



Profesor: Gonzalo Hernández.  
Auxiliar: Gonzalo Ríos.  
Fecha: 24 de Agosto

### Pauta Control 1

#### 1) Representación Numerica

- (a) Considere una representación floating point tipo inicial, donde el número real más cercano a cero es  $2^{-23}$ . Se sabe que la cantidad de bits de la mantisa es el doble que el número de bits usados en el exponente.
- Explique cuantos bits son necesarios para implementar esta codificación y como se distribuyen.
  - Sea  $x = a_1a_2...a_n$  la representación floating point de un número real, donde  $n$  es el número de bits utilizados por la codificación y:

$$a_1 = 1, \quad a_k = (a_{k-1} + k) \bmod 2, \quad k = 2...n$$

Determine el real representado por  $x$ .

- Calcule el real máximo representable en esta codificación.
- (b) Considere la codificación floating point actual de 32 bits de la forma:

$$fl(x) = (-1)^s 2^z (1 + m)$$

donde  $s$  el bit de signo,  $z \in [-126, 127]$  el exponente y  $m$  la mantisa de 23 bits.

Suponga que se redondea un número  $x > 0$  para llegar a su codificación floating point.

- Demuestre que:

$$-2^{z-n} \leq x - fl(x) \leq 2^{z-n}$$

donde  $n$  es la cantidad de bits de la mantisa.

- Demuestre que  $x \geq 2^z$  y que por lo tanto:

$$\frac{|x - fl(x)|}{x} \leq 2^{-n}$$

### **Respuesta**

#### 1) Representación Numérica

- (a) Representación floating point tipo inicial

- Como el número real más cercano a cero representable en una codificación binaria siempre es  $2^{-m} \times 2^{-(2^e-1)}$ , donde  $m$  es la cantidad de bits de la mantisa, y  $e$  la cantidad de bits del exponente, esto equivale a  $2^{-(2^e-1)-m}$ , y como  $m = 2e$  queda un sistema:

$$2^{-(2^e-1)-m} = 2^{-23} \implies \begin{matrix} 2^e - 1 + m = 23 \\ m = 2e \end{matrix} \implies \begin{matrix} 2^e + 2e = 24 \\ m = 2e = 8 \end{matrix} \implies \begin{matrix} e = 4 \\ m = 8 \end{matrix}$$

Sumando el bit para el signo de la mantisa y el bit del signo del exponente, la codificación necesita  $2 + 4 + 8 = 14$  bits.

- En total son 14 bits, entonces

$a_1$	1
$a_2$	$(1 + 2) \bmod 2 = 1$
$a_3$	$(1 + 3) \bmod 2 = 0$
$a_4$	$(0 + 4) \bmod 2 = 0$
$a_5$	$(0 + 5) \bmod 2 = 1$
$a_6$	$(1 + 6) \bmod 2 = 1$
$a_7$	$(1 + 7) \bmod 2 = 0$
$a_8$	$(0 + 8) \bmod 2 = 0$
$a_9$	$(0 + 9) \bmod 2 = 1$
$a_{10}$	$(1 + 10) \bmod 2 = 1$
$a_{11}$	$(1 + 11) \bmod 2 = 0$
$a_{12}$	$(0 + 12) \bmod 2 = 0$
$a_{13}$	$(0 + 13) \bmod 2 = 1$
$a_{14}$	$(1 + 14) \bmod 2 = 1$

Número real:  $x = 1\ 1\ 0011\ 00110011$

Signo Mantisa:  $-$

Signo Exponente:  $-$

Exponente:  $0 \times 2^3 + 0 \times 2^2 + 1 \times 2^1 + 1 \times 2^0 = 3$

Mantisa:  $0 \times 2^{-1} + 0 \times 2^{-2} + 1 \times 2^{-3} + 1 \times 2^{-4} + 0 \times 2^{-5} + 0 \times 2^{-6} + 1 \times 2^{-7} + 1 \times 2^{-8} =$

$$\frac{1}{8} + \frac{1}{16} + \frac{1}{128} + \frac{1}{256} = \frac{32+16+2+1}{256} = \frac{51}{256}$$

$$\text{Numero: } x = -\frac{51}{256} \times 2^{-3} = -\frac{51}{256} \times \frac{1}{8} = -\frac{51}{2048} = -0.02490234375$$

iii) El número real máximo representable en una codificación binario tipo inicial es de la forma

$$M = (1 - 2^{-m}) \times 2^{(2^e - 1)}. \text{ Como } m = 8 \text{ y } e = 4, \text{ entonces}$$

$$M = (1 - 2^{-8}) \times 2^{(2^4 - 1)} = 2^{15} - 2^7 = 32640$$

(b) Codificación floating point actual

i) Dado un real  $x > 0$ , ese se pasa a base binaria, con una mantisa entre 1 y 2, es decir  $x = 2^z(1 + m^*)$ , con  $m^* \in [0, 1]$ . Ahora, al aproximar queda de la forma  $fl(x) = 2^z(1 + m)$ . Entonces, se puede hacer una transformación de codificación tipo actual a tipo inicial tomando  $x = 2^{z+1}(\frac{1+m^*}{2})$ ,  $fl(x) = 2^{z+1}(\frac{1+m}{2})$ , en donde se cumple que la nueva mantisa es mayor que  $\frac{1}{2}$  y menor que 1, y ahora tiene  $n + 1$  cifras significativas. Como vimos en clase, en la codificación tipo inicial se tiene que  $E_{rel}(x, fl(x)) \leq \frac{b}{2} \times b^{-t}$ , donde  $b$  es la base y  $t$  es la cantidad de cifras significativas de la mantisa, entonces en nuestro caso,  $E_{rel}(x, fl(x)) \leq 2^{-(n+1)} \implies \frac{|x - fl(x)|}{x} \leq 2^{-(n+1)} \implies |x - fl(x)| \leq x 2^{-(n+1)} \implies |x - fl(x)| \leq x 2^{-(n+1)} = 2^{z+1}(\frac{1+m^*}{2}) \times 2^{-(n+1)} \leq 2^{z+1-n-1} = 2^{z-n} \implies -2^{z-n} \leq x - fl(x) \leq 2^{z-n}$

ii) Como  $x = 2^z(1 + m^*)$ , con  $m^* \in [0, 1] \implies (1 + m^*) \geq 1 \implies x = 2^z(1 + m^*) \geq 2^z \implies \frac{1}{x} \leq \frac{1}{2^z}$

$$\text{Entonces, } E_{rel}(x, fl(x)) = \frac{|x - fl(x)|}{x} \leq \frac{2^{z-n}}{x} \leq \frac{2^{z-n}}{2^z} \leq 2^{-n}$$

## 2) Aproximación y Errores

(a) Determine la propagación de errores de las siguientes operaciones matemáticas:

i)  $\phi(x, y) = 1 + \sin(x^2 + y^2), \quad x, y \in [0, 1]$

ii)  $\phi(x, y, z) = \sqrt{xyz}$

Cuáles de ellas son estables/inestables? Fundamente su respuesta.

(b) Considere las siguientes aproximaciones numéricas de la derivada de una función a variable real  $f(x)$  en un punto  $x_0$ : (para  $h \approx 0$ )

$$\frac{df(x_0)}{dx} \approx \frac{f(x_0 + h) - f(x_0)}{h} \quad \frac{df(x_0)}{dx} \approx \frac{f(x_0 + h) - f(x_0 - h)}{2h}$$

i) Haga un análisis de propagación de error de la primera fórmula con  $\varepsilon_h = 0$ .

Obs: Si aparece  $\frac{f(x+h)-f(x)}{h}$ , aproxímelo por  $f'(x)$ .

- ii) Para una aritmética finita de 5 cifras significativas con redondeo, aproxime la derivada de  $f(x) = x \ln x$  en el punto  $x_0 = 10.125$ , usando la segunda fórmula con  $h = 0.001$ . Compare este valor aproximado con el valor exacto de la derivada. Calcule el error absoluto y relativo.

## Respuesta

### 2) Aproximación y Errores

(a) Estabilidad:  $\varepsilon_\phi = \frac{x}{\phi(x,y)} \frac{\partial \phi}{\partial x} \varepsilon_x + \frac{y}{\phi(x,y)} \frac{\partial \phi}{\partial y} \varepsilon_y$

i)  $\phi(x, y) = 1 + \sin(x^2 + y^2)$

$$\frac{\partial \phi}{\partial x} = \cos(x^2 + y^2) 2x$$

$$\frac{\partial \phi}{\partial y} = \cos(x^2 + y^2) 2y$$

$$\varepsilon_\phi = \frac{x}{\phi(x,y)} \frac{\partial \phi}{\partial x} \varepsilon_x + \frac{y}{\phi(x,y)} \frac{\partial \phi}{\partial y} \varepsilon_y = \frac{\cos(x^2 + y^2) 2x^2}{1 + \sin(x^2 + y^2)} \varepsilon_x + \frac{\cos(x^2 + y^2) 2y^2}{1 + \sin(x^2 + y^2)} \varepsilon_y$$

Como  $x, y \in [0, 1]$ , entonces los errores se podrían acotar por su mayor valor que tome en ese intervalo, siempre y cuando exista. La única forma en que se indetermina es en el caso que  $1 + \sin(x^2 + y^2) = 0$ , que solo podría suceder si  $\sin(x^2 + y^2) = -1$ , que sería cuando  $x^2 + y^2 = \frac{3\pi}{2}$ , pero como  $x, y \in [0, 1]$ ,  $\max(x^2 + y^2) = 2 < \frac{3\pi}{2}$ , lo cual es estable.

ii)  $\phi(x, y, z) = \sqrt{xyz}$ ;  $\varepsilon_\phi = \frac{x}{\phi(x,y,z)} \frac{\partial \phi}{\partial x} \varepsilon_x + \frac{y}{\phi(x,y,z)} \frac{\partial \phi}{\partial y} \varepsilon_y + \frac{z}{\phi(x,y,z)} \frac{\partial \phi}{\partial z} \varepsilon_z$

$$\frac{\partial \phi}{\partial x} = \frac{1}{2} \sqrt{\frac{yz}{x}}$$

$$\frac{\partial \phi}{\partial y} = \frac{1}{2} \sqrt{\frac{xz}{y}}$$

$$\frac{\partial \phi}{\partial z} = \frac{1}{2} \sqrt{\frac{xy}{z}}$$

$$\varepsilon_\phi = \frac{x}{\phi(x,y,z)} \frac{\partial \phi}{\partial x} \varepsilon_x + \frac{y}{\phi(x,y,z)} \frac{\partial \phi}{\partial y} \varepsilon_y + \frac{z}{\phi(x,y,z)} \frac{\partial \phi}{\partial z} \varepsilon_z = \frac{x}{\sqrt{xyz}} \frac{1}{2} \sqrt{\frac{yz}{x}} \varepsilon_x + \frac{y}{\sqrt{xyz}} \frac{1}{2} \sqrt{\frac{xz}{y}} \varepsilon_y + \frac{z}{\sqrt{xyz}} \frac{1}{2} \sqrt{\frac{xy}{z}} \varepsilon_z = \frac{1}{2} (\varepsilon_x + \varepsilon_y + \varepsilon_z)$$

(b)  $\frac{df(x_0)}{dx} \simeq \frac{f(x_0+h) - f(x_0-h)}{2h}$

i)  $f'(x) = \phi(x, h) = \frac{f(x+h) - f(x)}{h}$

$$\phi_0(x) = f(x)$$

$$\varepsilon_0 = x \frac{f'(x)}{f(x)} \varepsilon_x$$

$$\phi_1(x, h) = f(x + h)$$

$$\varepsilon_1 = x \frac{f'(x+h)}{f(x+h)} \varepsilon_x + h \frac{f'(x+h)}{f(x+h)} \varepsilon_h = x \frac{f'(x+h)}{f(x+h)} \varepsilon_x$$

$$\phi_2(f(x+h), f(x)) = f(x+h) - f(x)$$

$$\varepsilon_2 = \frac{f(x+h)}{f(x+h) - f(x)} \varepsilon_1 - \frac{f(x)}{f(x+h) - f(x)} \varepsilon_0 = \frac{f(x+h)}{f(x+h) - f(x)} x \frac{f'(x+h)}{f(x+h)} \varepsilon_x - \frac{f(x)}{f(x+h) - f(x)} x \frac{f'(x)}{f(x)} \varepsilon_x$$

$$= \frac{x f'(x+h) \varepsilon_x}{f(x+h) - f(x)} - \frac{x f'(x) \varepsilon_x}{f(x+h) - f(x)} = \frac{f'(x+h) - f'(x)}{f(x+h) - f(x)} x \varepsilon_x$$

$$f'(x, h) = \frac{\phi_2}{2h}$$

$$\varepsilon_{f'} = \varepsilon_2 - \varepsilon_h = \varepsilon_2 = \frac{f'(x+h) - f'(x)}{f(x+h) - f(x)} x \varepsilon_x = \frac{\frac{f'(x+h) - f'(x)}{h}}{\frac{f(x+h) - f(x)}{h}} x \varepsilon_x = \frac{f''(x)}{f'(x)} x \varepsilon_x$$

Obs: Si se toma  $\phi(x, h) = \frac{f(x+h) - f(x)}{h}$ , entonces  $\varepsilon_\phi = \frac{x}{\frac{f(x+h) - f(x)}{h}} \frac{f'(x+h) - f'(x)}{h} \varepsilon_x =$

$$\frac{x}{f'(x)} f''(x) \varepsilon_x = \frac{f''(x)}{f'(x)} x \varepsilon_x,$$

llegando al mismo resultado, pero la idea era hacerlo dividiendo por operaciones.

ii)  $f(x) = x \ln x$ ,  $x_0 = 10.125$ ,  $h = 0.001$

$$\frac{df(x_0)}{dx} \simeq \frac{f(x_0+h) - f(x_0-h)}{2h}$$

A.  $fl(x_0) = 10.125$

$$fl(h) = 0.001$$

$$fl(x_0 + h) = fl(10.126) = 10.126$$

$$fl(\ln(10.126)) = fl(2.3151063735477174296) = 2.3151$$

$$fl(10.126 \times 2.3151) = fl(23.4427026) = 23.443$$

$$fl(x_0 - h) = fl(10.124) = 10.124$$

$$fl(\ln(10.124)) = fl(2.3149088426828776198) = 2.3149$$

$$fl(10.124 \times 2.3149) = fl(23.4360476) = 23.436$$

$$fl(23.443 - 23.436) = fl(0.007) = 0.007$$

$$fl(2 \times 0.001) = fl(0.002) = 0.002$$

$$fl\left(\frac{0.007}{0.002}\right) = fl(3.5) = 3.5$$

B.  $f'(x) = \ln x + 1$

$$f'(10.125) = \ln 10.125 + 1 = 3.3150076129926028373$$

$$\Rightarrow fl(f'(10.125)) = 3.315$$

$$E_{abs} = |3.315 - 3.5| = 0.185$$

$$E_{rel} = \frac{|3.315 - 3.5|}{|3.315|} = 0.05580693815987933635 < 5 \times 10^{-1}$$

$$\Rightarrow \text{tiene 1 cifra significativa}$$

### 3) Sistemas de Ecuaciones Lineales

Dada una matriz tridiagonal, su factorización  $A = LU$  puede ser llevada a la forma:

$$\begin{bmatrix} a_{11} & a_{12} & 0 & \cdots & 0 \\ a_{21} & a_{22} & a_{23} & \cdots & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ 0 & 0 & \cdots & a_{nn-1} & a_{nn} \end{bmatrix} = \begin{bmatrix} l_{11} & 0 & \cdots & 0 \\ l_{21} & l_{22} & \cdots & 0 \\ \vdots & \ddots & \ddots & \ddots \\ 0 & 0 & l_{nn-1} & l_{nn} \end{bmatrix} \begin{bmatrix} 1 & u_{12} & 0 & \cdots & 0 \\ 0 & 1 & u_{23} & \ddots & 0 \\ \vdots & \vdots & \ddots & \ddots & u_{n-1n} \\ 0 & 0 & \cdots & 0 & 1 \end{bmatrix}$$

mediante el Método de Crout:

Paso 1:	Paso 2: Para $i = 2, \dots, n-1$	Paso 3:
$l_{11} = a_{11}$ $u_{12} = \frac{a_{12}}{l_{11}}$	$l_{i(i-1)} = a_{i(i-1)}$ $l_{ii} = a_{ii} - l_{i(i-1)}u_{(i-1)i}$ $u_{i(i+1)} = \frac{a_{i(i+1)}}{l_{ii}}$	$l_{n(n-1)} = a_{n(n-1)}$ $l_{nn} = a_{nn} - l_{n(n-1)}u_{(n-1)n}$

(a) Calcule la factorización de Crout de la siguiente matriz:

$$A = \begin{bmatrix} 5 & -2 & 0 & 0 \\ -2 & 5 & -2 & 0 \\ 0 & -2 & 5 & -2 \\ 0 & 0 & -2 & 5 \end{bmatrix}$$

(b) Calcule la cantidad de *ops* que este método realiza aplicado a una matriz cuadrada tridiagonal de tamaño  $n$ .

### Respuesta

### 3) Sistemas de Ecuaciones Lineales

(a)  $A = \begin{bmatrix} 5 & -2 & 0 & 0 \\ -2 & 5 & -2 & 0 \\ 0 & -2 & 5 & -2 \\ 0 & 0 & -2 & 5 \end{bmatrix}$

Paso 1:  $l_{11} = a_{11} = 5$   
 $u_{12} = \frac{a_{12}}{l_{11}} = \frac{-2}{5}$

Paso 2:  $l_{21} = a_{21} = -2$

$$l_{22} = a_{22} - l_{21}u_{12} = 5 - (-2)\left(\frac{-2}{5}\right) = \frac{21}{5}$$

$$u_{23} = \frac{a_{23}}{l_{22}} = \frac{-2}{\frac{21}{5}} = -\frac{10}{21}$$

$$l_{32} = a_{32} = -2$$

$$l_{33} = a_{33} - l_{32}u_{23} = 5 - (-2)\left(-\frac{10}{21}\right) = \frac{85}{21}$$

$$u_{34} = \frac{a_{34}}{l_{33}} = \frac{-2}{\frac{85}{21}} = -\frac{42}{85}$$

Paso 3:  $l_{43} = a_{43} = -2$

$$l_{44} = a_{44} - l_{43}u_{34} = 5 - (-2)\left(-\frac{42}{85}\right) = \frac{341}{85}$$

Finalmente:

$$L = \begin{bmatrix} 5 & 0 & 0 & 0 \\ -2 & \frac{21}{5} & 0 & 0 \\ 0 & -2 & \frac{85}{21} & 0 \\ 0 & 0 & -2 & \frac{341}{85} \end{bmatrix}; U = \begin{bmatrix} 1 & \frac{-2}{5} & 0 & 0 \\ 0 & 1 & -\frac{10}{21} & 0 \\ 0 & 0 & 1 & -\frac{42}{85} \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

(b)  $ops = 1 + \sum_{i=2}^{n-1} 3 + 2 = 3(n-2) + 3 = 3(n-1) \Rightarrow O(n)$  lineal