



Cálculo Numérico

Prof. Guilherme Amorim

26/11/2013

Aula 11 – Sistemas de Equações Lineares / Parte 4 Convergência e Sistemas mal-condicionados

Aula passada...

□ Métodos Iterativos

□ Jacobi

$$x_i^{(k+1)} = \left(b_i - \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij} x_j^{(k)} \right) / a_{ii}$$

□ Gauss-Seidel

$$x_i^{(k+1)} = \left[b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij} x_j^{(k)} \right] / a_{ii}$$

Pergunta...

- Como garantir (ou verificar) que as soluções através dos métodos de Jacobi e Gauss-Seidel convergem?
- Como verificar se pequenas alterações nos coeficientes levam a variações nos resultados do sistema?
- Hoje, vamos estudar:
 - ▣ Convergência de métodos iterativos
 - ▣ Sistemas mal-condicionados

Convergência

- Considerando o sistema de equações lineares na forma:

$$x^{(k+1)} = Bx^{(k)} + c$$

- Como garantir a convergência?

Revisão – Normas de Vetores

- Dado um espaço vetorial V , a norma é uma função que satisfaz aos seguintes postulados:
 - $\|x\| > 0$ se $x \neq 0$ e $\|x\| = 0$ se $x = 0$
 - $\|\lambda x\| = |\lambda| \cdot \|x\|$ se $\lambda \in \mathbb{R}$
 - $\|x + y\| \leq \|x\| + \|y\|$ se $x, y \in V$
 - Desigualdade triangular.
- A norma é uma medida do vetor no espaço

Revisão – Normas de Vetores

- Norma Euclidiana
 - $\|x\|_2 = \sqrt{\sum_{i=1}^n x_i^2}$
- Norma do Máximo
 - $\|x\|_\infty = \max_{1 \leq i \leq n} |x_i|$
- Norma da soma
 - $\|x\|_1 = \sum_{i=1}^n |x_i|$
- E no caso de matrizes?

Revisão – Normas de Matrizes

Definição 3.3: A norma de uma matriz A $n \times n$ é um número real não negativo denotado por $\|A\|$, associado com A , tal que:

- 1) $\|A\| > 0$, se $A \neq 0$ e $\|A\| = 0$ se $A = 0$;
- 2) $\|A + B\| \leq \|A\| + \|B\|$;
- 3) $\|KA\| \leq |K| \times \|A\|$, $K \in \mathbf{R}$;
- 4) $\|A \times B\| \leq \|A\| \times \|B\|$;

Se uma norma matricial e uma norma vetorial estão relacionadas de tal modo que:

5) $\|A \mathbf{x}\| \leq \|A\| \times \|\mathbf{x}\|$, seja satisfeita para qualquer A e \mathbf{x} , então as duas normas são ditas serem consistentes.

Revisão – Normas de Matrizes

Definição 3.4: As normas matriciais associadas às normas vetoriais 1, 2 e ∞ são:

$$\|\mathbf{A}\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}| \quad (\text{Soma máxima absoluta por coluna})$$

$$\|\mathbf{A}\|_2 = \{\text{autovalor máximo de } \mathbf{A}^T \mathbf{A}\}^{1/2} \quad (\text{Norma espectral})$$

$$\|\mathbf{A}\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}| \quad (\text{Soma máxima absoluta por linha})$$

Revisão – Diagonal Estritamente Dominante

Definição 3.1: Uma matriz $A \in \mathbf{R}^{n \times n}$ é de diagonal estritamente dominante, se ela satisfaz pelo menos uma das seguintes condições:

a) por linha

$$|a_{ii}| > \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}|, \quad i = 1, 2, \dots, n$$

ou

b) por coluna

$$|a_{jj}| > \sum_{\substack{i=1 \\ i \neq j}}^n |a_{ij}|, \quad j = 1, 2, \dots, n$$

Exemplo

$$\square \begin{pmatrix} 5 & 2 & 2 \\ -1 & -4 & 0 \\ -2 & 3 & 8 \end{pmatrix}$$

■ é uma matriz diagonal estritamente dominante por linha

$$\square \begin{pmatrix} 6 & 2 & 6 \\ 1 & -8 & 3 \\ 4 & 3 & -10 \end{pmatrix}$$

■ é uma matriz diagonal estritamente dominante por coluna

Revisão - Autovalores

Definição 3.2: Dada uma matriz $A \in \mathbf{R}^{n \times n}$, dizemos que seus autovalores são as raízes do polinômio característico dela, denotado por $\rho(\lambda)$, obtido de

$$|A - \lambda I| = \begin{vmatrix} a_{11} - \lambda & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} - \lambda & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} - \lambda \end{vmatrix}$$

□ Isto é, $\det(A - \lambda I) = 0$

Exemplo

- Calcular os autovalores da matriz A
- $A = \begin{pmatrix} 4 & 5 \\ 2 & 1 \end{pmatrix}$
- $A - \lambda I = \begin{pmatrix} 4 & 5 \\ 2 & 1 \end{pmatrix} - \lambda \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} = \begin{pmatrix} 4 - \lambda & 5 \\ 2 & 1 - \lambda \end{pmatrix}$
- $\det(A - \lambda I) = 0$
 - ▣ $(4 - \lambda)(1 - \lambda) - 10 = 0$
 - $\lambda_1 = -1$
 - $\lambda_2 = 6$

Convergência (voltando...)

- Considerando o sistema de equações lineares na forma:

$$x^{(k+1)} = Bx^{(k)} + c$$

- Como garantir a convergência?

$$\begin{cases} x^{(k+1)} = Bx^{(k)} + c & \Rightarrow x^{(k+1)} - x = B(x^{(k)} - x) \\ x = Bx + c & \Rightarrow e^{(k+1)} = B e^{(k)} \end{cases}$$

Convergência

$$\|e^{(k+1)}\|_1 = \|B e^{(k)}\|_1 \leq \|B\|_1 \|e^{(k)}\|_1$$

Da propriedade 5

$$\|B\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |B_{ij}| = \max_{1 \leq j \leq n} \sum_{\substack{i=1 \\ i \neq j}}^n \left| -\frac{a_{ij}}{a_{jj}} \right|$$

Da aula passada

Se B é de diagonal estritamente dominante, temos:

$$\sum_{\substack{i=1 \\ i \neq j}}^n \left| \frac{a_{ij}}{a_{jj}} \right| < 1 \quad ; \quad j=1, 2, \dots, n$$

Logo: $\|B\|_1 \leq \rho < 1$

Convergência

- Considerando a norma da soma dos vetores:

$$\|e^{(k+1)}\|_1 = \sum_{i=1}^n |e_i^{(k+1)}| \quad \|e^{(k)}\|_1 = \sum_{i=1}^n |e_i^{(k)}|$$

$$\Rightarrow \|e^{(k+1)}\|_1 = \|Be^{(k)}\| \leq \|B\|_1 \|e^{(k)}\|_1$$

$$\sum_{i=1}^n |e_i^{(k+1)}| \leq \rho \sum_{i=1}^n |e_i^{(k)}|$$

- Recursivamente:

$$\sum_{i=1}^n |e_i^{(k+1)}| \leq \rho^{(k+1)} \sum_{i=1}^n |e_i^{(0)}|$$

E como:

$$0 < \rho < 1$$

$$\lim_{k \rightarrow \infty} \sum_{i=1}^n |e_i^{(k+1)}| = 0$$

Teorema 3.2

Teorema 3.2

Se $A \in \mathbf{R}^{n \times n}$ é uma matriz não singular, de diagonal estritamente dominante, então o método de Gauss-Seidel converge para a solução do sistema de equações lineares $A\mathbf{x} = \mathbf{b}$, e a convergência é pelo menos tão rápida quanto para o método de Jacobi, para qualquer vetor aproximação inicial $\mathbf{x}^{(0)}$.

- Matriz não-singular: determinante não-nulo.
- Demonstração em [4]

Exemplo

□ Questão de Prova (2013.1)

Questão 2 (3,0 pontos): Considere o seguinte sistema linear:

$$\begin{aligned}6x_2 + 16x_3 &= 18 \\12x_1 + 8x_2 &= 23 \\-10x_1 - 13x_2 + 2x_3 &= -24\end{aligned}$$

Verifique se é possível estabelecer uma condição suficiente para garantir a convergência do método de Gauss-Seidel para computar a solução do sistema. Caso seja possível, utilize o método de Gauss-Seidel, aplicando-o na configuração com garantia de convergência, para determinar a solução aproximada do sistema. **Parta do vetor inicial** $(x_1^{(0)}, x_2^{(0)}, x_3^{(0)}) = (1, 1, 1)$ **e faça iterações até que, após a k -ésima iteração tenha-se a condição de parada** $\max_{1 \leq i \leq 3} |x_i^{(k)} - x_i^{(k-1)}| < 0.05$ **satisfeita.** Caso não seja possível estabelecer uma condição suficiente de convergência, utilize o método direto de decomposição LU para resolver o sistema.

Exemplo (Resposta)

- A matriz A é de diagonal estritamente dominante?
 - Não...
 - $0 < 6 + 16$ (não é pelo critério das linhas)
 - $0 < 12 + 10$ (nem pelo das colunas)

$$A = \begin{pmatrix} 0 & 6 & 16 \\ 12 & 8 & 0 \\ -10 & -13 & 2 \end{pmatrix}$$

$$\begin{aligned} 6x_2 + 16x_3 &= 18 \\ 12x_1 + 8x_2 &= 23 \\ -10x_1 - 13x_2 + 2x_3 &= -24 \end{aligned}$$

Exemplo (Resposta)

- Mas, poderíamos escalonar o sistema para:

$$A = \begin{pmatrix} 12 & 8 & 0 \\ -10 & -13 & 2 \\ 0 & 6 & 16 \end{pmatrix}$$

- Nesse caso, a matriz A é de diagonal estritamente dominante por linha e por coluna.
 - Porém, é importante salientar que basta que A seja de diagonal estritamente dominante apenas por linha ou apenas por coluna
- Logo, podemos garantir a convergência.
 - Deixamos o restante da questão como exercício.

Teorema 3.3

Teorema 3.3

A iteração $\mathbf{x}^{(k+1)} = \mathbf{D}\mathbf{x}^{(k)} + \mathbf{c}$ convergirá para qualquer escolha do vetor inicial $\mathbf{x}^{(0)}$ se, e somente se, os autovalores da matriz \mathbf{D} forem todos, em módulo, menores que 1.

□ Demonstração em [5]

Teorema 3.2

- “Devemos salientar que as condições apresentadas no Teorema 3.2 são suficientes e não necessárias.”
- “O que significa dizer que se tais condições não forem satisfeitas, nada se pode afirmar pois uma das seguintes situações pode ocorrer:”
 - ▣ Não converge por nenhum dos métodos (Jacobi / Gauss-Seidel)
 - ▣ Converte por um deles e diverge pelo outro
 - ▣ Converte por ambos os métodos

Sistemas Mal-Condicionados

- “Um sistema de equações lineares é dito ser mal-condicionado se sua solução é muito sensível às pequenas mudanças em algum ou alguns coeficientes das equações.”

Exemplo 3.7

Exemplo 3.7 - Considere o sistema de equações lineares

$$\begin{cases} 1,00x_1 + 1,00x_2 = 2,00 \\ 1,01x_1 + 1,00x_2 = 2,01 \end{cases}$$

solução é dada pelo vetor $\mathbf{x} = \{ (1,00; 1,00)^T \}$.

Entretanto, se o coeficiente de x_1 , na segunda equação, for 1,0001 ao invés de 1,01, isto é, se tivermos o sistema

$$\begin{cases} 1,00x_1 + 1,00x_2 = 2,00 \\ 1,0001x_1 + 1,00x_2 = 2,01 \end{cases}$$

a solução passa a ser o vetor $\mathbf{x} = \{ (100; -98)^T \}$.

Exemplo 3.7

- Esse exemplo mostra a instabilidade do sistema, pois, alterando apenas um de seus coeficientes em 0,099, sua solução foi multiplicada por aproximadamente um fator 100 (em módulo).
- Importante notar que, geralmente, os coeficientes das equações não são conhecidos exatamente. Podem ter sido obtidos de arredondamento, experimento, modelagem matemática, etc. Logo, possivelmente imprecisos.

Pergunta

- Como reconhecer se um sistema de equações lineares é mal-condicionado?
- “A resposta a essa questão é bastante complexa. Um estudo sobre alguns critérios de de identificação de mal-condicionamento de sistemas é apresentado em [6]”

Algumas critérios que podem caracterizar o mal-condicionamento:

- Pequeno valor do determinante da matriz dos coeficientes;
- Pequeno valor do determinante normalizado da matriz dos coeficientes;
- Grandes valores dos elementos da matriz inversa dos coeficientes do sistema em estudo;
- Número de condição.

Definição 3.5

Definição 3.5: O determinante normalizado de uma matriz quadrada A é definido como

$$\textit{norma } |A| = \frac{|A|}{\alpha_1 \times \alpha_2 \times \alpha_3 \times \dots \times \alpha_n}$$

Onde

$$\alpha_k = (a_{k1}^2 + a_{k2}^2 + \dots + a_{kn}^2)^{1/2}$$

com $k = 1, 2, \dots, n$.

Definição 3.6

Definição 3.6: O número de condição de uma matriz não singular A , denotado por $\mathit{cond}(A)$ ou $K(A)$ é dado por $\mathit{cond}(A) = K(A) = \|A\| \times \|A^{-1}\|$ para qualquer norma.

Este número de condição é comumente usado para identificar se um sistema de equações lineares é mal-condicionado, isto é, se $\mathit{cond}(A)$ ou $K(A)$ for “muito grande” (lamentavelmente não há meio de especificar esta grandeza), o sistema $A\mathbf{x} = \mathbf{b}$ é mal-condicionado.

Exemplo 3.9

Exemplo 3.9 - Considere o sistema de equações lineares

$$\begin{cases} 1,2969 x + 0,8648 y = 0,8642 \\ 0,2161 x + 0,1441 y = 0,1440 \end{cases}$$

Temos que:

$$A = \begin{pmatrix} 1,2969 & 0,8648 \\ 0,2161 & 0,1441 \end{pmatrix} \quad b = \begin{pmatrix} 0,8642 \\ 0,1440 \end{pmatrix}$$

Exemplo 3.9

□ $A^{-1} = ?$

□ $A = \begin{pmatrix} a & b \\ c & d \end{pmatrix}$

□ $A^{-1} = \frac{1}{\det(A)} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$

□ Logo, se $A = \begin{pmatrix} 1,2969 & 0,8648 \\ 0,2161 & 0,1441 \end{pmatrix}$, temos:

□ $A^{-1} = 10^8 \begin{pmatrix} 0,1441 & -0,8648 \\ -0,2161 & 1,2969 \end{pmatrix}$

Exemplo 3.9

- Calculando o valor das normas matriciais:

$$\begin{aligned}\|A\|_{\infty} &= \max_{1 \leq i \leq 2} \sum_{j=1}^2 |a_{ij}| = \\ &= \max \{ 1,2969 + 0,8648 ; 0,2161 + 0,1441 \} \\ &= 2,1617\end{aligned}$$

$$\begin{aligned}\|A^{-1}\|_{\infty} &= \max_{1 \leq i \leq 2} \sum_{j=1}^2 |a_{ij}^{(-1)}| \\ &= \max \{ 1,0089 \times 10^8 ; 1,5130 \times 10^8 \} \\ &= 1,5130 \times 10^8\end{aligned}$$

Exemplo 3.9

- Logo, calculando o valor no número de condição $K(A)$, temos:

$$K(A) = \|A\| \cdot \|A^{-1}\| = 2,1617 \times 1,5130 \times 10^8$$

$$\Rightarrow K(A) = 3,27 \times 10^8$$

- Logo, podemos afirmar que o sistema é mal-condicionado.
- Notar que utilizamos os valores das normas matriciais associadas à norma vetorial ∞ .

Bibliografia

- [1] Silva, Zandoni; Santos, José Dias. Métodos Numéricos, 3ª Edição. Universitária, Recife, 2010.
- [2] Notas de aula do prof. Divanilson Campelo
- [3] Ruggiero, Márcia; Lopes, Vera. Cálculo Numérico – Aspectos Teóricos e Computacionais, 2ª Edição. Pearson. São Paulo, 1996.
- [4] Hammerlin G. and Hoffman K. Numerical Mathematics, Springer-Verlag, New York, 1991.
- [5] Albrecht P. Análise Numérica – Um curso Moderno, LTC, Rio de Janeiro, 1973.
- [6] Santos J.D. Análise de Sistemas de Equações Lineares Mal-condicionados. Dissertação de Mestrado, Departamento de Informática, UFPE, Recife, 1981.

