

A₁ - Análise Numérica - 2021

1. (4 pontos) Seja S o conjunto formado pelos números reais que tem uma representação exata no computador (considere precisão dupla, i.e 64 bits) e cuja representação em ponto flutuante tem exatamente um bit "1".

- (a) Determine o maior e o menor número real positivo contido em S .
(b) Determine um número real x tal que $x \notin S$, mas $fl(x) \in S$.

a) Temos que esses números têm o formato

(i) $\overset{11}{1\ 0\ \text{---}\ 0\ 0\ \text{---}\ 0}$ ou
(ii) $0\ 0\text{---}1\text{---}0\ 0\ \text{---}\ 0$; ou
(iii) $0\ 0\ \text{---}\ 0\ 0\text{---}1\text{---}0$

Em (i), temos o número -0

Em (ii), temos os números da forma
 $2^{2^{i-1}-1023}$

em que $i = 1, \dots, 11$ é a posição do bit 1.

Em (iii), em que o expoente é nulo, temos os números subnormais. Nesse caso temos o formato
 $2^{-1022} \cdot (0 + 2^{-i}) = 2^{-(1022+i)}$

em que $i = 1, \dots, 52$ é a posição na mantissa (da esquerda para a direita) do bit 1.

Concluímos que:

$$S = \{2^{2^{i-1}-1023} \mid i = 1, \dots, 11\} \cup \{2^{-(i+1022)} \mid i = 1, \dots, 52\} \cup \{-0\}$$

O maior em S é $2^{2^{11}-1-1023} = 2^{1074}$
O menor em S é $2^{-(52+1022)} = 2^{-1074}$

b) Considere o número

$$0 \underbrace{10-0}_{\text{exponente}} \underbrace{0-0}_{\text{mantissa}} \underbrace{01}_{\text{resto}}$$

que tem representação decimal

$$(-1)^0 2(1 + 2^{-54}) = 2 + 2^{-53}$$

Temos que $x \notin S$ e de fato nem pode ser representado por outro número de máquina. Entretanto, na operação de arredondamento da mantissa 01 é cortado e temos o número $f(x) = 2 \in S$.

2. (6 pontos) Considere o sistema de equações lineares de $n \times n$, cuja j -ésima equação ($j = 1, \dots, n-1$) é

$$\sum_{k=1}^j \frac{1}{2^{j-k}} x_k + \sum_{k=j+1}^n \frac{1}{2^k} x_k = \frac{1}{j}$$

e cuja n -ésima equação é

$$\sum_{k=1}^n \frac{1}{2^{n-k}} x_k = \frac{1}{n}$$

- (a) O método de Jacobi aplicado a esse sistema é convergente $\forall n \in \mathbb{N}$? Justifique bem sua resposta.
 (b) O método de Gauss-Seidel aplicado a esse sistema é convergente $\forall n \in \mathbb{N}$? Justifique bem sua resposta.

Seja $Ax = b$ nosso sistema.

$$\begin{aligned} \text{lin}_i(A) &= (\overbrace{2^{1-i}, 2^{2-i}, \dots, 1}^i, \overbrace{2^{-(i+1)}, \dots, 2^{-n}}^{n-i}) \quad (i = 1, \dots, n-1) \\ \text{lin}_n(A) &= (2^{1-n}, 2^{2-n}, \dots, 1) \end{aligned}$$

Considere a linha n .

$$\sum_{k=1}^{n-1} \frac{1}{2^{n-k}} = \sum_{j=1}^{n-1} 2^{-j} = \frac{1}{2} \frac{(1 - (\frac{1}{2})^{n-1})}{1 - 1/2} = 1 - \frac{1}{2^{n-1}} < 1,$$

$\forall n \in \mathbb{N}$, pois $2^{1-n} > 0$.

Isso implica que a matriz é irredutivelmente diagonalmente dominante. Além disso, para $j = 1, \dots, n-1$,

$$\begin{aligned}
\sum_{k=1}^{j-1} 2^{k-j} + \sum_{k=j+1}^n 2^{-k} &= \sum_{i=1}^{j-1} 2^{-i} + \sum_{i=j+1}^n 2^{-i} \\
&= \sum_{i=1}^n 2^{-i} - 2^{-j} \\
&= \frac{1 - (1/2)^{n+1}}{1 - 1/2} - 2^{-j} \\
&= 1 - 2^{-n} - 2^{-j} < 1,
\end{aligned}$$

o que implica A ser estritamente diagonalmente dominante. Isso mostra que $\forall n \in \mathbb{N}$, ambos os métodos são convergentes.

(c) Demonstre que para qualquer norma induzida, o método iterativo $x^{(m+1)} = Cx^{(m)} + d$ satisfaz

$$\|x^{(m+1)} - x^{(m)}\| \leq \|C\| \|x^{(m)} - x^{(m-1)}\|, \quad \forall m \in \mathbb{N}$$

(d) Determine m , em função de n , de modo que após m iterações do método de Jacobi, se obtenha uma aproximação a solução do sistema com uma precisão de 10^{-5} . Justifique.

c)

$$\begin{aligned}
\|x^{(m+1)} - x^{(m)}\| &\stackrel{\text{passo de iteração}}{=} \|Cx^{(m)} + d - Cx^{(m-1)} - d\| \\
&\stackrel{\text{linearidade}}{=} \|C(x^{(m)} - x^{(m-1)})\| \\
&\leq \|C\| \|x^{(m)} - x^{(m-1)}\|,
\end{aligned}$$

pois $\|C\| = \sup_{\|x\| \neq 0} \frac{\|Cx\|}{\|x\|} \Rightarrow \|C\| \geq \frac{\|Cx\|}{\|x\|}, \quad \forall x \neq 0$ e, portanto,

$\forall x \in \mathbb{R}^n, \|C\| \|x\| \geq \|Cx\|$, em que $x=0$ a desigualdade é trivial e torna-se uma igualdade.

d) Note que

$$\begin{aligned}
\|x^* - x^{(m+1)}\| &= \|Cx^* + d - Cx^{(m)} - d\| \\
&\leq \|C\| \|x^* - x^{(m)}\| \\
&= \|C\| \|x^* - x^{(m+1)} + x^{(m+1)} - x^{(m)}\| \\
&\leq \|C\| \|x^* - x^{(m+1)}\| + \|C\| \|x^{(m+1)} - x^{(m)}\| \\
\Rightarrow \|x^* - x^{(m+1)}\| &\leq \frac{\|C\|}{1 - \|C\|} \|x^{(m+1)} - x^{(m)}\|
\end{aligned}$$

No nosso caso $\|C\| < 1$, pois o método é convergente,

isto é, existe $\|\cdot\|$ induzida com $\|C\| < 1$.

Como $\|x^{(m+1)} - x^{(m)}\| \leq \|C\| \|x^{(m)} - x^{(m-1)}\|$, que por indução implica

$$\|x^{(m+1)} - x^{(m)}\| \leq \|C\|^m \|x^{(1)} - x^{(0)}\|.$$

Logo

$$\|x^* - x^{(m+1)}\| \leq \frac{\|C\|^{m+1}}{1 - \|C\|} \|x^{(1)} - x^{(0)}\|.$$

Para $\|x^* - x^{(m)}\| \leq 10^{-5}$, é suficiente que

$$\frac{\|C\|^m}{1 - \|C\|} \leq 10^{-5}$$

$$\Rightarrow m \log \|C\| - \log(1 - \|C\|) \leq -5$$

$$\Rightarrow m \geq \frac{\log(1 - \|C\|) - 5}{\log \|C\|}$$

Falta calcular $\|C\|$, por fim.

No método de Jacobi, $C = -D^{-1}(L+U)$. Eu lembro que $D^{-1} = I$, pois $D_{jj} = 1/2j = 1$. Logo $C = -(L+U)$. Note que

$$\begin{aligned} \|C\|_{\infty} &= \|L+U\|_{\infty} \\ &= \max_{1 \leq j \leq n} \sum_{k=1}^n |c_{jk}| \\ &= \max_{1 \leq j \leq n} \sum_{k=1}^{j-1} \frac{1}{2^{j-k}} + \sum_{k=j+1}^n \frac{1}{2^j} \\ &= \max_{1 \leq j \leq n} \left(\sum_{i=1}^n \frac{1}{2^i} - \frac{1}{2^j} \right) \\ &= \max \left(1 - \frac{1}{2^n} - \frac{1}{2^j} \right) \\ &= 1 - \frac{1}{2^n} - \min \frac{1}{2^j} \\ &= 1 - 2^{1-n} \end{aligned}$$

Assim

$$\begin{aligned} m &\geq \frac{\log(1 - \|C\|_\infty) - 5}{\log(\|C\|_\infty)} \\ &= \frac{(1-n)\log 2 - 5}{\log(1 - 2^{1-n})} \\ &= \frac{(n-1)\log 2 + 5}{\log(1/(1 - 2^{1-n}))} . \end{aligned}$$