{A} . Logo,

$$\mathbf{A}^\top \mathbf{A} = \begin{bmatrix} \mathbf{a}_1^\top \\ \mathbf{a}_2^\top \\ \vdots \\ \mathbf{a}_n^\top \end{bmatrix} \left[\mathbf{a}_1 \mid \mathbf{a}_2 \mid \cdots \mid \mathbf{a}_n \right] = \begin{bmatrix} \mathbf{a}_1 \cdot \mathbf{a}_1 & \mathbf{a}_1 \cdot \mathbf{a}_2 & \cdots & \mathbf{a}_1 \cdot \mathbf{a}_n \\ \mathbf{a}_1 \cdot \mathbf{a}_2 & \mathbf{a}_2 \cdot \mathbf{a}_2 & \cdots & \mathbf{a}_2 \cdot \mathbf{a}_n \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{a}_1 \cdot \mathbf{a}_n & \mathbf{a}_2 \cdot \mathbf{a}_n & \cdots & \mathbf{a}_n \cdot \mathbf{a}_n \end{bmatrix} = \mathbf{I}$$

2 $\|\mathbf{A}\mathbf{v}\|_2 = \|\mathbf{v}\|_2, \forall \mathbf{v} \in \mathbb{R}^n$

$$\|\mathbf{A}\mathbf{v}\|_2^2 = \mathbf{A}\mathbf{v} \cdot \mathbf{A}\mathbf{v} = \mathbf{v} \cdot \mathbf{A}^\top \mathbf{A}\mathbf{v} = \mathbf{v} \cdot \mathbf{v} = \|\mathbf{v}\|_2^2$$

Matríz Ortogonal

1 $\mathbf{A}^\top = \mathbf{A}^{-1}$. Seja \mathbf{a}_j a j -ésima coluna de \mathbf{A} . Logo,

$$\mathbf{A}^\top \mathbf{A} = \begin{bmatrix} \mathbf{a}_1^\top \\ \mathbf{a}_2^\top \\ \vdots \\ \mathbf{a}_n^\top \end{bmatrix} \left[\mathbf{a}_1 \mid \mathbf{a}_2 \mid \cdots \mid \mathbf{a}_n \right] = \begin{bmatrix} \mathbf{a}_1 \cdot \mathbf{a}_1 & \mathbf{a}_1 \cdot \mathbf{a}_2 & \cdots & \mathbf{a}_1 \cdot \mathbf{a}_n \\ \mathbf{a}_1 \cdot \mathbf{a}_2 & \mathbf{a}_2 \cdot \mathbf{a}_2 & \cdots & \mathbf{a}_2 \cdot \mathbf{a}_n \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{a}_1 \cdot \mathbf{a}_n & \mathbf{a}_2 \cdot \mathbf{a}_n & \cdots & \mathbf{a}_n \cdot \mathbf{a}_n \end{bmatrix} = \mathbf{I}$$

2 $\|\mathbf{A}\mathbf{v}\|_2 = \|\mathbf{v}\|_2, \forall \mathbf{v} \in \mathbb{R}^n$

$$\|\mathbf{A}\mathbf{v}\|_2^2 = \mathbf{A}\mathbf{v} \cdot \mathbf{A}\mathbf{v} = \mathbf{v} \cdot \mathbf{A}^\top \mathbf{A}\mathbf{v} = \mathbf{v} \cdot \mathbf{v} = \|\mathbf{v}\|_2^2$$

3 $\mathbf{A}\mathbf{v} = \lambda\mathbf{v}$

Matriz Ortogonal

1 $\mathbf{A}^\top = \mathbf{A}^{-1}$. Seja \mathbf{a}_j a j -ésima coluna de \mathbf{A} . Logo,

$$\mathbf{A}^\top \mathbf{A} = \begin{bmatrix} \mathbf{a}_1^\top \\ \mathbf{a}_2^\top \\ \vdots \\ \mathbf{a}_n^\top \end{bmatrix} \left[\mathbf{a}_1 \mid \mathbf{a}_2 \mid \cdots \mid \mathbf{a}_n \right] = \begin{bmatrix} \mathbf{a}_1 \cdot \mathbf{a}_1 & \mathbf{a}_1 \cdot \mathbf{a}_2 & \cdots & \mathbf{a}_1 \cdot \mathbf{a}_n \\ \mathbf{a}_1 \cdot \mathbf{a}_2 & \mathbf{a}_2 \cdot \mathbf{a}_2 & \cdots & \mathbf{a}_2 \cdot \mathbf{a}_n \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{a}_1 \cdot \mathbf{a}_n & \mathbf{a}_2 \cdot \mathbf{a}_n & \cdots & \mathbf{a}_n \cdot \mathbf{a}_n \end{bmatrix} = \mathbf{I}$$

2 $\|\mathbf{A}\mathbf{v}\|_2 = \|\mathbf{v}\|_2, \forall \mathbf{v} \in \mathbb{R}^n$

$$\|\mathbf{A}\mathbf{v}\|_2^2 = \mathbf{A}\mathbf{v} \cdot \mathbf{A}\mathbf{v} = \mathbf{v} \cdot \mathbf{A}^\top \mathbf{A}\mathbf{v} = \mathbf{v} \cdot \mathbf{v} = \|\mathbf{v}\|_2^2$$

3 $\mathbf{A}\mathbf{v} = \lambda\mathbf{v}$

$$\|\mathbf{v}\|_2 = \|\mathbf{A}\mathbf{v}\|_2 = \|\lambda\mathbf{v}\|_2 = |\lambda| \|\mathbf{v}\|_2 \Rightarrow \lambda = \pm 1$$

Matrizes Semelhantes

Definição (matrizes semelhantes)

As matrizes $\mathbf{A}, \mathbf{B} \in \mathcal{M}(n, n)$ são **semelhantes** se existir $\mathbf{P} \in \mathcal{M}(n, n)$ invertível, tal que:

$$\mathbf{B} = \mathbf{P}^{-1}\mathbf{A}\mathbf{P}.$$

Matrizes Semelhantes

Definição (matrizes semelhantes)

As matrizes $\mathbf{A}, \mathbf{B} \in \mathcal{M}(n, n)$ são **semelhantes** se existir $\mathbf{P} \in \mathcal{M}(n, n)$ invertível, tal que:

$$\mathbf{B} = \mathbf{P}^{-1}\mathbf{A}\mathbf{P}.$$

Proposição

Se \mathbf{A} e \mathbf{B} são semelhantes então elas possuem os mesmos autovalores.

Decomposição Espectral

Toda matriz simétrica $\mathbf{A} \in \mathcal{M}(n, n)$ pode ser **diagonalizada** por uma matriz **ortogonal** $\mathbf{V} \in \mathcal{M}(n, n)$, isto é:

$$\mathbf{D} = \mathbf{V}^\top \mathbf{A} \mathbf{V}$$

onde \mathbf{D} é uma matriz diagonal formada pelos autovalores (todos reais) de \mathbf{A} e as colunas de \mathbf{V} são os seus respectivos autovetores. Logo,

$$\mathbf{A} = \mathbf{V} \mathbf{D} \mathbf{V}^\top,$$

Projeção Ortogonal


$$\text{pr}_{\mathbf{v}}(\mathbf{u}) = \frac{\mathbf{u} \cdot \mathbf{v}}{\mathbf{v} \cdot \mathbf{v}} \mathbf{v} = \frac{\mathbf{u} \cdot \mathbf{v}}{\|\mathbf{v}\|_2^2} \mathbf{v}$$

$$\|\mathbf{v}\|_2 = 1 \Rightarrow \text{pr}_{\mathbf{v}} = \mathbf{v}\mathbf{v}^T$$

Projeção no Complemento Ortogonal

$$\text{pr}_{\perp\mathbf{v}}(\mathbf{u}) = \mathbf{u} - \text{pr}_{\mathbf{v}}(\mathbf{u})$$

$$\|\mathbf{v}\|_2 = 1 \Rightarrow \text{pr}_{\perp\mathbf{v}} = \mathbf{I} - \mathbf{v}\mathbf{v}^T$$



Processo de Ortogonalização de Gram-Schmidt

Entrada: dado um conjunto L.I. $\{\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n\} \subset \mathbb{R}^m$, com $m \geq n$.

Saída: um conjunto **ortornormal** $\{\mathbf{q}_1, \mathbf{q}_2, \dots, \mathbf{q}_n\}$.

Processo de Ortogonalização de Gram-Schmidt

Entrada: dado um conjunto L.I. $\{\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n\} \subset \mathbb{R}^m$, com $m \geq n$.

Saída: um conjunto **ortornormal** $\{\mathbf{q}_1, \mathbf{q}_2, \dots, \mathbf{q}_n\}$.

- $\mathbf{v}_1 = \mathbf{a}_1$
- $\mathbf{q}_1 = \mathbf{v}_1 / \|\mathbf{v}_1\|_2$




Processo de Ortogonalização de Gram-Schmidt

Entrada: dado um conjunto L.I. $\{\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n\} \subset \mathbb{R}^m$, com $m \geq n$.

Saída: um conjunto **ortornormal** $\{\mathbf{q}_1, \mathbf{q}_2, \dots, \mathbf{q}_n\}$.

- $\mathbf{v}_1 = \mathbf{a}_1$
- $\mathbf{q}_1 = \mathbf{v}_1 / \|\mathbf{v}_1\|_2$
- $\mathbf{v}_2 = \mathbf{a}_2 - \underbrace{(\mathbf{q}_1 \cdot \mathbf{a}_2)}_{\text{pr}_{\mathbf{q}_1}(\mathbf{a}_2)} \mathbf{q}_1$
- $\mathbf{q}_2 = \mathbf{v}_2 / \|\mathbf{v}_2\|_2$



Processo de Ortogonalização de Gram-Schmidt

Entrada: dado um conjunto L.I. $\{\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_n\} \subset \mathbb{R}^m$, com $m \geq n$.

Saída: um conjunto **ortornormal** $\{\mathbf{q}_1, \mathbf{q}_2, \dots, \mathbf{q}_n\}$.

$$\blacksquare \mathbf{v}_1 = \mathbf{a}_1$$


$$\blacksquare \mathbf{q}_1 = \mathbf{v}_1 / \|\mathbf{v}_1\|_2$$

$$\blacksquare \mathbf{v}_2 = \mathbf{a}_2 - \underbrace{(\mathbf{q}_1 \cdot \mathbf{a}_2)}_{\text{pr}_{\mathbf{q}_1}(\mathbf{a}_2)} \mathbf{q}_1$$

$$\blacksquare \mathbf{q}_2 = \mathbf{v}_2 / \|\mathbf{v}_2\|_2$$

$$\blacksquare \mathbf{v}_3 = \mathbf{a}_3 - \left[\underbrace{(\mathbf{q}_1 \cdot \mathbf{a}_3)}_{\text{pr}_{\mathbf{q}_1}(\mathbf{a}_3)} \mathbf{q}_1 + \underbrace{(\mathbf{q}_2 \cdot \mathbf{a}_3)}_{\text{pr}_{\mathbf{q}_2}(\mathbf{a}_3)} \mathbf{q}_2 \right]$$

$$\blacksquare \mathbf{q}_3 = \mathbf{v}_3 / \|\mathbf{v}_3\|_2$$



Processo de Ortogonalização de Gram-Schmidt

Termo Geral

Para obter \mathbf{v}_j **ortogonal** a $\mathbf{q}_1, \dots, \mathbf{q}_{j-1}$:

$$\mathbf{v}_j = \mathbf{a}_j - \sum_{i=1}^{j-1} (\mathbf{q}_i \cdot \mathbf{a}_j) \mathbf{q}_i.$$

Depois **normalizar** \mathbf{v}_j :

$$\mathbf{q}_j = \frac{\mathbf{v}_j}{\|\mathbf{v}_j\|_2}.$$

Decomposição QR

Completa

A **Decomposição QR completa** de $\mathbf{A} \in \mathcal{M}(m, n)$ é dada por:

$$\mathbf{A} = \mathbf{Q} \cdot \mathbf{R},$$

onde $\mathbf{Q} \in \mathcal{M}(m, m)$ é **ortogonal** e $\mathbf{R} \in \mathcal{M}(m, n)$ é **triangular superior**.


Decomposição QR

Completa

A **Decomposição QR completa** de $\mathbf{A} \in \mathcal{M}(m, n)$ é dada por:

$$\mathbf{A} = \mathbf{Q} \cdot \mathbf{R},$$

onde $\mathbf{Q} \in \mathcal{M}(m, m)$ é **ortogonal** e $\mathbf{R} \in \mathcal{M}(m, n)$ é **triangular superior**.



Decomposição QR

Reduzida

Seja $\mathbf{A} \in \mathcal{M}(m, n)$, com $m \geq n$. Uma representação mais compacta é dada pela **Decomposição QR reduzida** de \mathbf{A} :

$$\mathbf{A} = \hat{\mathbf{Q}} \cdot \hat{\mathbf{R}},$$

onde $\hat{\mathbf{Q}} \in \mathcal{M}(m, n)$ e $\hat{\mathbf{R}} \in \mathcal{M}(n, n)$.


Decomposição QR

Reduzida

Seja $\mathbf{A} \in \mathcal{M}(m, n)$, com $m \geq n$. Uma representação mais compacta é dada pela **Decomposição QR reduzida** de \mathbf{A} :

$$\mathbf{A} = \hat{\mathbf{Q}} \cdot \hat{\mathbf{R}},$$

onde $\hat{\mathbf{Q}} \in \mathcal{M}(m, n)$ e $\hat{\mathbf{R}} \in \mathcal{M}(n, n)$.



Decomposição QR

Reduzida

$$\underbrace{\left[\mathbf{a}_1 \mid \mathbf{a}_2 \mid \cdots \mid \mathbf{a}_n \right]}_{\mathbf{A}} = \underbrace{\left[\mathbf{q}_1 \mid \mathbf{q}_2 \mid \cdots \mid \mathbf{q}_n \right]}_{\hat{\mathbf{Q}}} \underbrace{\begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ & r_{22} & \cdots & r_{2n} \\ & & \ddots & \vdots \\ & & & r_{nn} \end{bmatrix}}_{\hat{\mathbf{R}}}$$

- $\mathbf{a}_1 = r_{11} \mathbf{q}_1$
- $\mathbf{a}_2 = r_{12} \mathbf{q}_1 + r_{22} \mathbf{q}_2$
- \vdots
- $\mathbf{a}_n = r_{1n} \mathbf{q}_1 + r_{2n} \mathbf{q}_2 + \cdots + r_{nn} \mathbf{q}_n$

Precisamos determinar r_{ij} e os vetores coluna \mathbf{q}_j .

Decomposição QR

Reduzida

Usando o Processo de Gram-Schmidt nos vetores coluna $\{\mathbf{a}_1, \dots, \mathbf{a}_n\}$, obtemos $\mathbf{A} = \hat{\mathbf{Q}} \cdot \hat{\mathbf{R}}$ com

Decomposição QR

Reduzida

Usando o Processo de Gram-Schmidt nos vetores coluna $\{\mathbf{a}_1, \dots, \mathbf{a}_n\}$, obtemos $\mathbf{A} = \hat{\mathbf{Q}} \cdot \hat{\mathbf{R}}$ com

$$r_{ij} = \mathbf{q}_i \cdot \mathbf{a}_j \quad (i \neq j)$$

$$|r_{jj}| = \|\mathbf{v}_j\|_2$$

Decomposição QR

Reduzida

Usando o Processo de Gram-Schmidt nos vetores coluna $\{\mathbf{a}_1, \dots, \mathbf{a}_n\}$, obtemos $\mathbf{A} = \hat{\mathbf{Q}} \cdot \hat{\mathbf{R}}$ com

$$r_{ij} = \mathbf{q}_i \cdot \mathbf{a}_j \quad (i \neq j)$$

$$|r_{jj}| = \|\mathbf{v}_j\|_2$$

Teorema

Toda matriz $\mathbf{A} \in \mathcal{M}(m, n)$ (com $m \geq n$) possui Decomposição QR completa e reduzida. Além disso, se \mathbf{A} tem posto completo então $\mathbf{A} = \hat{\mathbf{Q}} \cdot \hat{\mathbf{R}}$ é única com $r_{jj} > 0$.

MATLAB – Decomposição QR

Gram-Schmidt Clássico

```
function [Q,R] = clgs(A)

[m,n] = size(A);
Q = zeros(m,n);
R = zeros(n,n);

for j=1:n
    V = A(:,j);
    for i=1:j-1
        R(i,j) = Q(:,i)'*A(:,j);
        V = V - R(i,j)*Q(:,i);
    end
    R(j,j) = norm(V);
    Q(:,j) = V/R(j,j);
end
```

Decomposição QR

Gram-Schmidt Clássico

Exemplo 1

Calcule a Decomposição QR de $\mathbf{A} = \begin{bmatrix} 3 & 1 \\ 4 & -1 \end{bmatrix}$.

Decomposição QR

Gram-Schmidt Clássico

Exemplo 1

Calcule a Decomposição QR de $\mathbf{A} = \begin{bmatrix} 3 & 1 \\ 4 & -1 \end{bmatrix}$.

Solução: os vetores colunas de \mathbf{A} são $\mathbf{a}_1 = [3, 4]^\top$ e $\mathbf{a}_2 = [1, -1]^\top$. Logo,

Decomposição QR

Gram-Schmidt Clássico

Exemplo 1

Calcule a Decomposição QR de $\mathbf{A} = \begin{bmatrix} 3 & 1 \\ 4 & -1 \end{bmatrix}$.

Solução: os vetores colunas de \mathbf{A} são $\mathbf{a}_1 = [3, 4]^\top$ e $\mathbf{a}_2 = [1, -1]^\top$. Logo,

$$r_{11} = \|\mathbf{v}_1\|_2 = \|\mathbf{a}_1\|_2 = \sqrt{3^2 + 4^2} = 5 \Rightarrow \mathbf{q}_1 = \frac{\mathbf{v}_1}{\|\mathbf{v}_1\|_2} = [3/5, 4/5]^\top$$

Decomposição QR

Gram-Schmidt Clássico

Exemplo 1

Calcule a Decomposição QR de $\mathbf{A} = \begin{bmatrix} 3 & 1 \\ 4 & -1 \end{bmatrix}$.

Solução: os vetores colunas de \mathbf{A} são $\mathbf{a}_1 = [3, 4]^\top$ e $\mathbf{a}_2 = [1, -1]^\top$. Logo,

$$r_{11} = \|\mathbf{v}_1\|_2 = \|\mathbf{a}_1\|_2 = \sqrt{3^2 + 4^2} = 5 \Rightarrow \mathbf{q}_1 = \frac{\mathbf{v}_1}{\|\mathbf{v}_1\|_2} = [3/5, 4/5]^\top$$

$$\mathbf{v}_2 = \mathbf{a}_2 - \underbrace{(\mathbf{q}_1 \cdot \mathbf{a}_2)}_{r_{12}} \mathbf{q}_1 = [1, -1]^\top - (-1/5) [3/5, 4/5]^\top = [28/25, -21/25]^\top$$

Decomposição QR

Gram-Schmidt Clássico

Exemplo 1

Calcule a Decomposição QR de $\mathbf{A} = \begin{bmatrix} 3 & 1 \\ 4 & -1 \end{bmatrix}$.

Solução: os vetores colunas de \mathbf{A} são $\mathbf{a}_1 = [3, 4]^\top$ e $\mathbf{a}_2 = [1, -1]^\top$. Logo,

$$r_{11} = \|\mathbf{v}_1\|_2 = \|\mathbf{a}_1\|_2 = \sqrt{3^2 + 4^2} = 5 \Rightarrow \mathbf{q}_1 = \frac{\mathbf{v}_1}{\|\mathbf{v}_1\|_2} = [3/5, 4/5]^\top$$

$$\mathbf{v}_2 = \mathbf{a}_2 - \underbrace{(\mathbf{q}_1 \cdot \mathbf{a}_2)}_{r_{12}} \mathbf{q}_1 = [1, -1]^\top - (-1/5) [3/5, 4/5]^\top = [28/25, -21/25]^\top$$

$$r_{22} = \|\mathbf{v}_2\|_2 = 7/5 \Rightarrow \mathbf{q}_2 = \frac{\mathbf{v}_2}{\|\mathbf{v}_2\|_2} = [4/5, -3/5]^\top$$

Decomposição QR

Gram-Schmidt Clássico

Exemplo 1

Calcule a Decomposição QR de $\mathbf{A} = \begin{bmatrix} 3 & 1 \\ 4 & -1 \end{bmatrix}$.

Solução: os vetores colunas de \mathbf{A} são $\mathbf{a}_1 = [3, 4]^\top$ e $\mathbf{a}_2 = [1, -1]^\top$. Logo,

$$r_{11} = \|\mathbf{v}_1\|_2 = \|\mathbf{a}_1\|_2 = \sqrt{3^2 + 4^2} = 5 \Rightarrow \mathbf{q}_1 = \frac{\mathbf{v}_1}{\|\mathbf{v}_1\|_2} = [3/5, 4/5]^\top$$

$$\mathbf{v}_2 = \mathbf{a}_2 - \underbrace{(\mathbf{q}_1 \cdot \mathbf{a}_2)}_{r_{12}} \mathbf{q}_1 = [1, -1]^\top - (-1/5) [3/5, 4/5]^\top = [28/25, -21/25]^\top$$

$$r_{22} = \|\mathbf{v}_2\|_2 = 7/5 \Rightarrow \mathbf{q}_2 = \frac{\mathbf{v}_2}{\|\mathbf{v}_2\|_2} = [4/5, -3/5]^\top$$

$$\mathbf{Q} = \begin{bmatrix} 3/5 & 4/5 \\ 4/5 & -3/5 \end{bmatrix} \quad \mathbf{R} = \begin{bmatrix} 5 & -1/5 \\ 0 & 7/5 \end{bmatrix}$$

Decomposição QR

Gram-Schmidt Clássico

Exemplo 2

Usando o MATLAB, calcule a Decomposição QR de

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

Verifique o erro da decomposição $\|\mathbf{A} - \mathbf{QR}\|_F$ e o erro de ortogonalidade $\|\mathbf{I}_3 - \mathbf{Q}^\top \mathbf{Q}\|_F$.

Decomposição QR

Gram-Schmidt Clássico

Exemplo 3

Refaça o exemplo anterior com

$$\mathbf{A} = \begin{bmatrix} 1 & 1 & 1 \\ \varepsilon & 0 & 0 \\ 0 & \varepsilon & 0 \\ 0 & 0 & \varepsilon \end{bmatrix} .$$

Decomposição QR

Gram-Schmidt Clássico

Exemplo 3

Refaça o exemplo anterior com

$$\mathbf{A} = \begin{bmatrix} 1 & 1 & 1 \\ \varepsilon & 0 & 0 \\ 0 & \varepsilon & 0 \\ 0 & 0 & \varepsilon \end{bmatrix} .$$

Gram-Schmidt clássico é numericamente instável!!!


Decomposição QR

Gram-Schmidt Modificado

- pequenas modificações no Gram-Schmidt clássico;
- numericamente estável (menos sensível a erros de arredondamento);
- $\text{pr}_{\perp \mathbf{q}_i}$ é aplicado a todos \mathbf{v}_j assim que \mathbf{q}_i é determinado.


Decomposição QR

Gram-Schmidt Modificado




Decomposição QR

Gram-Schmidt Modificado



Decomposição QR

Gram-Schmidt Modificado



Decomposição QR

Gram-Schmidt Modificado

Clássico

- $\mathbf{v}_j \leftarrow \mathbf{a}_j$
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_1 \cdot \mathbf{a}_j) \mathbf{q}_1$
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_2 \cdot \mathbf{a}_j) \mathbf{q}_2$
- \vdots
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_{j-1} \cdot \mathbf{a}_j) \mathbf{q}_{j-1}$
- $\mathbf{q}_j \leftarrow \mathbf{v}_j / \|\mathbf{v}_j\|_2$

Modificado

- $\mathbf{v}_j \leftarrow \mathbf{a}_j$
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_1 \cdot \mathbf{v}_j) \mathbf{q}_1$
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_2 \cdot \mathbf{v}_j) \mathbf{q}_2$
- \vdots
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_{j-1} \cdot \mathbf{v}_j) \mathbf{q}_{j-1}$
- $\mathbf{q}_j \leftarrow \mathbf{v}_j / \|\mathbf{v}_j\|_2$

Decomposição QR

Gram-Schmidt Modificado

Clássico

- $\mathbf{v}_j \leftarrow \mathbf{a}_j$
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_1 \cdot \mathbf{a}_j) \mathbf{q}_1$
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_2 \cdot \mathbf{a}_j) \mathbf{q}_2$
- \vdots
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_{j-1} \cdot \mathbf{a}_j) \mathbf{q}_{j-1}$
- $\mathbf{q}_j \leftarrow \mathbf{v}_j / \|\mathbf{v}_j\|_2$

Modificado

- $\mathbf{v}_j \leftarrow \mathbf{a}_j$
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_1 \cdot \mathbf{v}_j) \mathbf{q}_1$
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_2 \cdot \mathbf{v}_j) \mathbf{q}_2$
- \vdots
- $\mathbf{v}_j \leftarrow \mathbf{v}_j - (\mathbf{q}_{j-1} \cdot \mathbf{v}_j) \mathbf{q}_{j-1}$
- $\mathbf{q}_j \leftarrow \mathbf{v}_j / \|\mathbf{v}_j\|_2$

Complexidade: $2mn^2$ flops.

MATLAB – Decomposição QR

Gram-Schmidt Modificado

```
function [Q,R] = mgs(A)

[m,n] = size(A);
V = A;
Q = zeros(m,n);
R = zeros(n,n);

for i=1:n
    R(i,i) = norm(V(:,i));
    Q(:,i) = V(:,i)/R(i,i);
    for j=i+1:n
        R(i,j) = Q(:,i)'*V(:,j);
        V(:,j) = V(:,j) - R(i,j)*Q(:,i);
    end
end
end
```

Método de Francis

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ **simétrica**, vamos usar a Decomposição QR para calcular **todos** os seus autovalores e autovetores.

Método de Francis

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ **simétrica**, vamos usar a Decomposição QR para calcular **todos** os seus autovalores e autovetores.

Processo:

- $\mathbf{A}_1 = \mathbf{A} \Rightarrow \mathbf{A}_1 = \mathbf{Q}_1 \mathbf{R}_1$

Método de Francis

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ **simétrica**, vamos usar a Decomposição QR para calcular **todos** os seus autovalores e autovetores.

Processo:

- $\mathbf{A}_1 = \mathbf{A} \Rightarrow \mathbf{A}_1 = \mathbf{Q}_1 \mathbf{R}_1$
- $\mathbf{A}_2 = \mathbf{R}_1 \mathbf{Q}_1 \Rightarrow \mathbf{A}_2 = \mathbf{Q}_2 \mathbf{R}_2$

Método de Francis

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ **simétrica**, vamos usar a Decomposição QR para calcular **todos** os seus autovalores e autovetores.

Processo:

- $\mathbf{A}_1 = \mathbf{A} \Rightarrow \mathbf{A}_1 = \mathbf{Q}_1 \mathbf{R}_1$
- $\mathbf{A}_2 = \mathbf{R}_1 \mathbf{Q}_1 \Rightarrow \mathbf{A}_2 = \mathbf{Q}_2 \mathbf{R}_2$
- $\mathbf{A}_3 = \mathbf{R}_2 \mathbf{Q}_2 \Rightarrow \mathbf{A}_3 = \mathbf{Q}_3 \mathbf{R}_3$

Método de Francis

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ **simétrica**, vamos usar a Decomposição QR para calcular **todos** os seus autovalores e autovetores.

Processo:

- $\mathbf{A}_1 = \mathbf{A} \Rightarrow \mathbf{A}_1 = \mathbf{Q}_1 \mathbf{R}_1$
- $\mathbf{A}_2 = \mathbf{R}_1 \mathbf{Q}_1 \Rightarrow \mathbf{A}_2 = \mathbf{Q}_2 \mathbf{R}_2$
- $\mathbf{A}_3 = \mathbf{R}_2 \mathbf{Q}_2 \Rightarrow \mathbf{A}_3 = \mathbf{Q}_3 \mathbf{R}_3$
- \vdots
- $\mathbf{A}_{k-1} = \mathbf{R}_{k-2} \mathbf{Q}_{k-2} \Rightarrow \mathbf{A}_{k-1} = \mathbf{Q}_{k-1} \mathbf{R}_{k-1}$
- $\mathbf{A}_k = \mathbf{R}_{k-1} \mathbf{Q}_{k-1}$

Método de Francis

Proposição

As matrizes \mathbf{A} e \mathbf{A}_k possuem os mesmos autovalores.

Método de Francis

Proposição

As matrizes \mathbf{A} e \mathbf{A}_k possuem os mesmos autovalores.

Como $\mathbf{A}_{k-1} = \mathbf{Q}_{k-1}\mathbf{R}_{k-1} \Rightarrow \mathbf{R}_{k-1} = \mathbf{Q}_{k-1}^\top \mathbf{A}_{k-1}$ e $\mathbf{A}_k = \mathbf{R}_{k-1}\mathbf{Q}_{k-1}$.

Método de Francis

Proposição

As matrizes \mathbf{A} e \mathbf{A}_k possuem os mesmos autovalores.

Como $\mathbf{A}_{k-1} = \mathbf{Q}_{k-1}\mathbf{R}_{k-1} \Rightarrow \mathbf{R}_{k-1} = \mathbf{Q}_{k-1}^\top \mathbf{A}_{k-1}$ e $\mathbf{A}_k = \mathbf{R}_{k-1}\mathbf{Q}_{k-1}$.

Temos que, $\mathbf{A}_k = \mathbf{Q}_{k-1}^\top \mathbf{A}_{k-1} \mathbf{Q}_{k-1}$.

Proposição

As matrizes \mathbf{A} e \mathbf{A}_k possuem os mesmos autovalores.

Como $\mathbf{A}_{k-1} = \mathbf{Q}_{k-1} \mathbf{R}_{k-1} \Rightarrow \mathbf{R}_{k-1} = \mathbf{Q}_{k-1}^\top \mathbf{A}_{k-1}$ e $\mathbf{A}_k = \mathbf{R}_{k-1} \mathbf{Q}_{k-1}$.

Temos que, $\mathbf{A}_k = \mathbf{Q}_{k-1}^\top \mathbf{A}_{k-1} \mathbf{Q}_{k-1}$. Assim,

$$\begin{aligned}
 \mathbf{A}_k &= \mathbf{Q}_{k-1}^\top \mathbf{A}_{k-1} \mathbf{Q}_{k-1} \\
 &= \mathbf{Q}_{k-1}^\top \mathbf{Q}_{k-2}^\top \mathbf{A}_{k-2} \mathbf{Q}_{k-2} \mathbf{Q}_{k-1} \\
 &\quad \vdots \\
 &= \mathbf{Q}_{k-1}^\top \mathbf{Q}_{k-2}^\top \cdots \mathbf{Q}_1^\top \mathbf{A}_1 \mathbf{Q}_1 \cdots \mathbf{Q}_{k-2} \mathbf{Q}_{k-1} \\
 &= (\mathbf{Q}_1 \cdots \mathbf{Q}_{k-2} \mathbf{Q}_{k-1})^\top \mathbf{A} (\mathbf{Q}_1 \cdots \mathbf{Q}_{k-2} \mathbf{Q}_{k-1})
 \end{aligned}$$

Proposição

As matrizes \mathbf{A} e \mathbf{A}_k possuem os mesmos autovalores.

Como $\mathbf{A}_{k-1} = \mathbf{Q}_{k-1} \mathbf{R}_{k-1} \Rightarrow \mathbf{R}_{k-1} = \mathbf{Q}_{k-1}^\top \mathbf{A}_{k-1}$ e $\mathbf{A}_k = \mathbf{R}_{k-1} \mathbf{Q}_{k-1}$.

Temos que, $\mathbf{A}_k = \mathbf{Q}_{k-1}^\top \mathbf{A}_{k-1} \mathbf{Q}_{k-1}$. Assim,

$$\begin{aligned} \mathbf{A}_k &= \mathbf{Q}_{k-1}^\top \mathbf{A}_{k-1} \mathbf{Q}_{k-1} \\ &= \mathbf{Q}_{k-1}^\top \mathbf{Q}_{k-2}^\top \mathbf{A}_{k-2} \mathbf{Q}_{k-2} \mathbf{Q}_{k-1} \\ &\quad \vdots \\ &= \mathbf{Q}_{k-1}^\top \mathbf{Q}_{k-2}^\top \cdots \mathbf{Q}_1^\top \mathbf{A}_1 \mathbf{Q}_1 \cdots \mathbf{Q}_{k-2} \mathbf{Q}_{k-1} \\ &= (\mathbf{Q}_1 \cdots \mathbf{Q}_{k-2} \mathbf{Q}_{k-1})^\top \mathbf{A} (\mathbf{Q}_1 \cdots \mathbf{Q}_{k-2} \mathbf{Q}_{k-1}) \end{aligned}$$

Fazendo $\mathbf{V} = \mathbf{Q}_1 \mathbf{Q}_2 \cdots \mathbf{Q}_{k-1}$ temos que \mathbf{A} e $\mathbf{A}_k = \mathbf{V}^\top \mathbf{A} \mathbf{V}$ são semelhantes.

Método de Francis

Proposição

As matrizes \mathbf{A} e \mathbf{A}_k possuem os mesmos autovalores.

Método de Francis

Proposição

As matrizes \mathbf{A} e \mathbf{A}_k possuem os mesmos autovalores.

Proposição

A sequência \mathbf{A}_k converge para uma matriz diagonal.

Método de Francis

Proposição

As matrizes \mathbf{A} e \mathbf{A}_k possuem os mesmos autovalores.

Proposição

A sequência \mathbf{A}_k converge para uma matriz diagonal.

Logo, os elementos da **diagonal de \mathbf{A}_k** fornecem uma aproximação para os **autovalores** de \mathbf{A} , enquanto que as **colunas da matriz**:

$$\mathbf{V} = \mathbf{Q}_1 \mathbf{Q}_2 \cdots \mathbf{Q}_{k-1}$$

uma aproximação dos seus respectivos **autovetores**.

Método de Francis

Critérios de Parada

Dados $\varepsilon > 0$ e $k_{max} \in \mathbb{N}$, temos:

1 $k = k_{max}$

Método de Francis

Critérios de Parada

Dados $\varepsilon > 0$ e $k_{max} \in \mathbb{N}$, temos:

1 $k = k_{max}$

2 $\max_{i < j} \{|a_{ij}|\} < \varepsilon$

Método de Francis

Crítérios de Parada

Dados $\varepsilon > 0$ e $k_{max} \in \mathbb{N}$, temos:

- 1 $k = k_{max}$
- 2 $\max_{i < j} \{|a_{ij}|\} < \varepsilon$
- 3 $off(\mathbf{A}) < \varepsilon$, com

$$off(\mathbf{A}) = \sqrt{\|\mathbf{A}\|_F^2 - \sum_{i=1}^n a_{ii}^2}$$

MATLAB – Método de Francis

```
function [V,D] = francis(A,tol)

n = size(A,1);
V = eye(n);
erro = inf;

while erro>tol
    [Q,R] = mgs(A);
    A = R*Q;
    V = V*Q;
    erro = max(max(abs(tril(A,-1)))));
end

D = diag(A);
```


Decomposição SVD

Completa

A **Decomposição SVD**¹ de $\mathbf{A} \in \mathcal{M}(m, n)$ é dada por:

$$\mathbf{A} = \mathbf{U} \cdot \mathbf{\Sigma} \cdot \mathbf{V}^T,$$

onde as matrizes $\mathbf{U} \in \mathcal{M}(m, m)$ é **ortogonal**, $\mathbf{\Sigma} \in \mathcal{M}(m, n)$ é **diagonal** e $\mathbf{V} \in \mathcal{M}(n, n)$ é **ortogonal**.

¹Do inglês, Singular Value Decomposition.


Decomposição SVD

Completa

A **Decomposição SVD**¹ de $\mathbf{A} \in \mathcal{M}(m, n)$ é dada por:

$$\mathbf{A} = \mathbf{U} \cdot \mathbf{\Sigma} \cdot \mathbf{V}^T,$$

onde as matrizes $\mathbf{U} \in \mathcal{M}(m, m)$ é **ortogonal**, $\mathbf{\Sigma} \in \mathcal{M}(m, n)$ é **diagonal** e $\mathbf{V} \in \mathcal{M}(n, n)$ é **ortogonal**.



Os coeficientes σ_i da diagonal de $\mathbf{\Sigma}$ são chamados de **valores singulares** de \mathbf{A} .

¹Do inglês, Singular Value Decomposition.

Decomposição SVD

Reduzida

Seja $\mathbf{A} \in \mathcal{M}(m, n)$, com $m \geq n$. Uma representação mais compacta da Decomposição SVD é dada na forma **reduzida**:

$$\mathbf{A} = \hat{\mathbf{U}} \cdot \hat{\mathbf{\Sigma}} \cdot \mathbf{V}^T,$$

com $\hat{\mathbf{U}} \in \mathcal{M}(m, n)$, $\hat{\mathbf{\Sigma}} \in \mathcal{M}(n, n)$ e $\mathbf{V} \in \mathcal{M}(n, n)$.


Decomposição SVD

Reduzida

Seja $\mathbf{A} \in \mathcal{M}(m, n)$, com $m \geq n$. Uma representação mais compacta da Decomposição SVD é dada na forma **reduzida**:

$$\mathbf{A} = \hat{\mathbf{U}} \cdot \hat{\mathbf{\Sigma}} \cdot \mathbf{V}^T,$$

com $\hat{\mathbf{U}} \in \mathcal{M}(m, n)$, $\hat{\mathbf{\Sigma}} \in \mathcal{M}(n, n)$ e $\mathbf{V} \in \mathcal{M}(n, n)$.



Decomposição SVD

Teorema (Decomposição SVD)

Toda matriz $\mathbf{A} \in \mathcal{M}(m, n)$ de posto $p > 0$ possui decomposição SVD, isto é, $\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T$ com $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_p > 0$.

²Algoritmos mais eficientes para SVD são encontrados no livro “Golub and Van Loan, *Matrix Computations*, 1996”.

Decomposição SVD

Teorema (Decomposição SVD)

Toda matriz $\mathbf{A} \in \mathcal{M}(m, n)$ de posto $p > 0$ possui decomposição SVD, isto é, $\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^\top$ com $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_p > 0$.

Uma forma *ingênua*² de calcular a Decomposição SVD de \mathbf{A} é utilizando o **Método de Francis** nas matrizes simétricas $\mathbf{A}^\top \mathbf{A}$ e $\mathbf{A}\mathbf{A}^\top$, pois:

- $\mathbf{A}^\top \mathbf{A} = (\mathbf{U}\mathbf{\Sigma}\mathbf{V}^\top)^\top (\mathbf{U}\mathbf{\Sigma}\mathbf{V}^\top) = \mathbf{V}\mathbf{\Sigma}(\mathbf{U}^\top \mathbf{U})\mathbf{\Sigma}\mathbf{V}^\top = \mathbf{V}\mathbf{\Sigma}^2 \mathbf{V}^\top$
- $\mathbf{A}\mathbf{A}^\top = (\mathbf{U}\mathbf{\Sigma}\mathbf{V}^\top)(\mathbf{U}\mathbf{\Sigma}\mathbf{V}^\top)^\top = \mathbf{U}\mathbf{\Sigma}(\mathbf{V}^\top \mathbf{V})\mathbf{\Sigma}\mathbf{U}^\top = \mathbf{U}\mathbf{\Sigma}^2 \mathbf{U}^\top$

²Algoritmos mais eficientes para SVD são encontrados no livro "Golub and Van Loan, *Matrix Computations*, 1996".

Decomposição SVD

Teorema (Decomposição SVD)

Toda matriz $\mathbf{A} \in \mathcal{M}(m, n)$ de posto $p > 0$ possui decomposição SVD, isto é, $\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^\top$ com $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_p > 0$.

Uma forma *ingênua*² de calcular a Decomposição SVD de \mathbf{A} é utilizando o **Método de Francis** nas matrizes simétricas $\mathbf{A}^\top \mathbf{A}$ e $\mathbf{A}\mathbf{A}^\top$, pois:

- $\mathbf{A}^\top \mathbf{A} = (\mathbf{U}\mathbf{\Sigma}\mathbf{V}^\top)^\top (\mathbf{U}\mathbf{\Sigma}\mathbf{V}^\top) = \mathbf{V}\mathbf{\Sigma}(\mathbf{U}^\top \mathbf{U})\mathbf{\Sigma}\mathbf{V}^\top = \mathbf{V}\mathbf{\Sigma}^2 \mathbf{V}^\top$
- $\mathbf{A}\mathbf{A}^\top = (\mathbf{U}\mathbf{\Sigma}\mathbf{V}^\top)(\mathbf{U}\mathbf{\Sigma}\mathbf{V}^\top)^\top = \mathbf{U}\mathbf{\Sigma}(\mathbf{V}^\top \mathbf{V})\mathbf{\Sigma}\mathbf{U}^\top = \mathbf{U}\mathbf{\Sigma}^2 \mathbf{U}^\top$

Note que a diagonal de $\mathbf{\Sigma}^2$ é formada pelo quadrado dos valores singulares de \mathbf{A} , isto é, σ_i^2 .

²Algoritmos mais eficientes para SVD são encontrados no livro "Golub and Van Loan, *Matrix Computations*, 1996".

MATLAB – Decomposição SVD

```
function [U,S,V] = my_svd(A)
```

```
tol = 1e-5;
```

```
[m,n] = size(A);
```

```
k = min(m,n);
```

```
S = zeros(m,n);
```

```
[U,~] = francis(A*A',tol);
```

```
[V,D] = francis(A'*A,tol);
```

```
S(1:k,1:k) = diag(sqrt(D));
```


Resumo em MATLAB



$[Q,R] = \text{qr}(A)$: decomposição QR completa de \mathbf{A} ;



$[V,D] = \text{eig}(A)$: calcula os autovalores e autovetores de \mathbf{A} ;

$[V,D] = \text{eigs}(A,k)$: calcula k autovalores e autovetores de \mathbf{A} ;



$[U,S,V] = \text{svd}(A)$: decomposição SVD de \mathbf{A} ;

$[U,S,V] = \text{svds}(A,k)$: SVD com apenas k valores singulares de \mathbf{A} ;

Aplicação de SVD

Compressão de Imagem

Entrada: uma imagem \mathcal{I} de $m \times n$ pixels (*grayscale*)

- representar \mathcal{I} como $\mathbf{A} \in \mathcal{M}(m, n), 0 \leq a_{ij} \leq 1;$

Aplicação de SVD

Compressão de Imagem

Entrada: uma imagem \mathcal{I} de $m \times n$ pixels (*grayscale*)

- representar \mathcal{I} como $\mathbf{A} \in \mathcal{M}(m, n)$, $0 \leq a_{ij} \leq 1$;
- compressão via SVD: trocar \mathbf{A} por \mathbf{A}_k ;

Aplicação de SVD

Compressão de Imagem

Entrada: uma imagem \mathcal{I} de $m \times n$ pixels (*grayscale*)

- representar \mathcal{I} como $\mathbf{A} \in \mathcal{M}(m, n)$, $0 \leq a_{ij} \leq 1$;
- compressão via SVD: trocar \mathbf{A} por \mathbf{A}_k ;
- \mathbf{A}_k possui apenas os k primeiros valores singulares de \mathbf{A} ;

Aplicação de SVD

Compressão de Imagem

Entrada: uma imagem \mathcal{I} de $m \times n$ pixels (*grayscale*)

- representar \mathcal{I} como $\mathbf{A} \in \mathcal{M}(m, n)$, $0 \leq a_{ij} \leq 1$;
- compressão via SVD: trocar \mathbf{A} por \mathbf{A}_k ;
- \mathbf{A}_k possui apenas os k primeiros valores singulares de \mathbf{A} ;
- armazenamos $k(m + n + 1)$ números ao invés de mn .

Aplicação de SVD

Compressão de Imagem

Entrada: uma imagem \mathcal{I} de $m \times n$ pixels (*grayscale*)

- representar \mathcal{I} como $\mathbf{A} \in \mathcal{M}(m, n)$, $0 \leq a_{ij} \leq 1$;
- compressão via SVD: trocar \mathbf{A} por \mathbf{A}_k ;
- \mathbf{A}_k possui apenas os k primeiros valores singulares de \mathbf{A} ;
- armazenamos $k(m + n + 1)$ números ao invés de mn .



imagem original

$k = 374$

Aplicação de SVD

Compressão de Imagem

Entrada: uma imagem \mathcal{I} de $m \times n$ pixels (*grayscale*)

- representar \mathcal{I} como $\mathbf{A} \in \mathcal{M}(m, n)$, $0 \leq a_{ij} \leq 1$;
- compressão via SVD: trocar \mathbf{A} por \mathbf{A}_k ;
- \mathbf{A}_k possui apenas os k primeiros valores singulares de \mathbf{A} ;
- armazenamos $k(m + n + 1)$ números ao invés de mn .



imagem original
 $k = 374$



compress. $\approx 44\%$
 $k = 120$

Aplicação de SVD

Compressão de Imagem

Entrada: uma imagem \mathcal{I} de $m \times n$ pixels (*grayscale*)

- representar \mathcal{I} como $\mathbf{A} \in \mathcal{M}(m, n)$, $0 \leq a_{ij} \leq 1$;
- compressão via SVD: trocar \mathbf{A} por \mathbf{A}_k ;
- \mathbf{A}_k possui apenas os k primeiros valores singulares de \mathbf{A} ;
- armazenamos $k(m + n + 1)$ números ao invés de mn .



imagem original
 $k = 374$



compress. $\approx 44\%$
 $k = 120$



compress. $\approx 77\%$
 $k = 50$

MATLAB – Aplicação de SVD

Compressão de Imagem

```
A = imread('flor.png'); % carrega uma imagem indexada [0,255]
A = im2double(A); % transforma para valores reais em [0,1]
figure, imshow(A); % mostra imagem original
```

```
[U,S,V] = svd(A);
k = 120; % numero de valores singulares < min(size(A))
Ak = U(:,1:k)*S(1:k,1:k)*V(:,1:k)'; % imagem comprimida
figure, imshow(Ak);
imwrite(Ak,'flor_svd.png'); % salva imagem
```

Método das Potências

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ diagonalizável, isto é, \mathbf{A} possui autovalores $\lambda_1, \dots, \lambda_n$ associados a um conjunto de autovetores $\{\mathbf{v}_1, \dots, \mathbf{v}_n\} \subset \mathbb{R}^n$ L.I. (com $\|\mathbf{v}_i\|_2 = 1, \forall i$).

Método das Potências

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ diagonalizável, isto é, \mathbf{A} possui autovalores $\lambda_1, \dots, \lambda_n$ associados a um conjunto de autovetores $\{\mathbf{v}_1, \dots, \mathbf{v}_n\} \subset \mathbb{R}^n$ L.I. (com $\|\mathbf{v}_i\|_2 = 1, \forall i$).

Além disso, vamos assumir que os autovalores estão ordenados da seguinte forma:

$$|\lambda_1| > |\lambda_2| \geq |\lambda_3| \geq \dots \geq |\lambda_n|$$

Método das Potências

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ diagonalizável, isto é, \mathbf{A} possui autovalores $\lambda_1, \dots, \lambda_n$ associados a um conjunto de autovetores $\{\mathbf{v}_1, \dots, \mathbf{v}_n\} \subset \mathbb{R}^n$ L.I. (com $\|\mathbf{v}_i\|_2 = 1, \forall i$).

Além disso, vamos assumir que os autovalores estão ordenados da seguinte forma:

$$|\lambda_1| > |\lambda_2| \geq |\lambda_3| \geq \dots \geq |\lambda_n|$$

Objetivo:

- Calcular o autovalor *dominante* λ_1 e o seu autovetor associado \mathbf{v}_1 .

Método das Potências

Quociente de Rayleigh

$$\mu(\mathbf{x}) = \frac{\mathbf{x} \cdot \mathbf{A}\mathbf{x}}{\|\mathbf{x}\|_2^2}$$

Método das Potências

Quociente de Rayleigh

$$\mu(\mathbf{x}) = \frac{\mathbf{x} \cdot \mathbf{A}\mathbf{x}}{\|\mathbf{x}\|_2^2}$$

O que acontece quando \mathbf{x} é autovetor de \mathbf{A} cujo autovalor é λ ?

Método das Potências

Quociente de Rayleigh

$$\mu(\mathbf{x}) = \frac{\mathbf{x} \cdot \mathbf{A}\mathbf{x}}{\|\mathbf{x}\|_2^2}$$

O que acontece quando \mathbf{x} é autovetor de \mathbf{A} cujo autovalor é λ ?

$$\mu(\mathbf{x}) = \frac{\mathbf{x} \cdot \mathbf{A}\mathbf{x}}{\|\mathbf{x}\|_2^2} = \frac{\mathbf{x} \cdot \lambda\mathbf{x}}{\|\mathbf{x}\|_2^2} = \lambda \frac{\|\mathbf{x}\|_2^2}{\|\mathbf{x}\|_2^2} = \lambda$$

Método das Potências

Quociente de Rayleigh

$$\mu(\mathbf{x}) = \frac{\mathbf{x} \cdot \mathbf{Ax}}{\|\mathbf{x}\|_2^2}$$

O que acontece quando \mathbf{x} é autovetor de \mathbf{A} cujo autovalor é λ ?

$$\mu(\mathbf{x}) = \frac{\mathbf{x} \cdot \mathbf{Ax}}{\|\mathbf{x}\|_2^2} = \frac{\mathbf{x} \cdot \lambda \mathbf{x}}{\|\mathbf{x}\|_2^2} = \lambda \frac{\|\mathbf{x}\|_2^2}{\|\mathbf{x}\|_2^2} = \lambda$$

$\mu(\mathbf{x})$ fornece o autovalor associado a \mathbf{x} !

Método das Potências

Processo Iterativo

Dado um chute inicial $\mathbf{x}^{(0)} \in \mathbb{R}^n$ (não-nulo), calcule $\mathbf{y}^{(0)} = \mathbf{x}^{(0)} / \|\mathbf{x}^{(0)}\|_2$.

Método das Potências

Processo Iterativo

Dado um chute inicial $\mathbf{x}^{(0)} \in \mathbb{R}^n$ (não-nulo), calcule $\mathbf{y}^{(0)} = \mathbf{x}^{(0)} / \|\mathbf{x}^{(0)}\|_2$.

Para $k = 1, 2, \dots$ faça:

$$\mathbf{x}^{(k)} = \mathbf{A}\mathbf{y}^{(k-1)}, \quad \mathbf{y}^{(k)} = \frac{\mathbf{x}^{(k)}}{\|\mathbf{x}^{(k)}\|_2}, \quad \lambda_1^{(k)} = \mathbf{y}^{(k)} \cdot \mathbf{A}\mathbf{y}^{(k)}$$

Método das Potências

Processo Iterativo

Dado um chute inicial $\mathbf{x}^{(0)} \in \mathbb{R}^n$ (não-nulo), calcule $\mathbf{y}^{(0)} = \mathbf{x}^{(0)} / \|\mathbf{x}^{(0)}\|_2$.

Para $k = 1, 2, \dots$ faça:

$$\mathbf{x}^{(k)} = \mathbf{A}\mathbf{y}^{(k-1)}, \quad \mathbf{y}^{(k)} = \frac{\mathbf{x}^{(k)}}{\|\mathbf{x}^{(k)}\|_2}, \quad \lambda_1^{(k)} = \mathbf{y}^{(k)} \cdot \mathbf{A}\mathbf{y}^{(k)}$$

O vetor $\mathbf{y}^{(k)}$ é uma aproximação de \mathbf{v}_1 .

Método das Potências

Processo Iterativo

Dado um chute inicial $\mathbf{x}^{(0)} \in \mathbb{R}^n$ (não-nulo), calcule $\mathbf{y}^{(0)} = \mathbf{x}^{(0)} / \|\mathbf{x}^{(0)}\|_2$.

Para $k = 1, 2, \dots$ faça:

$$\mathbf{x}^{(k)} = \mathbf{A}\mathbf{y}^{(k-1)}, \quad \mathbf{y}^{(k)} = \frac{\mathbf{x}^{(k)}}{\|\mathbf{x}^{(k)}\|_2}, \quad \lambda_1^{(k)} = \mathbf{y}^{(k)} \cdot \mathbf{A}\mathbf{y}^{(k)}$$

O vetor $\mathbf{y}^{(k)}$ é uma aproximação de \mathbf{v}_1 .

Note que pela recursão acima temos:

$$\mathbf{y}^{(k)} = \beta^{(k)} \mathbf{A}^k \mathbf{x}^{(0)} \quad \text{com} \quad \beta^{(k)} = \frac{1}{\prod_{i=0}^k \|\mathbf{x}^{(i)}\|_2} = \frac{1}{\|\mathbf{A}^k \mathbf{x}^{(0)}\|_2}$$

Método das Potências

Convergência

Afirmção: $\mathbf{y}^{(k)} \rightarrow \pm \mathbf{v}_1$

Método das Potências

Convergência

Afirmção: $\mathbf{y}^{(k)} \rightarrow \pm \mathbf{v}_1$

$$\mathbf{x}^{(0)} = \sum_{i=1}^n \alpha_i \mathbf{v}_i \Rightarrow \mathbf{y}^{(0)} = \beta^{(0)} \sum_{i=1}^n \alpha_i \mathbf{v}_i, \quad \text{com} \quad \beta^{(0)} = \frac{1}{\|\mathbf{x}^{(0)}\|_2}$$

$$\mathbf{x}^{(1)} = \mathbf{A}\mathbf{y}^{(0)} = \beta^{(0)} \mathbf{A} \sum_{i=1}^n \alpha_i \mathbf{v}_i = \beta^{(0)} \sum_{i=1}^n \alpha_i \mathbf{A}\mathbf{v}_i = \beta^{(0)} \sum_{i=1}^n \alpha_i \lambda_i \mathbf{v}_i$$

$$\mathbf{y}^{(1)} = \beta^{(1)} \sum_{i=1}^n \alpha_i \lambda_i \mathbf{v}_i, \quad \text{com} \quad \beta^{(1)} = \frac{1}{\|\mathbf{x}^{(0)}\|_2 \|\mathbf{x}^{(1)}\|_2}$$

Assim por diante... até o passo k :

$$\mathbf{y}^{(k)} = \beta^{(k)} \sum_{i=1}^n \alpha_i \lambda_i^k \mathbf{v}_i, \quad \text{com} \quad \beta^{(k)} = \frac{1}{\|\mathbf{x}^{(0)}\|_2 \cdots \|\mathbf{x}^{(k)}\|_2}$$

Método das Potências

Convergência

$$\mathbf{y}^{(k)} = \beta^{(k)} \sum_{i=1}^n \alpha_i \lambda_i^k \mathbf{v}_i = \beta^{(k)} \lambda_1^k \left(\alpha_1 \mathbf{v}_1 + \underbrace{\sum_{i=2}^n \alpha_i \frac{\lambda_i^k}{\lambda_1^k} \mathbf{v}_i}_{\mathbf{r}^{(k)}} \right)$$

Como $|\lambda_1| > |\lambda_i| \Rightarrow \lim_{k \rightarrow \infty} (\lambda_i/\lambda_1)^k = 0 \Rightarrow \lim_{k \rightarrow \infty} \mathbf{r}^{(k)} = \bar{\mathbf{0}}$, logo

$$\lim_{k \rightarrow \infty} \mathbf{y}^{(k)} = \lim_{k \rightarrow \infty} \beta^{(k)} \lambda_1^k \alpha_1 \mathbf{v}_1.$$

Agora precisamos mostrar que $\beta^{(k)} \lambda_1^k \alpha_1 \rightarrow \pm 1$. Por outro lado,

$$\beta^{(k)} = \frac{1}{\|\mathbf{A}^k \mathbf{x}^{(0)}\|_2} = \frac{1}{\|\lambda_1^k (\alpha_1 \mathbf{v}_1 + \mathbf{r}^{(k)})\|_2} \quad \text{e} \quad \|\mathbf{v}_1\|_2 = 1$$

$$\text{Portanto, } \beta^{(k)} \lambda_1^k \alpha_1 = \frac{\lambda_1^k \alpha_1}{\|\lambda_1^k (\alpha_1 \mathbf{v}_1 + \mathbf{r}^{(k)})\|_2} \rightarrow \pm 1.$$

Método das Potências

Critérios de Parada

Dados $\varepsilon > 0$ e $k_{max} \in \mathbb{N}$, temos:

1 $k = k_{max}$

Método das Potências

Critérios de Parada

Dados $\varepsilon > 0$ e $k_{max} \in \mathbb{N}$, temos:

1 $k = k_{max}$

2 $|\lambda_1^{(k+1)} - \lambda_1^{(k)}| < \varepsilon$


Método das Potências

Critérios de Parada

Dados $\varepsilon > 0$ e $k_{max} \in \mathbb{N}$, temos:

- 1 $k = k_{max}$
- 2 $|\lambda_1^{(k+1)} - \lambda_1^{(k)}| < \varepsilon$
- 3 teste de alinhamento ($|\cos \theta| \approx 1$):

$$| |\mathbf{y}^{(k+1)} \cdot \mathbf{y}^{(k)}| - 1 | < \varepsilon$$



Método das Potências

Exemplo 1

Considere a matriz $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix}$. Use o Método das Potências para calcular o autovalor dominante e seu autovetor correspondente, com $\varepsilon = 0.1$ para o teste de alinhamento.

Método das Potências

Exemplo 1

Considere a matriz $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix}$. Use o Método das Potências para calcular o autovalor dominante e seu autovetor correspondente, com $\varepsilon = 0.1$ para o teste de alinhamento.

Solução: vamos escolher $\mathbf{y}^{(0)} = [1, 0]^T$ como chute inicial.

Método das Potências

Exemplo 1

Considere a matriz $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix}$. Use o Método das Potências para calcular o autovalor dominante e seu autovetor correspondente, com $\varepsilon = 0.1$ para o teste de alinhamento.

Solução: vamos escolher $\mathbf{y}^{(0)} = [1, 0]^T$ como chute inicial.

$$\mathbf{x}^{(1)} = \mathbf{A}\mathbf{y}^{(0)} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ 3 \end{bmatrix}$$

Método das Potências

Exemplo 1

Considere a matriz $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix}$. Use o Método das Potências para calcular o autovalor dominante e seu autovetor correspondente, com $\varepsilon = 0.1$ para o teste de alinhamento.

Solução: vamos escolher $\mathbf{y}^{(0)} = [1, 0]^T$ como chute inicial.

$$\mathbf{x}^{(1)} = \mathbf{A}\mathbf{y}^{(0)} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ 3 \end{bmatrix} \Rightarrow \mathbf{y}^{(1)} = \mathbf{x}^{(1)} / \|\mathbf{x}^{(1)}\|_2 = \begin{bmatrix} \sqrt{10}/10 \\ 3\sqrt{10}/10 \end{bmatrix}$$

Método das Potências

Exemplo 1

Considere a matriz $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix}$. Use o Método das Potências para calcular o autovalor dominante e seu autovetor correspondente, com $\varepsilon = 0.1$ para o teste de alinhamento.

Solução: vamos escolher $\mathbf{y}^{(0)} = [1, 0]^\top$ como chute inicial.

$$\mathbf{x}^{(1)} = \mathbf{A}\mathbf{y}^{(0)} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ 3 \end{bmatrix} \Rightarrow \mathbf{y}^{(1)} = \mathbf{x}^{(1)} / \|\mathbf{x}^{(1)}\|_2 = \begin{bmatrix} \sqrt{10}/10 \\ 3\sqrt{10}/10 \end{bmatrix}$$

$$erro = \left| |\mathbf{y}^{(1)} \cdot \mathbf{y}^{(0)}| - 1 \right| = 0.6838 > \varepsilon$$

Método das Potências

Exemplo 1

Considere a matriz $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix}$. Use o Método das Potências para calcular o autovalor dominante e seu autovetor correspondente, com $\varepsilon = 0.1$ para o teste de alinhamento.

Solução: vamos escolher $\mathbf{y}^{(0)} = [1, 0]^\top$ como chute inicial.

$$\mathbf{x}^{(1)} = \mathbf{A}\mathbf{y}^{(0)} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ 3 \end{bmatrix} \Rightarrow \mathbf{y}^{(1)} = \mathbf{x}^{(1)} / \|\mathbf{x}^{(1)}\|_2 = \begin{bmatrix} \sqrt{10}/10 \\ 3\sqrt{10}/10 \end{bmatrix}$$

$$\text{erro} = \left| |\mathbf{y}^{(1)} \cdot \mathbf{y}^{(0)}| - 1 \right| = 0.6838 > \varepsilon$$

$$\mathbf{x}^{(2)} = \mathbf{A}\mathbf{y}^{(1)} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix} \begin{bmatrix} \sqrt{10}/10 \\ 3\sqrt{10}/10 \end{bmatrix} = \begin{bmatrix} 7\sqrt{10}/10 \\ 9\sqrt{10}/10 \end{bmatrix}$$

Método das Potências

Exemplo 1

Considere a matriz $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix}$. Use o Método das Potências para calcular o autovalor dominante e seu autovetor correspondente, com $\varepsilon = 0.1$ para o teste de alinhamento.

Solução: vamos escolher $\mathbf{y}^{(0)} = [1, 0]^\top$ como chute inicial.

$$\mathbf{x}^{(1)} = \mathbf{A}\mathbf{y}^{(0)} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ 3 \end{bmatrix} \Rightarrow \mathbf{y}^{(1)} = \mathbf{x}^{(1)} / \|\mathbf{x}^{(1)}\|_2 = \begin{bmatrix} \sqrt{10}/10 \\ 3\sqrt{10}/10 \end{bmatrix}$$

$$\text{erro} = |\mathbf{y}^{(1)} \cdot \mathbf{y}^{(0)}| - 1 = 0.6838 > \varepsilon$$

$$\mathbf{x}^{(2)} = \mathbf{A}\mathbf{y}^{(1)} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix} \begin{bmatrix} \sqrt{10}/10 \\ 3\sqrt{10}/10 \end{bmatrix} = \begin{bmatrix} 7\sqrt{10}/10 \\ 9\sqrt{10}/10 \end{bmatrix} \Rightarrow \mathbf{y}^{(2)} = \mathbf{x}^{(2)} / \|\mathbf{x}^{(2)}\|_2 = \begin{bmatrix} 7\sqrt{130}/130 \\ 9\sqrt{130}/130 \end{bmatrix}$$

Método das Potências

Exemplo 1

Considere a matriz $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix}$. Use o Método das Potências para calcular o autovalor dominante e seu autovetor correspondente, com $\varepsilon = 0.1$ para o teste de alinhamento.

Solução: vamos escolher $\mathbf{y}^{(0)} = [1, 0]^\top$ como chute inicial.

$$\mathbf{x}^{(1)} = \mathbf{A}\mathbf{y}^{(0)} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ 3 \end{bmatrix} \Rightarrow \mathbf{y}^{(1)} = \mathbf{x}^{(1)} / \|\mathbf{x}^{(1)}\|_2 = \begin{bmatrix} \sqrt{10}/10 \\ 3\sqrt{10}/10 \end{bmatrix}$$

$$\text{erro} = ||\mathbf{y}^{(1)} \cdot \mathbf{y}^{(0)}| - 1| = 0.6838 > \varepsilon$$

$$\mathbf{x}^{(2)} = \mathbf{A}\mathbf{y}^{(1)} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix} \begin{bmatrix} \sqrt{10}/10 \\ 3\sqrt{10}/10 \end{bmatrix} = \begin{bmatrix} 7\sqrt{10}/10 \\ 9\sqrt{10}/10 \end{bmatrix} \Rightarrow \mathbf{y}^{(2)} = \mathbf{x}^{(2)} / \|\mathbf{x}^{(2)}\|_2 = \begin{bmatrix} 7\sqrt{130}/130 \\ 9\sqrt{130}/130 \end{bmatrix}$$

$$\text{erro} = ||\mathbf{y}^{(2)} \cdot \mathbf{y}^{(1)}| - 1| = 0.0570 < \varepsilon$$

Método das Potências

Exemplo 1

Considere a matriz $\mathbf{A} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix}$. Use o Método das Potências para calcular o autovalor dominante e seu autovetor correspondente, com $\varepsilon = 0.1$ para o teste de alinhamento.

Solução: vamos escolher $\mathbf{y}^{(0)} = [1, 0]^\top$ como chute inicial.

$$\mathbf{x}^{(1)} = \mathbf{A}\mathbf{y}^{(0)} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ 3 \end{bmatrix} \Rightarrow \mathbf{y}^{(1)} = \mathbf{x}^{(1)} / \|\mathbf{x}^{(1)}\|_2 = \begin{bmatrix} \sqrt{10}/10 \\ 3\sqrt{10}/10 \end{bmatrix}$$

$$\text{erro} = \left| |\mathbf{y}^{(1)} \cdot \mathbf{y}^{(0)}| - 1 \right| = 0.6838 > \varepsilon$$

$$\mathbf{x}^{(2)} = \mathbf{A}\mathbf{y}^{(1)} = \begin{bmatrix} 1 & 2 \\ 3 & 2 \end{bmatrix} \begin{bmatrix} \sqrt{10}/10 \\ 3\sqrt{10}/10 \end{bmatrix} = \begin{bmatrix} 7\sqrt{10}/10 \\ 9\sqrt{10}/10 \end{bmatrix} \Rightarrow \mathbf{y}^{(2)} = \mathbf{x}^{(2)} / \|\mathbf{x}^{(2)}\|_2 = \begin{bmatrix} 7\sqrt{130}/130 \\ 9\sqrt{130}/130 \end{bmatrix}$$

$$\text{erro} = \left| |\mathbf{y}^{(2)} \cdot \mathbf{y}^{(1)}| - 1 \right| = 0.0570 < \varepsilon \Rightarrow \lambda_1 \approx \lambda_1^{(2)} = \mathbf{y}^{(2)} \cdot \mathbf{A}\mathbf{y}^{(2)} = 4.0462$$

MATLAB – Método das Potências

```
function [lambda,y,k] = potencias(A,tol)

k = 0; kmax = 1000; erro = inf;
n = size(A,1); y0 = zeros(n,1); y0(1) = 1;

while (erro>tol && k<kmax)
    x = A*y0;
    y = x/norm(x);
    erro = abs(abs(y0'*y)-1);
    y0 = y; k = k+1;
end

lambda = y'*A*y;
```

Método das Potências

Potência Inversa

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ invertível. Agora, vamos assumir que os seus autovalores estão ordenados da seguinte forma:

$$|\lambda_1| \geq |\lambda_2| \geq |\lambda_3| \geq \cdots > |\lambda_n| > 0$$

Método das Potências

Potência Inversa

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ invertível. Agora, vamos assumir que os seus autovalores estão ordenados da seguinte forma:

$$|\lambda_1| \geq |\lambda_2| \geq |\lambda_3| \geq \dots > |\lambda_n| > 0$$

Objetivo:

- Calcular o **menor** autovalor em módulo λ_n e o seu autovetor associado \mathbf{v}_n . Note que,

$$\mathbf{A}\mathbf{v}_j = \lambda_j\mathbf{v}_j \iff \mathbf{A}^{-1}\mathbf{v}_j = \frac{1}{\lambda_j}\mathbf{v}_j \iff \Lambda(\mathbf{A}^{-1}) = \{1/\lambda_1, \dots, 1/\lambda_n\}.$$

Logo, $1/\lambda_n$ é autovalor dominante de \mathbf{A}^{-1} .

Método das Potências

Potência Inversa

Dado um chute inicial $\mathbf{x}^{(0)} \in \mathbb{R}^n$ (não-nulo), calcule $\mathbf{y}^{(0)} = \mathbf{x}^{(0)} / \|\mathbf{x}^{(0)}\|_2$.

Método das Potências

Potência Inversa

Dado um chute inicial $\mathbf{x}^{(0)} \in \mathbb{R}^n$ (não-nulo), calcule $\mathbf{y}^{(0)} = \mathbf{x}^{(0)} / \|\mathbf{x}^{(0)}\|_2$.

Para $k = 1, 2, \dots$ faça:

$$\mathbf{x}^{(k)} = \mathbf{A}^{-1}\mathbf{y}^{(k-1)}, \quad \mathbf{y}^{(k)} = \frac{\mathbf{x}^{(k)}}{\|\mathbf{x}^{(k)}\|_2}, \quad \lambda_n^{(k)} = \mathbf{y}^{(k)} \cdot \mathbf{A}\mathbf{y}^{(k)}$$

Considerações:

- Devemos resolver o sistema linear $\mathbf{A}\mathbf{x}^{(k)} = \mathbf{y}^{(k-1)}$ a cada iteração;
- Calcule a **Decomposição LU** de \mathbf{A} e armazene \mathbf{L} e \mathbf{U} ;
- Use os algoritmos de substituição para resolver o sistema.

Método das Potências

Potência Inversa com Deslocamento

Pergunta: como calcular um autovalor arbitrário λ_j e o seu autovetor associado \mathbf{v}_j ?

Método das Potências

Potência Inversa com Deslocamento

Pergunta: como calcular um autovalor arbitrário λ_j e o seu autovetor associado \mathbf{v}_j ? A ideia é a seguinte, seja $\alpha \in \mathbb{C} \setminus \Lambda(\mathbf{A})$, logo

$$\Lambda(\mathbf{A}) = \{\lambda_1, \dots, \lambda_n\} \implies \Lambda(\mathbf{A} - \alpha \mathbf{I}) = \{\lambda_1 - \alpha, \dots, \lambda_n - \alpha\}.$$

Método das Potências

Potência Inversa com Deslocamento

Pergunta: como calcular um autovalor arbitrário λ_j e o seu autovetor associado \mathbf{v}_j ? A ideia é a seguinte, seja $\alpha \in \mathbb{C} \setminus \Lambda(\mathbf{A})$, logo

$$\Lambda(\mathbf{A}) = \{\lambda_1, \dots, \lambda_n\} \implies \Lambda(\mathbf{A} - \alpha \mathbf{I}) = \{\lambda_1 - \alpha, \dots, \lambda_n - \alpha\}.$$

Assim, os autovalores de $\mathbf{B} = (\mathbf{A} - \alpha \mathbf{I})^{-1}$ são da forma

$$\gamma_j = \frac{1}{\lambda_j - \alpha}$$

Portanto, quanto mais próximo α estiver de λ_j , mais dominante será γ_j . O número α é chamado de **deslocamento**.

Resposta: agora basta aplicar o Método da Potência Inversa na matriz deslocada \mathbf{B} .

Método das Potências

Potência Inversa com Deslocamento

Pergunta: como calcular um autovalor arbitrário λ_j e o seu autovetor associado \mathbf{v}_j ? A ideia é a seguinte, seja $\alpha \in \mathbb{C} \setminus \Lambda(\mathbf{A})$, logo

$$\Lambda(\mathbf{A}) = \{\lambda_1, \dots, \lambda_n\} \implies \Lambda(\mathbf{A} - \alpha \mathbf{I}) = \{\lambda_1 - \alpha, \dots, \lambda_n - \alpha\}.$$

Assim, os autovalores de $\mathbf{B} = (\mathbf{A} - \alpha \mathbf{I})^{-1}$ são da forma

$$\gamma_j = \frac{1}{\lambda_j - \alpha}$$

Portanto, quanto mais próximo α estiver de λ_j , mais dominante será γ_j . O número α é chamado de **deslocamento**.

Resposta: agora basta aplicar o Método da Potência Inversa na matriz deslocada \mathbf{B} . **Mas, como escolher α ?**

MATLAB – Potência Inversa com Deslocamento

```
function [lambda,y,k] = potencia_inv(A,tol,alpha)
```

```
if(nargin==2) alpha = 0; end
```

```
k = 0; kmax = 1000; erro = inf;
```

```
n = size(A,1); y0 = zeros(n,1); y0(1) = 1;
```

```
B = A - alpha*eye(n);
```

```
[L,U] = lu(B);
```

```
while (erro>tol && k<kmax)
```

```
    x = U \ (L \ y0);
```

```
    y = x/norm(x);
```

```
    erro = abs(abs(y0'*y)-1);
```

```
    y0 = y; k = k+1;
```

```
end
```

```
lambda = y'*A*y;
```

Discos de Gershgorin

Definição (discos de Gershgorin)

Seja $\mathbf{A} \in \mathcal{M}(n, n)$. O **disco de Gershgorin** de centro a_{ii} e raio r_i associado a i -ésima linha de \mathbf{A} é definido como

$$D_{\mathbf{A}}(a_{ii}, r_i) = \{z \in \mathbb{C} \mid |z - a_{ii}| \leq r_i\} \quad \text{com} \quad r_i = \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}|$$


Discos de Gershgorin

Definição (discos de Gershgorin)

Seja $\mathbf{A} \in \mathcal{M}(n, n)$. O **disco de Gershgorin** de centro a_{ii} e raio r_i associado a i -ésima linha de \mathbf{A} é definido como

$$D_{\mathbf{A}}(a_{ii}, r_i) = \{z \in \mathbb{C} \mid |z - a_{ii}| \leq r_i\} \quad \text{com} \quad r_i = \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}|$$

$$\mathbf{A} = \begin{bmatrix} 12 & 2 & 3 \\ 2 & 3 & 5 \\ 3 & 5 & -2 \end{bmatrix}$$



Discos de Gershgorin

Proposição

Seja $\mathbf{A} \in \mathcal{M}(n, n)$. Temos que

$$\Lambda(\mathbf{A}) \subset \left(\bigcup_{i=1}^n D_{\mathbf{A}}(a_{ii}, r_i) \right) \cap \left(\bigcup_{i=1}^n D_{\mathbf{A}^T}(a_{ii}, r_i) \right).$$

Discos de Gershgorin

Proposição

Seja $\mathbf{A} \in \mathcal{M}(n, n)$. Temos que

$$\Lambda(\mathbf{A}) \subset \left(\bigcup_{i=1}^n D_{\mathbf{A}}(a_{ii}, r_i) \right) \cap \left(\bigcup_{i=1}^n D_{\mathbf{A}^T}(a_{ii}, r_i) \right).$$

Note que a proposição acima fornece um teste de rejeição no cálculo de autovalores e uma boa região (apesar de grande) para escolha do deslocamento α no Método da Potência Inversa.

Discos de Gershgorin

Proposição

Seja $\mathbf{A} \in \mathcal{M}(n, n)$. Temos que

$$\Lambda(\mathbf{A}) \subset \left(\bigcup_{i=1}^n D_{\mathbf{A}}(a_{ii}, r_i) \right) \cap \left(\bigcup_{i=1}^n D_{\mathbf{A}^T}(a_{ii}, r_i) \right).$$

Note que a proposição acima fornece um teste de rejeição no cálculo de autovalores e uma boa região (apesar de grande) para escolha do deslocamento α no Método da Potência Inversa.

Para restringir ainda mais essa região, não se esqueça do **Teorema Espectral**: se $\mathbf{A} = \mathbf{A}^T \Rightarrow \Lambda(\mathbf{A}) \subset \mathbb{R}$.

MATLAB – Discos de Gershgorin

```
function discos_gersh(A)

ctr = diag(A); raio = sum(abs(A-diag(ctr)),2);
theta = linspace(0,2*pi,50);
n = length(ctr);

figure; set(gca,'FontSize',18); cor = [1, 1, 0.7];
axis equal; xlabel('Real'); ylabel('Imag');
hold on
for k=1:n
    D = ctr(k) + raio(k)*exp(i*theta);
    patch(real(D),imag(D),cor);
end
for k=1:n
    D = ctr(k) + raio(k)*exp(i*theta);
    plot(real(D),imag(D),'k-',real(ctr(k)),imag(ctr(k)),'k+');
end
hold off
```

Aplicação: Pagerank

Medida de relevância de uma página web (Brin & Page, 1998).

- ordenação dos resultados de uma busca no Google

The screenshot shows a Google search interface with the query "icmc-usp são carlos". The search results are organized into several sections:

- Search Bar:** Displays the Google logo, the search query "icmc-usp são carlos", and a search button.
- Navigation:** Includes tabs for "All", "Maps", "Images", "News", "Videos", and "More", along with a "Search tools" button.
- Results Summary:** Shows "About 114,000 results (0.43 seconds)".
- Main Result:**
 - Title:** "ICMC-USP - São Carlos | Instituto de Ciências Matemáticas ..."
 - Description:** "www.icmc.usp.br • University of São Paulo. Abertas inscrições para visita monitorada à USP São Carlos | Veja Mais. PrevNext ... ICMC oferece curso preparatório para a Olimpíada Brasileira de Robótica."
 - Left Column:**
 - Pos_graduacao:** "13 Bem-vindo! Aqui você encontra as informações referentes aos ..."
 - Departamentos:** "O ICMC é composto por quatro Departamentos - Departamento ..."
 - Matemática:** "Na área de Matemática, a Universidade de São Paulo tem ..."
 - More results from usp.br**
 - Right Column:**
 - Cso08:** "UNIVERSIDADE DE SÃO PAULO INSTITUTO DE CIÊNCIAS ..."
 - Pessoas:** "PESSOAS. Currículo Lattes - Grupos CNPq ... PESSOAS ..."
- Local Listing:**
 - Title:** "ICMC - São Carlos"
 - Address:** "Av. Trab. São-Carolense, 400 - Centro, São Carlos - SP, 13095-580, Brazil"
 - Phone:** "+55 16 3373-9700"
 - Reviews:** "25 Google reviews"
 - People also search for:** Includes links to "USP São Carlos - Campus 1", "Universidade Federal de São Carlos", "Teatro da USP", "Auto Escola São Carlos", and "Auto Escola Santa Fel..."
- Additional Results:**
 - ICMC/USP - Facebook:** "www.facebook.com/... School • Translate this page. Bem-vindo, São Carlos (São Carlos, Brazil) 5433 likes · 191 talking about this. Página oficial do Instituto de Ciências Matemáticas e de Computação ..."
 - ICMC/USP - YouTube:** "https://www.youtube.com/user/icmcusp • Translate this page. Canal do Instituto de Ciências Matemáticas e de Computação - ICMC, da USP de São Carlos."
 - Graduação no ICMC-USP São Carlos - YouTube:** "https://www.youtube.com/watch?v=mpEAgpWFPo. Mar 22, 2010 - Uploaded by ProfInjantana. Cursos de Graduação oferecidos pelo ICMC-USP-São Carlos - 6 cursos de graduação oferecidos ..."
 - Licenciatura em Matemática ICMC USP São Carlos - Video ...:** "www.dailymotion.com/video/x27yrb08. Dailymotion • May 16, 2010. Licenciatura em Matemática ICMC USP São Carlos."

Aplicação: Pagerank

Processo Estocástico

Definição (vetor estocástico)

Um vetor $\mathbf{p} \in \mathbb{R}^n$ com $p_i \geq 0$ e $\sum_{i=1}^n p_i = 1$ é chamado de **estocástico**.

Aplicação: Pagerank

Processo Estocástico

Definição (vetor estocástico)

Um vetor $\mathbf{p} \in \mathbb{R}^n$ com $p_i \geq 0$ e $\sum_{i=1}^n p_i = 1$ é chamado de **estocástico**.

Definição (matriz estocástica)

Uma matriz $\mathbf{A} \in \mathcal{M}(n, n)$ cujos vetores coluna são estocásticos é chamada de **matriz estocástica**.

Aplicação: Pagerank

Processo Estocástico

Definição (vetor estocástico)

Um vetor $\mathbf{p} \in \mathbb{R}^n$ com $p_i \geq 0$ e $\sum_{i=1}^n p_i = 1$ é chamado de **estocástico**.

Definição (matriz estocástica)

Uma matriz $\mathbf{A} \in \mathcal{M}(n, n)$ cujos vetores coluna são estocásticos é chamada de **matriz estocástica**.

Proposição

Se $\mathbf{A} \in \mathcal{M}(n, n)$ e $\mathbf{p} \in \mathbb{R}^n$ são estocásticos então:

- 1 o vetor $\mathbf{A}\mathbf{p} \in \mathbb{R}^n$ é estocástico;
- 2 $\lambda = 1$ é um autovalor de \mathbf{A} .

Aplicação: Pagerank

Matriz Estocástica

Processo de Markov

- Dada uma matriz estocástica \mathbf{A} e um distribuição de probabilidade $\mathbf{p}^{(t)}$ no tempo t , podemos descobrir a distribuição no tempo $t + k$:

$$\mathbf{p}^{(t+k)} = \mathbf{A}^k \mathbf{p}^{(t)} .$$

Aplicação: Pagerank

Matriz Estocástica

Processo de Markov

- Dada uma matriz estocástica \mathbf{A} e um distribuição de probabilidade $\mathbf{p}^{(t)}$ no tempo t , podemos descobrir a distribuição no tempo $t + k$:

$$\mathbf{p}^{(t+k)} = \mathbf{A}^k \mathbf{p}^{(t)} .$$

Exemplo 4

Em uma cidade têm pessoas que só ficam em 3 estados: 1 (magra), 2 (gorda) e 3 (sarada). A distribuição inicial é dada por $\mathbf{p}^{(0)} = (1/3, 1/3, 1/3)^\top$, suponha que a matriz estocástica seja

$$\mathbf{A} = \begin{bmatrix} 1/2 & 0 & 1/4 \\ 0 & 1/2 & 1/4 \\ 1/2 & 1/2 & 1/2 \end{bmatrix}$$

Aplicação: Pagerank

Matriz Estocástica

Processo de Markov

- Dada uma matriz estocástica \mathbf{A} e um distribuição de probabilidade $\mathbf{p}^{(t)}$ no tempo t , podemos descobrir a distribuição no tempo $t + k$:

$$\mathbf{p}^{(t+k)} = \mathbf{A}^k \mathbf{p}^{(t)}.$$

Exemplo 4

Em uma cidade têm pessoas que só ficam em 3 estados: 1 (magra), 2 (gorda) e 3 (sarada). A distribuição inicial é dada por $\mathbf{p}^{(0)} = (1/3, 1/3, 1/3)^\top$, suponha que a matriz estocástica seja

$$\mathbf{A} = \begin{bmatrix} 1/2 & 0 & 1/4 \\ 0 & 1/2 & 1/4 \\ 1/2 & 1/2 & 1/2 \end{bmatrix} \implies \mathbf{p}^{(1)} = \mathbf{A}\mathbf{p}^{(0)} = \begin{bmatrix} 1/4 \\ 1/4 \\ 1/2 \end{bmatrix}$$

Aplicação: Pagerank

Teorema de Perron-Frobenius

Teorema (Perron-Frobenius)

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ uma matriz estocástica, então:

- 1 $\lambda = 1$ é o autovalor dominante de \mathbf{A} ;
- 2 O autovetor \mathbf{v} associado a λ possui todas entradas positivas ou negativas. Em particular, para λ existe um único autovetor que é estocástico.

Aplicação: Pagerank

Teorema de Perron-Frobenius

Teorema (Perron-Frobenius)

Seja $\mathbf{A} \in \mathcal{M}(n, n)$ uma matriz estocástica, então:

- 1 $\lambda = 1$ é o autovalor dominante de \mathbf{A} ;
- 2 O autovetor \mathbf{v} associado a λ possui todas entradas positivas ou negativas. Em particular, para λ existe um único autovetor que é estocástico.

Portanto, a convergência do Processo de Markov é assegurada graças ao **Método das Potências**, isto é,

$$\mathbf{p}^{(k)} \rightarrow \mathbf{v}.$$

O autovetor \mathbf{v} é chamado de **vetor estacionário** de \mathbf{A} .

Aplicação: Pagerank

MATLAB – Método das Potências *Revisitado*


```
function [y,k] = potencias_markov(A,tol)

k = 0; kmax = 1000; erro = inf;
n = size(A,1); y0 = ones(n,1)/n;

while (erro>tol && k<kmax)
    y = A*y0;
    erro = abs(y'*A*y-1);
    y0 = y; k = k+1;
end
```

Aplicação: Pagerank

WWW




Páginas da web podem ser representadas como um grafo direcionado.

- uma página é importante se páginas importantes têm *link* para ela;
- eleição: um link de $A \rightarrow B$ é um voto de A para B ;

Aplicação: Pagerank

WWW




Páginas da web podem ser representadas como um grafo direcionado.

- uma página é importante se páginas importantes têm *link* para ela;
- eleição: um link de $A \rightarrow B$ é um voto de A para B ;
- **visão probabilística do Pagerank:** é a probabilidade de uma página web ser visitada em certo instante de tempo durante um passeio aleatório infinito.

Aplicação: Pagerank

WWW




Um grafo direcionado pode ser representado por uma matriz de conectividade:

$$a_{ij} = \begin{cases} 1 & \text{se tem link } j \rightarrow i \\ 0 & \text{caso contrário} \end{cases} \quad \mathbf{A} = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 1 & 1 & 0 \end{bmatrix}$$

Aplicação: Pagerank

WWW



Agora precisamos transformar A em uma “matriz estocástica” P :


$$p_{ij} = \begin{cases} a_{ij}/c_j & \text{se } c_j \neq 0 \\ 0 & \text{caso contrário} \end{cases}$$

$$\text{com } c_j = \sum_{i=1}^n a_{ij}$$

$$P = \begin{bmatrix} 0 & 0 & 1/3 & 0 & 0 & 0 \\ 1/2 & 0 & 1/3 & 0 & 0 & 0 \\ 1/2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1/3 & 0 & 0 & 1/2 \\ 0 & 0 & 0 & 1/2 & 0 & 1/2 \\ 0 & 0 & 0 & 1/2 & 1 & 0 \end{bmatrix}$$

Aplicação: Pagerank

WWW




Para resolver os “becos sem saída” precisamos de um vetor $\mathbf{d} \in \mathbb{R}^n$:

$$d_j = \begin{cases} 1/n & \text{se } c_j = 0 \\ 0 & \text{caso contrário} \end{cases} \quad \mathbf{S} = \begin{bmatrix} 0 & 0 & 1/3 & 0 & 0 & 0 \\ 1/2 & 0 & 1/3 & 0 & 0 & 0 \\ 1/2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1/3 & 0 & 0 & 1/2 \\ 0 & 0 & 0 & 1/2 & 0 & 1/2 \\ 0 & 0 & 0 & 1/2 & 1 & 0 \end{bmatrix} + \mathbf{1}\mathbf{d}^\top$$

$$\mathbf{1} = [1, \dots, 1]^\top \in \mathbb{R}^n$$

Aplicação: Pagerank

WWW




Para resolver os “becos sem saída” precisamos de um vetor $\mathbf{d} \in \mathbb{R}^n$:

$$d_j = \begin{cases} 1/n & \text{se } c_j = 0 \\ 0 & \text{caso contrário} \end{cases} \quad \mathbf{S} = \begin{bmatrix} 0 & 1/6 & 1/3 & 0 & 0 & 0 \\ 1/2 & 1/6 & 1/3 & 0 & 0 & 0 \\ 1/2 & 1/6 & 0 & 0 & 0 & 0 \\ 0 & 1/6 & 1/3 & 0 & 0 & 1/2 \\ 0 & 1/6 & 0 & 1/2 & 0 & 1/2 \\ 0 & 1/6 & 0 & 1/2 & 1 & 0 \end{bmatrix}$$

$$\mathbf{1} = [1, \dots, 1]^T \in \mathbb{R}^n$$

Aplicação: Pagerank

WWW




Agora precisamos evitar ciclos no grafo modificando \mathbf{S} de modo a tornar o grafo irredutível:

$$\mathbf{G} = \alpha \begin{bmatrix} 0 & 1/6 & 1/3 & 0 & 0 & 0 \\ 1/2 & 1/6 & 1/3 & 0 & 0 & 0 \\ 1/2 & 1/6 & 0 & 0 & 0 & 0 \\ 0 & 1/6 & 1/3 & 0 & 0 & 1/2 \\ 0 & 1/6 & 0 & 1/2 & 0 & 1/2 \\ 0 & 1/6 & 0 & 1/2 & 1 & 0 \end{bmatrix} + (1 - \alpha) \frac{\mathbf{1}\mathbf{1}^T}{n}$$

Aplicação: Pagerank

WWW




Agora precisamos evitar ciclos no grafo modificando \mathbf{S} de modo a tornar o grafo irredutível:

$$\mathbf{G} = \alpha \begin{bmatrix} 0 & 1/2 & 1/3 & 0 & 0 & 0 \\ 1/2 & 1/2 & 1/3 & 0 & 0 & 0 \\ 1/2 & 1/6 & 0 & 0 & 0 & 0 \\ 0 & 1/6 & 1/3 & 0 & 0 & 1/2 \\ 0 & 1/6 & 0 & 1/2 & 0 & 1/2 \\ 0 & 1/6 & 0 & 1/2 & 1 & 0 \end{bmatrix} + (1 - \alpha) \begin{bmatrix} 1/6 & 1/6 & 1/6 & 1/6 & 1/6 & 1/6 \\ 1/6 & 1/6 & 1/6 & 1/6 & 1/6 & 1/6 \\ 1/6 & 1/6 & 1/6 & 1/6 & 1/6 & 1/6 \\ 1/6 & 1/6 & 1/6 & 1/6 & 1/6 & 1/6 \\ 1/6 & 1/6 & 1/6 & 1/6 & 1/6 & 1/6 \\ 1/6 & 1/6 & 1/6 & 1/6 & 1/6 & 1/6 \end{bmatrix}$$

Aplicação: Pagerank

WWW



Matriz Google:

$$\mathbf{G} = \alpha(\mathbf{A} + \mathbf{1}\mathbf{d}^T) + (1 - \alpha) \frac{\mathbf{1}\mathbf{1}^T}{n}$$

Originalmente o valor escolhido para o peso foi $\alpha = 0.85$.

Aplicação: Pagerank

MATLAB

```
clear;
I = [2 3 2 4 5 6 6 4 5];
J = [1 1 3 3 4 4 5 6 6];
n = 6; A = zeros(n);

for idx=1:length(I)
    A(I(idx),J(idx)) = 1;
end

c = sum(A);
j = find(c == 0);
A(:,j) = ones(n,1); c(j) = n;
S = A./repmat(c,[n,1]);
alpha = 0.85;
G = alpha*S + (1-alpha)*ones(n)/n;
v = potencias_markov(G,1e-6)
[~,ranking] = sort(v,'descend')
```