

# MS211 - Cálculo Numérico

Aula 06 – Fatoração de Cholesky e  
Condicionamento de uma Matriz.



**UNICAMP**

Marcos Eduardo Valle  
Matemática Aplicada  
IMECC - Unicamp



A aula de hoje está dividida em duas partes. Na primeira parte estudaremos a fatoração de Cholesky. Na segunda parte estudaremos o condicionamento de uma matriz.

A aula de hoje está dividida em duas partes. Na primeira parte estudaremos a fatoração de Cholesky. Na segunda parte estudaremos o condicionamento de uma matriz.

---

A fatoração de Cholesky pode ser interpretada como uma variação da fatoração LU que leva em considerações a estrutura da matriz.

A aula de hoje está dividida em duas partes. Na primeira parte estudaremos a fatoração de Cholesky. Na segunda parte estudaremos o condicionamento de uma matriz.

---

A fatoração de Cholesky pode ser interpretada como uma variação da fatoração LU que leva em considerações a estrutura da matriz.

---

O condicionamento de uma matriz está relacionado à credibilidade da solução obtida por um método numérico.

# Parte 1

## Fatoração de Cholesky

O método da eliminação de Gauss e a Fatoração LU podem ser adaptados para certos tipos de matrizes que surgem em muitas situações práticas.

O método da eliminação de Gauss e a Fatoração LU podem ser adaptados para certos tipos de matrizes que surgem em muitas situações práticas.

---

Nesse casos, informações adicionais sobre a estrutura da matriz são consideradas de forma a reduzir o esforço computacional do método numérico.

O método da eliminação de Gauss e a Fatoração LU podem ser adaptados para certos tipos de matrizes que surgem em muitas situações práticas.

---

Nesse casos, informações adicionais sobre a estrutura da matriz são consideradas de forma a reduzir o esforço computacional do método numérico.

---

Na aula de hoje, apresentaremos a fatoração de Cholesky que pode ser usada como alternativa para a fatoração LU quando a matriz do sistema linear é simétrica e definida positiva.

O método da eliminação de Gauss e a Fatoração LU podem ser adaptados para certos tipos de matrizes que surgem em muitas situações práticas.

---

Nesse casos, informações adicionais sobre a estrutura da matriz são consideradas de forma a reduzir o esforço computacional do método numérico.

---

Na aula de hoje, apresentaremos a fatoração de Cholesky que pode ser usada como alternativa para a fatoração LU quando a matriz do sistema linear é simétrica e definida positiva.

---

# Matriz Simétrica

---

## Definição 1 (Matriz Simétrica)

Uma matriz  $\mathbf{A} \in \mathbb{R}^{n \times n}$  é simétrica se  $\mathbf{A}^T = \mathbf{A}$ , ou seja,

$$a_{ij} = a_{ji}, \quad \forall i, j = 1, \dots, n.$$

# Matriz Simétrica

## Definição 1 (Matriz Simétrica)

Uma matriz  $\mathbf{A} \in \mathbb{R}^{n \times n}$  é simétrica se  $\mathbf{A}^T = \mathbf{A}$ , ou seja,

$$a_{ij} = a_{ji}, \quad \forall i, j = 1, \dots, n.$$

## Exemplo 2

Determine quais matrizes são simétricas:

$$\mathbf{A} = \begin{bmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{bmatrix}, \quad \mathbf{B} = \begin{bmatrix} 7 & 2 & 0 \\ 3 & 5 & -1 \\ 0 & 5 & -6 \end{bmatrix} \quad \text{e} \quad \mathbf{C} = \begin{bmatrix} 6 & 4 & -3 \\ 4 & -2 & 0 \\ -3 & 0 & 1 \end{bmatrix}.$$

# Matriz Simétrica

## Definição 1 (Matriz Simétrica)

Uma matriz  $\mathbf{A} \in \mathbb{R}^{n \times n}$  é simétrica se  $\mathbf{A}^T = \mathbf{A}$ , ou seja,

$$a_{ij} = a_{ji}, \quad \forall i, j = 1, \dots, n.$$

## Exemplo 2

Determine quais matrizes são simétricas:

$$\mathbf{A} = \begin{bmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{bmatrix}, \quad \mathbf{B} = \begin{bmatrix} 7 & 2 & 0 \\ 3 & 5 & -1 \\ 0 & 5 & -6 \end{bmatrix} \quad \text{e} \quad \mathbf{C} = \begin{bmatrix} 6 & 4 & -3 \\ 4 & -2 & 0 \\ -3 & 0 & 1 \end{bmatrix}.$$

**Resposta:** As matrizes  $\mathbf{A}$  e  $\mathbf{C}$  são simétricas.

# Matriz Definida Positiva

---

## Definição 3 (Matriz Definida Positiva)

Uma matriz  $\mathbf{A} \in \mathbb{R}^{n \times n}$  é definida positiva se  $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0$  para todo  $\mathbf{x} \in \mathbb{R}^n$ ,  $\mathbf{x} \neq \mathbf{0}$ .

# Matriz Definida Positiva

---

## Definição 3 (Matriz Definida Positiva)

Uma matriz  $\mathbf{A} \in \mathbb{R}^{n \times n}$  é definida positiva se  $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0$  para todo  $\mathbf{x} \in \mathbb{R}^n$ ,  $\mathbf{x} \neq \mathbf{0}$ .

## Teorema 4 (Decomposição de Cholesky)

*Uma matriz  $\mathbf{A} \in \mathbb{R}^{n \times n}$  é simétrica e definida positiva se e somente se  $\mathbf{A}$  pode ser decomposta de forma única no produto  $\mathbf{G}^T \mathbf{G}$ , em que  $\mathbf{G}$  é uma matriz triangular superior com diagonal positiva.*

Pode-se demonstrar o teorema acima usando a fatoração LU.

# Matriz Definida Positiva

---

## Definição 3 (Matriz Definida Positiva)

Uma matriz  $\mathbf{A} \in \mathbb{R}^{n \times n}$  é definida positiva se  $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0$  para todo  $\mathbf{x} \in \mathbb{R}^n$ ,  $\mathbf{x} \neq \mathbf{0}$ .

## Teorema 4 (Decomposição de Cholesky)

*Uma matriz  $\mathbf{A} \in \mathbb{R}^{n \times n}$  é simétrica e definida positiva se e somente se  $\mathbf{A}$  pode ser decomposta de forma única no produto  $\mathbf{G}^T \mathbf{G}$ , em que  $\mathbf{G}$  é uma matriz triangular superior com diagonal positiva.*

Pode-se demonstrar o teorema acima usando a fatoração LU.

---

A demonstração pode ser encontrada em: “*Cálculo Numérico – Aspectos Teóricos e Computacionais*, M. Ruggiero e V. Lopes, 2a edição, Editora Pearson, 1997.”

# Cálculo do Fator de Cholesky

---

Seja  $\mathbf{A} \in \mathbb{R}^{n \times n}$  uma matriz simétrica e definida positiva.

# Cálculo do Fator de Cholesky

---

Seja  $\mathbf{A} \in \mathbb{R}^{n \times n}$  uma matriz simétrica e definida positiva.

---

Vamos admitir que podemos escrever  $\mathbf{A} = \mathbf{G}^T \mathbf{G}$ , ou seja,

$$\begin{bmatrix} a_{11} & a_{21} & \dots & a_{n1} \\ a_{21} & a_{22} & \dots & a_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix} = \begin{bmatrix} g_{11} & & & \\ g_{12} & g_{22} & & \\ \vdots & \vdots & \ddots & \\ g_{1n} & g_{2n} & \dots & g_{nn} \end{bmatrix} \begin{bmatrix} g_{11} & g_{12} & \dots & g_{1n} \\ & g_{22} & \dots & g_{2n} \\ & & \ddots & \vdots \\ & & & g_{nn} \end{bmatrix}$$

# Cálculo do Fator de Cholesky

---

Seja  $\mathbf{A} \in \mathbb{R}^{n \times n}$  uma matriz simétrica e definida positiva.

---

Vamos admitir que podemos escrever  $\mathbf{A} = \mathbf{G}^T \mathbf{G}$ , ou seja,

$$\begin{bmatrix} a_{11} & a_{21} & \dots & a_{n1} \\ a_{21} & a_{22} & \dots & a_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix} = \begin{bmatrix} g_{11} & & & \\ g_{12} & g_{22} & & \\ \vdots & \vdots & \ddots & \\ g_{1n} & g_{2n} & \dots & g_{nn} \end{bmatrix} \begin{bmatrix} g_{11} & g_{12} & \dots & g_{1n} \\ & g_{22} & \dots & g_{2n} \\ & & \ddots & \vdots \\ & & & g_{nn} \end{bmatrix}$$

---

Identificando as matrizes do lado esquerdo e direito da equação por por colunas, encontramos:

- Primeira coluna:

$$\begin{bmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{n1} \end{bmatrix} = \begin{bmatrix} g_{11} & & & & \\ g_{12} & g_{22} & & & \\ \vdots & \vdots & \ddots & & \\ g_{1n} & g_{2n} & \dots & g_{nn} & \end{bmatrix} \begin{bmatrix} g_{11} \\ 0 \\ \vdots \\ 0 \end{bmatrix} = \begin{bmatrix} g_{11}^2 \\ g_{12}g_{11} \\ \vdots \\ g_{1n}g_{11} \end{bmatrix}$$

- Primeira coluna:

$$\begin{bmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{n1} \end{bmatrix} = \begin{bmatrix} g_{11} & & & \\ g_{12} & g_{22} & & \\ \vdots & \vdots & \ddots & \\ g_{1n} & g_{2n} & \dots & g_{nn} \end{bmatrix} \begin{bmatrix} g_{11} \\ 0 \\ \vdots \\ 0 \end{bmatrix} = \begin{bmatrix} g_{11}^2 \\ g_{12}g_{11} \\ \vdots \\ g_{1n}g_{11} \end{bmatrix}$$

Logo,

$$g_{11} = \sqrt{a_{11}} \quad \text{e} \quad g_{1j} = \frac{a_{1j}}{g_{11}}, \quad j = 2, \dots, n.$$

- Segunda columna:

$$\begin{bmatrix} a_{12} \\ a_{22} \\ a_{32} \\ \vdots \\ a_{n2} \end{bmatrix} = \begin{bmatrix} g_{11} & & & & \\ g_{12} & g_{22} & & & \\ g_{13} & g_{23} & g_{33} & & \\ \vdots & \vdots & & \ddots & \\ g_{1n} & g_{2n} & g_{3n} & \dots & g_{nn} \end{bmatrix} \begin{bmatrix} g_{12} \\ g_{22} \\ 0 \\ \vdots \\ 0 \end{bmatrix} = \begin{bmatrix} g_{11}g_{12} \\ g_{12}^2 + g_{22}^2 \\ g_{13}g_{12} + g_{23}g_{22} \\ \vdots \\ g_{1n}g_{12} + g_{2n}g_{22} \end{bmatrix}$$

- Segunda coluna:

$$\begin{bmatrix} a_{12} \\ a_{22} \\ a_{32} \\ \vdots \\ a_{n2} \end{bmatrix} = \begin{bmatrix} g_{11} & & & & \\ g_{12} & g_{22} & & & \\ g_{13} & g_{23} & g_{33} & & \\ \vdots & \vdots & & \ddots & \\ g_{1n} & g_{2n} & g_{3n} & \dots & g_{nn} \end{bmatrix} \begin{bmatrix} g_{12} \\ g_{22} \\ 0 \\ \vdots \\ 0 \end{bmatrix} = \begin{bmatrix} g_{11}g_{12} \\ g_{12}^2 + g_{22}^2 \\ g_{13}g_{12} + g_{23}g_{22} \\ \vdots \\ g_{1n}g_{12} + g_{2n}g_{22} \end{bmatrix}$$

Logo,

$$g_{22} = \sqrt{a_{22} - g_{12}^2} \quad \text{e} \quad g_{2j} = \frac{a_{2j} - g_{1j}g_{12}}{g_{22}}, \quad j = 3, \dots, n.$$

- $i$ -ésima columna:

$$\begin{bmatrix} a_{1i} \\ \vdots \\ a_{ij} \\ \vdots \\ a_{ji} \\ \vdots \\ a_{ni} \end{bmatrix} = \begin{bmatrix} g_{11} & & & & & & \\ & \ddots & & & & & \\ & & g_{1i} & \dots & g_{ii} & & \\ & & \vdots & \dots & \vdots & \ddots & \\ & & g_{1j} & \dots & g_{ij} & \dots & g_{jj} \\ & & \vdots & & \vdots & & \vdots \\ & & g_{1n} & \dots & g_{in} & \dots & g_{jn} & \dots & g_{nn} \end{bmatrix} \begin{bmatrix} g_{1i} \\ \vdots \\ g_{ii} \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

- $i$ -ésima columna:

$$\begin{bmatrix} a_{1i} \\ \vdots \\ a_{ij} \\ \vdots \\ a_{ji} \\ \vdots \\ a_{ni} \end{bmatrix} = \begin{bmatrix} g_{11} & & & & & & \\ & \ddots & & & & & \\ & & g_{1i} & \cdots & g_{ii} & & \\ & & \vdots & \cdots & \vdots & \ddots & \\ & & g_{1j} & \cdots & g_{ij} & \cdots & g_{jj} \\ & & \vdots & & \vdots & & \vdots \\ & & g_{1n} & \cdots & g_{in} & \cdots & g_{jn} & \cdots & g_{nn} \end{bmatrix} \begin{bmatrix} g_{1i} \\ \vdots \\ g_{ii} \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$a_{ij} = g_{1i}^2 + \cdots + g_{i-1,i}^2 + g_{ii}^2 \implies g_{ii} = \sqrt{a_{ii} - \sum_{k=1}^{i-1} g_{ki}^2}$$

- $i$ -ésima columna:

$$\begin{bmatrix} a_{1i} \\ \vdots \\ a_{ij} \\ \vdots \\ a_{ji} \\ \vdots \\ a_{ni} \end{bmatrix} = \begin{bmatrix} g_{11} & & & & & & \\ & \ddots & & & & & \\ & & g_{1i} & \dots & g_{ii} & & \\ & & \vdots & \dots & \vdots & \ddots & \\ & & g_{1j} & \dots & g_{ij} & \dots & g_{jj} \\ & & \vdots & & \vdots & & \vdots \\ g_{1n} & \dots & g_{in} & \dots & g_{jn} & \dots & g_{nn} \end{bmatrix} \begin{bmatrix} g_{1i} \\ \vdots \\ g_{ii} \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$a_{ii} = g_{1i}^2 + \dots + g_{i-1,i}^2 + g_{ii}^2 \implies g_{ii} = \sqrt{a_{ii} - \sum_{k=1}^{i-1} g_{ki}^2},$$

$$a_{ji} = a_{ij} = g_{1j}g_{1i} + \dots + g_{ij}g_{ii} \implies g_{ij} = \frac{1}{g_{ii}} \left( a_{ij} - \sum_{k=1}^{i-1} g_{kj}g_{ki} \right),$$

para  $j = i + 1, \dots, n$ .

# Fatoração de Cholesky

---

**Entrada:** Matriz  $\mathbf{A} \in \mathbb{R}^{n \times n}$  simétrica e definida positiva.

**para**  $i = 1 : n$  **faça**

- $g_{ii} = \sqrt{a_{ii} - \sum_{k=1}^{i-1} g_{ki}^2}$ .

**para**  $j = i + 1 : n$  **faça**

- $g_{ij} = \frac{1}{g_{ii}} \left( a_{ij} - \sum_{k=1}^{i-1} g_{kj} g_{ki} \right)$ .

**fim**

**fim**

**Saída:** Matriz  $\mathbf{G}$  triangular superior com diagonal positiva.

---

## Exemplo 5

Determine, se possível, a fatoração de Cholesky das matrizes

$$\mathbf{A} = \begin{bmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{bmatrix} \quad \text{e} \quad \mathbf{C} = \begin{bmatrix} 6 & 4 & -3 \\ 4 & -2 & 0 \\ -3 & 0 & 1 \end{bmatrix}.$$

## Exemplo 5

Determine, se possível, a fatoração de Cholesky das matrizes

$$\mathbf{A} = \begin{bmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{bmatrix} \quad \text{e} \quad \mathbf{C} = \begin{bmatrix} 6 & 4 & -3 \\ 4 & -2 & 0 \\ -3 & 0 & 1 \end{bmatrix}.$$

**Resposta:** Vamos calcular a fatoração de Cholesky de  $\mathbf{A}$ .

Primeiro, calculamos os elementos

$$g_{11} = \sqrt{a_{11}} = \sqrt{2}, \quad g_{12} = \frac{a_{12}}{g_{11}} = \frac{-1}{\sqrt{2}} \quad \text{e} \quad g_{13} = \frac{a_{13}}{g_{11}} = 0.$$

Primeiro, calculamos os elementos

$$g_{11} = \sqrt{a_{11}} = \sqrt{2}, \quad g_{12} = \frac{a_{12}}{g_{11}} = \frac{-1}{\sqrt{2}} \quad \text{e} \quad g_{13} = \frac{a_{13}}{g_{11}} = 0.$$

Depois, calculamos os elementos

$$g_{22} = \sqrt{a_{22} - g_{12}^2} = \sqrt{2 - (1/2)} = \sqrt{\frac{3}{2}},$$

Primeiro, calculamos os elementos

$$g_{11} = \sqrt{a_{11}} = \sqrt{2}, \quad g_{12} = \frac{a_{12}}{g_{11}} = \frac{-1}{\sqrt{2}} \quad \text{e} \quad g_{13} = \frac{a_{13}}{g_{11}} = 0.$$

Depois, calculamos os elementos

$$g_{22} = \sqrt{a_{22} - g_{12}^2} = \sqrt{2 - (1/2)} = \sqrt{\frac{3}{2}},$$

e

$$g_{23} = \frac{a_{23} - g_{13}g_{12}}{g_{22}} = \frac{-1 - 0 \cdot (-\sqrt{2}/2)}{\sqrt{3}/2} = -\sqrt{\frac{2}{3}}.$$

Primeiro, calculamos os elementos

$$g_{11} = \sqrt{a_{11}} = \sqrt{2}, \quad g_{12} = \frac{a_{12}}{g_{11}} = \frac{-1}{\sqrt{2}} \quad \text{e} \quad g_{13} = \frac{a_{13}}{g_{11}} = 0.$$

Depois, calculamos os elementos

$$g_{22} = \sqrt{a_{22} - g_{12}^2} = \sqrt{2 - (1/2)} = \sqrt{\frac{3}{2}},$$

e

$$g_{23} = \frac{a_{23} - g_{13}g_{12}}{g_{22}} = \frac{-1 - 0 \cdot (-\sqrt{2}/2)}{\sqrt{3}/2} = -\sqrt{\frac{2}{3}}.$$

Finalmente, calculamos

$$g_{33} = \sqrt{a_{33} - g_{13}^2 - g_{23}^2} = \sqrt{2 - 0^2 - 2/3} = \frac{\sqrt{2}}{3}.$$

Portanto, temos  $\mathbf{A} = \mathbf{G}^T \mathbf{G}$  em que

$$\mathbf{G} = \begin{bmatrix} \sqrt{2} & \frac{-1}{\sqrt{2}} & 0 \\ \sqrt{\frac{3}{2}} & \frac{2}{\sqrt{3}} & -\sqrt{\frac{2}{3}} \end{bmatrix}.$$

Vamos agora calcular a fatoração de Cholesky de **C**.

Vamos agora calcular a fatoração de Cholesky de **C**.  
Primeiro, temos

$$g_{11} = \sqrt{6}, \quad g_{12} = \frac{c_{12}}{g_{11}} = \frac{4}{\sqrt{6}} \quad \text{e} \quad g_{13} = \frac{c_{13}}{g_{11}} = \frac{-3}{\sqrt{6}}.$$

Vamos agora calcular a fatoração de Cholesky de **C**.  
Primeiro, temos

$$g_{11} = \sqrt{6}, \quad g_{12} = \frac{c_{12}}{g_{11}} = \frac{4}{\sqrt{6}} \quad \text{e} \quad g_{13} = \frac{c_{13}}{g_{11}} = \frac{-3}{\sqrt{6}}.$$

Depois, precisamos calcular

$$g_{22} = \sqrt{c_{22} - g_{12}^2} = \sqrt{-2 - 4^2/6}.$$

Vamos agora calcular a fatoração de Cholesky de **C**.  
Primeiro, temos

$$g_{11} = \sqrt{6}, \quad g_{12} = \frac{c_{12}}{g_{11}} = \frac{4}{\sqrt{6}} \quad \text{e} \quad g_{13} = \frac{c_{13}}{g_{11}} = \frac{-3}{\sqrt{6}}.$$

Depois, precisamos calcular

$$g_{22} = \sqrt{c_{22} - g_{12}^2} = \sqrt{-2 - 4^2/6}.$$

Note que devemos calcular a raiz de um número negativo, o que não é possível usando os números reais.

Vamos agora calcular a fatoração de Cholesky de **C**.  
Primeiro, temos

$$g_{11} = \sqrt{6}, \quad g_{12} = \frac{c_{12}}{g_{11}} = \frac{4}{\sqrt{6}} \quad \text{e} \quad g_{13} = \frac{c_{13}}{g_{11}} = \frac{-3}{\sqrt{6}}.$$

Depois, precisamos calcular

$$g_{22} = \sqrt{c_{22} - g_{12}^2} = \sqrt{-2 - 4^2/6}.$$

Note que devemos calcular a raiz de um número negativo, o que não é possível usando os números reais.

---

Logo, embora simétrica, a matriz **C** não é definida positiva.

A fatoração de Cholesky pode ser usada para verificar se uma matriz é simétrica e definida positiva; se o método falhar, a hipótese é falsa!

---

<sup>1</sup>`from scipy.linalg import cholesky.`

A fatoração de Cholesky pode ser usada para verificar se uma matriz é simétrica e definida positiva; se o método falhar, a hipótese é falsa!

---

A fatoração de Cholesky requer a metade do número de operações efetuadas na fatoração LU!

---

<sup>1</sup>from scipy.linalg import cholesky.

A fatoração de Cholesky pode ser usada para verificar se uma matriz é simétrica e definida positiva; se o método falhar, a hipótese é falsa!

---

A fatoração de Cholesky requer a metade do número de operações efetuadas na fatoração LU!

---

Conhecendo a fatoração de Cholesky, o sistema  $\mathbf{Ax} = \mathbf{b}$  é resolvido em dois estágios:

1.  $\mathbf{G}^T \mathbf{y} = \mathbf{b}$ .
2.  $\mathbf{Gx} = \mathbf{y}$ .

---

<sup>1</sup>from scipy.linalg import cholesky.

A fatoração de Cholesky pode ser usada para verificar se uma matriz é simétrica e definida positiva; se o método falhar, a hipótese é falsa!

---

A fatoração de Cholesky requer a metade do número de operações efetuadas na fatoração LU!

---

Conhecendo a fatoração de Cholesky, o sistema  $\mathbf{Ax} = \mathbf{b}$  é resolvido em dois estágios:

1.  $\mathbf{G}^T \mathbf{y} = \mathbf{b}$ .
  2.  $\mathbf{Gx} = \mathbf{y}$ .
- 

No Python, a fatoração de Cholesky de uma matriz  $\mathbf{A}$  simétrica e definida positiva é obtida através do comando:

```
» G = cholesky(A)  
da biblioteca Scipy1.
```

---

<sup>1</sup>from scipy.linalg import cholesky.

## Parte 2

### Condicionamento de uma Matriz

Nas primeiras aulas, falamos sobre os erros de arredondamento na representação de ponto flutuante e suas operações aritméticas.

Nas primeiras aulas, falamos sobre os erros de arredondamento na representação de ponto flutuante e suas operações aritméticas.

---

Em termos gerais, erros sempre existirão quando resolvemos um problema contínuo (e.g. em  $\mathbb{R}$ ) num computador.

Nas primeiras aulas, falamos sobre os erros de arredondamento na representação de ponto flutuante e suas operações aritméticas.

---

Em termos gerais, erros sempre existirão quando resolvemos um problema contínuo (e.g. em  $\mathbb{R}$ ) num computador.

---

Consequentemente, um método numérico raramente produz a solução exata de um problema matemático contínuo.

Nas primeiras aulas, falamos sobre os erros de arredondamento na representação de ponto flutuante e suas operações aritméticas.

---

Em termos gerais, erros sempre existirão quando resolvemos um problema contínuo (e.g. em  $\mathbb{R}$ ) num computador.

---

Consequentemente, um método numérico raramente produz a solução exata de um problema matemático contínuo.

---

Na aula de hoje, veremos quando o arredondamento em ponto flutuante e suas operações aritméticas influenciam na credibilidade do resultado produzido por um método para a resolução de um sistema linear.

Nas primeiras aulas, falamos sobre os erros de arredondamento na representação de ponto flutuante e suas operações aritméticas.

---

Em termos gerais, erros sempre existirão quando resolvemos um problema contínuo (e.g. em  $\mathbb{R}$ ) num computador.

---

Consequentemente, um método numérico raramente produz a solução exata de um problema matemático contínuo.

---

Na aula de hoje, veremos quando o arredondamento em ponto flutuante e suas operações aritméticas influenciam na credibilidade do resultado produzido por um método para a resolução de um sistema linear.

---

Iniciaremos apresentando a definição de norma, conceito matemático utilizado para medir tamanho ou distância.

# Norma Vetorial

---

## Norma Vetorial

Uma norma vetorial associa um vetor  $\mathbf{x} \in [x_1, \dots, x_n]^T \in \mathbb{R}^n$  à um número real não-negativo denotado por  $\|\mathbf{x}\|$ .

Exemplos de normas vetoriais incluem:

- $\|\mathbf{x}\|_1 = \sum_{i=1}^n |x_i| = |x_1| + |x_2| + \dots + |x_n|$ .

# Norma Vetorial

## Norma Vetorial

Uma norma vetorial associa um vetor  $\mathbf{x} \in [x_1, \dots, x_n]^T \in \mathbb{R}^n$  à um número real não-negativo denotado por  $\|\mathbf{x}\|$ .

Exemplos de normas vetoriais incluem:

- $\|\mathbf{x}\|_1 = \sum_{i=1}^n |x_i| = |x_1| + |x_2| + \dots + |x_n|$ .
- $\|\mathbf{x}\|_2 = \sqrt{\sum_{i=1}^n x_i^2} = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2}$ . (norma Euclidiana)

# Norma Vetorial

## Norma Vetorial

Uma norma vetorial associa um vetor  $\mathbf{x} \in [x_1, \dots, x_n]^T \in \mathbb{R}^n$  à um número real não-negativo denotado por  $\|\mathbf{x}\|$ .

Exemplos de normas vetoriais incluem:

- $\|\mathbf{x}\|_1 = \sum_{i=1}^n |x_i| = |x_1| + |x_2| + \dots + |x_n|$ .
- $\|\mathbf{x}\|_2 = \sqrt{\sum_{i=1}^n x_i^2} = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2}$ . (norma Euclidiana)
- $\|\mathbf{x}\|_\infty = \max_{i=1:n} \{|x_i|\} = \max\{|x_1|, |x_2|, \dots, |x_n|\}$ .

## Exemplo 6

Para o vetor  $\mathbf{x} = [3, -4]^T$ , temos:

$$\|\mathbf{x}\|_1 = |3| + |-4| = 7,$$

$$\|\mathbf{x}\|_2 = \sqrt{3^2 + (-4)^2} = 5,$$

$$\|\mathbf{x}\|_\infty = \max\{|3|, |-4|\} = 4.$$

## Exemplo 6

Para o vetor  $\mathbf{x} = [3, -4]^T$ , temos:

$$\|\mathbf{x}\|_1 = |3| + |-4| = 7,$$

$$\|\mathbf{x}\|_2 = \sqrt{3^2 + (-4)^2} = 5,$$

$$\|\mathbf{x}\|_\infty = \max\{|3|, |-4|\} = 4.$$

No `python`, podemos calcular as normas  $\|\cdot\|_1$ ,  $\|\cdot\|_2$  e  $\|\cdot\|_\infty$  de um vetor  $\mathbf{x}$  usando os comandos da biblioteca `numpy` (`np`):

```
» np.linalg.norm(x, 1)
```

```
» np.linalg.norm(x) ou » np.linalg.norm(x, 2)
```

```
» np.linalg.norm(x, np.inf)
```

respectivamente.

# Norma Matricial

## Norma Matricial

Uma norma matricial associa uma matriz  $\mathbf{A} \in \mathbb{R}^{m \times n}$  a um número real não-negativo denotado por  $\|\mathbf{A}\|$ .

Exemplos de normas matriciais incluem:

- A norma de Frobenius de uma matriz  $\mathbf{A}$  é dada por:

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n a_{ij}^2}.$$

Usando a biblioteca `numpy` (`np`) em `python`, o comando `np.linalg.norm(A)` fornece a norma de Frobenius de  $\mathbf{A}$ .

- $\|\mathbf{A}\|_1$  é o valor máximo da soma dos valores absolutos das colunas de  $\mathbf{A}$ , ou seja,

$$\|\mathbf{A}\|_1 = \max\{\|\mathbf{a}_1\|_1, \dots, \|\mathbf{a}_n\|_1\} = \max_{j=1:n} \left\{ \sum_{i=1}^m |a_{ij}| \right\}.$$

No `python`, usamos o comando `np.linalg.norm(A, 1)`.

- $\|\mathbf{A}\|_2$  é o maior valor singular de matriz  $\mathbf{A}$ . No `python`, usamos o comando `np.linalg.norm(A, 2)`.
- $\|\mathbf{A}\|_\infty$  é o valor máximo da soma dos valores absolutos das linhas de  $\mathbf{A}$ , ou seja,

$$\|\mathbf{A}\|_\infty = \max\{\|\mathbf{a}_1^T\|_1, \dots, \|\mathbf{a}_m^T\|_1\} = \max_{i=1:m} \left\{ \sum_{j=1}^n |a_{ij}| \right\},$$

em que  $\mathbf{a}_i^T$  denota a  $i$ -ésima linha de  $\mathbf{A}$ . No `python`, usamos o comando `np.linalg.norm(A, inf)`.

# Erro Absoluto e Erro Relativo

---

Suponha que resolvemos um sistema linear  $\mathbf{Ax} = \mathbf{b}$ , em que  $\mathbf{A} \in \mathbb{R}^{n \times n}$  é uma matriz não-singular e  $\mathbf{b} \in \mathbb{R}^n$ , usando um método numérico como, por exemplo, o método da eliminação de Gauss.

# Erro Absoluto e Erro Relativo

---

Suponha que resolvemos um sistema linear  $\mathbf{Ax} = \mathbf{b}$ , em que  $\mathbf{A} \in \mathbb{R}^{n \times n}$  é uma matriz não-singular e  $\mathbf{b} \in \mathbb{R}^n$ , usando um método numérico como, por exemplo, o método da eliminação de Gauss.

---

Vamos denotar por  $\tilde{\mathbf{x}}$  a solução encontrada pelo método numérico e  $\mathbf{x}^* = \mathbf{A}^{-1}\mathbf{b}$  a solução exata.

# Erro Absoluto e Erro Relativo

---

Suponha que resolvemos um sistema linear  $\mathbf{Ax} = \mathbf{b}$ , em que  $\mathbf{A} \in \mathbb{R}^{n \times n}$  é uma matriz não-singular e  $\mathbf{b} \in \mathbb{R}^n$ , usando um método numérico como, por exemplo, o método da eliminação de Gauss.

---

Vamos denotar por  $\tilde{\mathbf{x}}$  a solução encontrada pelo método numérico e  $\mathbf{x}^* = \mathbf{A}^{-1}\mathbf{b}$  a solução exata.

---

Para avaliar a qualidade da solução produzida pelo método numérico, comparamos a solução numérica  $\tilde{\mathbf{x}}$  com a solução exata  $\mathbf{x}^*$  usando uma norma vetorial. Especificamente, calculamos o erro absoluto  $E_a$  ou o erro relativo  $E_r$  dados por:

$$E_a = \|\mathbf{x}^* - \tilde{\mathbf{x}}\| \quad \text{e} \quad E_r = \frac{\|\mathbf{x}^* - \tilde{\mathbf{x}}\|}{\|\mathbf{x}^*\|}.$$

# Resíduo

---

Na prática, não conhecemos a solução exata  $\mathbf{x}^*$  do sistema linear  $\mathbf{Ax} = \mathbf{b}$ . Portanto, não podemos calcular o erro.

# Resíduo

---

Na prática, não conhecemos a solução exata  $\mathbf{x}^*$  do sistema linear  $\mathbf{Ax} = \mathbf{b}$ . Portanto, não podemos calcular o erro.

---

Como alternativa, calculamos o chamado **resíduo absoluto**  $R_a$  ou o **resíduo relativo**  $R_r$  definidos por

$$R_a = \|\mathbf{b} - \mathbf{A}\tilde{\mathbf{x}}\| \quad \text{e} \quad R_r = \frac{\|\mathbf{b} - \mathbf{A}\tilde{\mathbf{x}}\|}{\|\mathbf{b}\|}.$$

# Resíduo

---

Na prática, não conhecemos a solução exata  $\mathbf{x}^*$  do sistema linear  $\mathbf{Ax} = \mathbf{b}$ . Portanto, não podemos calcular o erro.

---

Como alternativa, calculamos o chamado **resíduo absoluto**  $R_a$  ou o **resíduo relativo**  $R_r$  definidos por

$$R_a = \|\mathbf{b} - \mathbf{A}\tilde{\mathbf{x}}\| \quad \text{e} \quad R_r = \frac{\|\mathbf{b} - \mathbf{A}\tilde{\mathbf{x}}\|}{\|\mathbf{b}\|}.$$

---

Em algumas situações, é conveniente definir os vetores

$$\mathbf{e} = \mathbf{x}^* - \tilde{\mathbf{x}} \quad \text{e} \quad \mathbf{r} = \mathbf{b} - \mathbf{A}\tilde{\mathbf{x}},$$

chamados respectivamente **erro** e **resíduo**.

# Matriz Gerada Aleatoriamente

---

Para avaliar a qualidade da solução de um sistema linear  $\mathbf{Ax} = \mathbf{b}$  produzida pelo método da eliminação de Gauss, geramos uma matriz  $\mathbf{A} \in \mathbb{R}^{100 \times 100}$  cujos elementos  $a_{ij}$  possuem distribuição normal padrão.

# Matriz Gerada Aleatoriamente

---

Para avaliar a qualidade da solução de um sistema linear  $\mathbf{Ax} = \mathbf{b}$  produzida pelo método da eliminação de Gauss, geramos uma matriz  $\mathbf{A} \in \mathbb{R}^{100 \times 100}$  cujos elementos  $a_{ij}$  possuem distribuição normal padrão.

---

Além disso, definimos  $\mathbf{x}^* = [1, \dots, 1]^T$  e  $\mathbf{b} = \mathbf{Ax}^*$ .

# Matriz Gerada Aleatoriamente

---

Para avaliar a qualidade da solução de um sistema linear  $\mathbf{Ax} = \mathbf{b}$  produzida pelo método da eliminação de Gauss, geramos uma matriz  $\mathbf{A} \in \mathbb{R}^{100 \times 100}$  cujos elementos  $a_{ij}$  possuem distribuição normal padrão.

---

Além disso, definimos  $\mathbf{x}^* = [1, \dots, 1]^T$  e  $\mathbf{b} = \mathbf{Ax}^*$ .

---

Determinamos a solução numérica  $\tilde{\mathbf{x}}$  usando o método da eliminação de Gauss e calculamos o erro e o resíduo relativo.

# Matriz Gerada Aleatoriamente

---

Para avaliar a qualidade da solução de um sistema linear  $\mathbf{Ax} = \mathbf{b}$  produzida pelo método da eliminação de Gauss, geramos uma matriz  $\mathbf{A} \in \mathbb{R}^{100 \times 100}$  cujos elementos  $a_{ij}$  possuem distribuição normal padrão.

---

Além disso, definimos  $\mathbf{x}^* = [1, \dots, 1]^T$  e  $\mathbf{b} = \mathbf{Ax}^*$ .

---

Determinamos a solução numérica  $\tilde{\mathbf{x}}$  usando o método da eliminação de Gauss e calculamos o erro e o resíduo relativo.

---

Repetimos o processo 1000 vezes. A média dos erros e resíduos relativos foram  $6.10 \times 10^{-14}$  e  $1.54 \times 10^{-15}$ , respectivamente.

# Matriz Gerada Aleatoriamente

---

Para avaliar a qualidade da solução de um sistema linear  $\mathbf{Ax} = \mathbf{b}$  produzida pelo método da eliminação de Gauss, geramos uma matriz  $\mathbf{A} \in \mathbb{R}^{100 \times 100}$  cujos elementos  $a_{ij}$  possuem distribuição normal padrão.

---

Além disso, definimos  $\mathbf{x}^* = [1, \dots, 1]^T$  e  $\mathbf{b} = \mathbf{Ax}^*$ .

---

Determinamos a solução numérica  $\tilde{\mathbf{x}}$  usando o método da eliminação de Gauss e calculamos o erro e o resíduo relativo.

---

Repetimos o processo 1000 vezes. A média dos erros e resíduos relativos foram  $6.10 \times 10^{-14}$  e  $1.54 \times 10^{-15}$ , respectivamente.

---

Note que o resíduo forneceu uma boa estimativa para o erro!

## Comandos do python

---

```
import numpy as np
Er = list()
Rr = list()
for i in range(1000):
    A = np.random.randn(100,100)
    xs = np.ones((100,1))
    b = A@xs
    xt = np.linalg.solve(A,b)
    Ea = np.linalg.norm(xs-xt)
    Er.append(Ea/np.linalg.norm(xs))
    Ra = np.linalg.norm(b-A@xt)
    Rr.append(Ra/np.linalg.norm(b))
np.mean(Er), np.mean(Rr)
```

# Matriz de Hilbert

---

Considere a matriz  $\mathbf{A} \in \mathbb{R}^{100 \times 100}$  cujos elementos são

$$a_{ij} = \frac{1}{i+j-1}.$$

# Matriz de Hilbert

---

Considere a matriz  $\mathbf{A} \in \mathbb{R}^{100 \times 100}$  cujos elementos são

$$a_{ij} = \frac{1}{i+j-1}.$$

Definimos  $\mathbf{x}^* = [1, \dots, 1]^T$ ,  $\mathbf{b} = \mathbf{Ax}^*$  e determinamos a solução numérica  $\tilde{\mathbf{x}}$  usando o método da eliminação de Gauss.

# Matriz de Hilbert

---

Considere a matriz  $\mathbf{A} \in \mathbb{R}^{100 \times 100}$  cujos elementos são

$$a_{ij} = \frac{1}{i+j-1}.$$

Definimos  $\mathbf{x}^* = [1, \dots, 1]^T$ ,  $\mathbf{b} = \mathbf{A}\mathbf{x}^*$  e determinamos a solução numérica  $\tilde{\mathbf{x}}$  usando o método da eliminação de Gauss.

---

O erro relativo e o resíduo relativo foram

$$E_r = \frac{\|\mathbf{x}^* - \tilde{\mathbf{x}}\|_2}{\|\mathbf{x}^*\|_2} = 78.19 \quad \text{e} \quad R_r = \frac{\|\mathbf{b} - \mathbf{A}\tilde{\mathbf{x}}\|_2}{\|\mathbf{b}\|_2} = 1.71 \times 10^{-15}.$$

# Matriz de Hilbert

---

Considere a matriz  $\mathbf{A} \in \mathbb{R}^{100 \times 100}$  cujos elementos são

$$a_{ij} = \frac{1}{i+j-1}.$$

Definimos  $\mathbf{x}^* = [1, \dots, 1]^T$ ,  $\mathbf{b} = \mathbf{Ax}^*$  e determinamos a solução numérica  $\tilde{\mathbf{x}}$  usando o método da eliminação de Gauss.

---

O erro relativo e o resíduo relativo foram

$$E_r = \frac{\|\mathbf{x}^* - \tilde{\mathbf{x}}\|_2}{\|\mathbf{x}^*\|_2} = 78.19 \quad \text{e} \quad R_r = \frac{\|\mathbf{b} - \mathbf{A}\tilde{\mathbf{x}}\|_2}{\|\mathbf{b}\|_2} = 1.71 \times 10^{-15}.$$

---

Ao contrário do exemplo anterior, temos resíduo relativo muito pequeno mas um erro relativo grande.

## Comandos do python

---

```
import numpy as np  
from scipy.linalg import hilbert
```

```
A = hilbert(100)  
xs = np.ones((100,1))  
b = A@xs  
xt = np.linalg.solve(A,b)
```

```
Ea = np.linalg.norm(xs-xt)  
Er = Ea/np.linalg.norm(xs)  
Ra = np.linalg.norm(b-A@xt)  
Rr = Ra/np.linalg.norm(b)
```

Er, Rr

# Sistemas Lineares Mal-Condicionados

---

Em termos gerais, um sistema linear  $\mathbf{Ax} = \mathbf{b}$  é mal-condicionado se pequenas perturbações na matriz  $\mathbf{A}$  ou no vetor  $\mathbf{b}$  causam grandes variações na solução.

# Sistemas Lineares Mal-Condicionados

---

Em termos gerais, um sistema linear  $\mathbf{Ax} = \mathbf{b}$  é mal-condicionado se pequenas perturbações na matriz  $\mathbf{A}$  ou no vetor  $\mathbf{b}$  causam grandes variações na solução.

---

Nesse caso, devido aos erros na representação e operações de pontos flutuantes, não devemos esperar uma solução precisa de um método numérico!

# Sistemas Lineares Mal-Condicionados

---

Em termos gerais, um sistema linear  $\mathbf{Ax} = \mathbf{b}$  é mal-condicionado se pequenas perturbações na matriz  $\mathbf{A}$  ou no vetor  $\mathbf{b}$  causam grandes variações na solução.

---

Nesse caso, devido aos erros na representação e operações de pontos flutuantes, não devemos esperar uma solução precisa de um método numérico!

---

Além disso, num sistema linear mal-condicionado, o resíduo pode não revelar a natureza do erro!

# Sistemas Lineares Mal-Condicionados

---

Em termos gerais, um sistema linear  $\mathbf{Ax} = \mathbf{b}$  é mal-condicionado se pequenas perturbações na matriz  $\mathbf{A}$  ou no vetor  $\mathbf{b}$  causam grandes variações na solução.

---

Nesse caso, devido aos erros na representação e operações de pontos flutuantes, não devemos esperar uma solução precisa de um método numérico!

---

Além disso, num sistema linear mal-condicionado, o resíduo pode não revelar a natureza do erro!

---

O condicionamento de uma matriz  $\mathbf{A}$  é definido em termos de sua norma e a norma de sua inversa.

# Número de Condição de uma Matriz

---

O número de condição de uma matriz  $\mathbf{A}$ , também chamado condicionamento de  $\mathbf{A}$ , é definido por

$$\text{cond}(\mathbf{A}) = \|\mathbf{A}\| \|\mathbf{A}^{-1}\|.$$

## Relação entre $E_r$ e $R_r$ :

Vale a relação entre o erro relativo e o resíduo relativo:

$$E_r \leq \text{cond}(\mathbf{A}) R_r.$$

- Se  $\text{cond}(\mathbf{A})$  é próximo de 1, o erro relativo  $E_r$  e o resíduo relativo  $R_r$  tem magnitudes semelhantes.

# Número de Condição de uma Matriz

O número de condição de uma matriz  $\mathbf{A}$ , também chamado condicionamento de  $\mathbf{A}$ , é definido por

$$\text{cond}(\mathbf{A}) = \|\mathbf{A}\| \|\mathbf{A}^{-1}\|.$$

## Relação entre $E_r$ e $R_r$ :

Vale a relação entre o erro relativo e o resíduo relativo:

$$E_r \leq \text{cond}(\mathbf{A}) R_r.$$

- Se  $\text{cond}(\mathbf{A})$  é próximo de 1, o erro relativo  $E_r$  e o resíduo relativo  $R_r$  tem magnitudes semelhantes.
- Se  $\text{cond}(\mathbf{A})$  é grande, o erro relativo pode ser muito maior que o resíduo relativo.

O número de condição de uma matriz **A** pode ser calculada no python usando a biblioteca `numpy` comando:

```
» np.linalg.cond(A)
```

O número de condição de uma matriz **A** pode ser calculada no python usando a biblioteca `numpy` comando:

```
» np.linalg.cond(A)
```

---

Calculamos o condicionamento da matriz de Hilbert como segue:

```
» np.linalg.cond(hilbert(100))
```

```
1.15e+20
```

O número de condição de uma matriz  $\mathbf{A}$  pode ser calculada no python usando a biblioteca `numpy` comando:

```
» np.linalg.cond(A)
```

---

Calculamos o condicionamento da matriz de Hilbert como segue:

```
» np.linalg.cond(hilbert(100))  
1.15e+20
```

---

Com base nos números do exemplo anterior, temos

$$\underbrace{78.19}_{E_r} \leq \underbrace{1.15 \times 10^{20}}_{\text{cond}(\mathbf{A})} \cdot \underbrace{1.71 \times 10^{-15}}_{R_r} = 1.98 \times 10^5.$$

## Considerações Finais

---

Na aula de hoje apresentamos a fatoração de Cholesky: Uma matriz simétrica ( $\mathbf{A} = \mathbf{A}^T$ ) e definida positiva ( $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0$ ) é escrita como  $\mathbf{A} = \mathbf{G}^T \mathbf{G}$ , em que  $\mathbf{G}$  é triangular superior.

## Considerações Finais

---

Na aula de hoje apresentamos a fatoração de Cholesky: Uma matriz simétrica ( $\mathbf{A} = \mathbf{A}^T$ ) e definida positiva ( $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0$ ) é escrita como  $\mathbf{A} = \mathbf{G}^T \mathbf{G}$ , em que  $\mathbf{G}$  é triangular superior.

---

Na aula de hoje apresentamos também os conceitos de norma vetorial e norma matricial; e mostramos como esses conceitos podem ser usados para determinar o erro relativo de um sistema linear.

## Considerações Finais

---

Na aula de hoje apresentamos a fatoração de Cholesky: Uma matriz simétrica ( $\mathbf{A} = \mathbf{A}^T$ ) e definida positiva ( $\mathbf{x}^T \mathbf{A} \mathbf{x} > 0$ ) é escrita como  $\mathbf{A} = \mathbf{G}^T \mathbf{G}$ , em que  $\mathbf{G}$  é triangular superior.

---

Na aula de hoje apresentamos também os conceitos de norma vetorial e norma matricial; e mostramos como esses conceitos podem ser usados para determinar o erro relativo de um sistema linear.

---

Finalmente destacamos que se  $cond(\mathbf{A})$  é grande, dizemos que a matriz é mal-condicionada. Nesse caso, não podemos confiar na solução fornecida por um método numérico.

Muito grato pela atenção!