

Classificação dos Erros. Representação dos números reais

MS211 – Cálculo Numérico – Turma C

Giuseppe Romanazzi

Agosto 2023

Conteúdo

- 1 Classificação dos erros
- 2 Representação dos números reais na aritmética finita
- 3 Erro Absoluto e Erro Relativo

Erros

- Erros de modelização
- Erros inerentes
- Erros de truncamento
- Erros de representação dos números (também chamado erro de arredondamento)

Erros de Modelização

A modelagem de um problema depende dos:

- dados disponíveis
- variáveis usadas t, a, b, N (variáveis representativas do problema)
- relações analisadas, exemplo $N = a * t + b$

Obtemos um **Erro de Modelização** se escolhemos variáveis do problema pouco significativas/representativas, ou se usamos relações erradas entre as variáveis para descrever o problema. Estes erros ocorrem se interpretamos mal o problema, ou se não encontramos as relações certas entre as variáveis que concorrem no modelo.

Erros Inerentes

Os Erros Inerentes dividem-se em duas categorias

- Erros Sistemáticos
- Erros Fortuitos (random)

Erros Sistemáticos aparecem quando o instrumento para medir os dados do problema apresentam algum erro de funcionamento ou de calibração. Este leva a medir erroneamente os dados de input do problema.

Erros Fortuitos são devidos a erros humanos não previsíveis, por exemplo devidos a falta de atenção durante as medidas.

São também fortuitos os erros devidos a variações das condições ambientais (como mudança de tensão elétrica, mudança de umidade, temperatura etc.) que podem afetar as medidas dos dados de input do problema.

Erros de Truncamento

Para determinar a solução exata de um problema matemático como:

- determinar o valor de uma função num certo ponto
- obter o integral definido num intervalo
- uma derivada de uma função num ponto
- resolver uma equação etc...

Precisamos de usar uma formula ou um método numérico que normalmente necessita infinitos passos computacionais que apresentam operações simples ('+', '-', '*', '/')

Erros de Truncamento

Por exemplo se quiséssemos determinar e^x para um dado $x \in \mathbb{R}$ podemos usar a formula da expansão em serie de Taylor do exponencial

$$e^x = \sum_{n=0}^{\infty} \frac{x^n}{n!}.$$

Para aproximar e^x podemos decidir de **truncar** a soma: consideramos somente os primeiros três termos (mais pesados/representativos) da soma: $1 + x + \frac{x^2}{2}$ é uma aproximação de e^x .

A diferença $|e^x - (1 + x + \frac{x^2}{2})|$ pode ser chamada erro de truncamento da expansão serie de Taylor de e^x usando três termos.

Erros de Truncamento

A diferença em valor absoluto

$$|V_E - V_T|$$

entre o valor exato V_E do problema e de uma sua aproximação V_T obtida truncando um processo (ou método) que determina a solução é chamada **Erro de Truncamento**.

Outro exemplo (erro de truncamento na aproximação da derivada):
pode-se usar a fórmula

$f(x+h) = f(x) + hf'(x) + \frac{h^2}{2}f''(x) + \frac{h^3}{3!}f'''(x) + \dots$ para obter a derivada $f'(x)$:

$$f'(x) = \frac{f(x+h) - f(x)}{h} - \frac{h}{2}f''(x) - \frac{h^2}{3!}f'''(x) + \dots$$

Uma aproximação da derivada se pode obter truncando esta fórmula até que se usam os termos simples: Aproximamos $f'(x)$ com $\frac{f(x+h)-f(x)}{h}$.

O erro de truncamento é

$$\left| f'(x) - \frac{f(x+h)-f(x)}{h} \right| = \left| \frac{h}{2}f''(x) + \frac{h^2}{6}f'''(x) + \dots \right|.$$

Sistema de Representação dos reais em virgula móvel (ponto flutuante, Floating Point)

Dado um numero x real a sua representação no sistema $FP(\beta, t, \ell, u)$ é \bar{x} definido como segue

$$\bar{x} = \pm m\beta^e \quad (\text{ou } fl(x) = \pm m\beta^e)$$

onde

- β é a base do sistema
- $m = 0.d_1d_2 \dots d_t$ é chamada mantissa do número \bar{x}
- t é o número de dígitos da mantissa
- e é um expoente que tem de ser contido no intervalo $[\ell, u]$,
 $e \in [\ell, u]$

O sistema de representação $FP(\beta, t, \ell, u)$ é chamado sistema de representação em virgula móvel, ou em ponto flutuante. Também pode ser chamada Aritmética de Ponto Flutuante.

Propriedades:

- β, t são inteiros positivos;
- $0 < d_1 < \beta - 1$;
- $0 \leq d_i \leq \beta - 1$ para $i = 2, \dots, t$
- ℓ, u são inteiros com $\ell < u$; Normalmente ℓ é negativo e u é positivo;
- O expoente e é um número inteiro no sistema com base β , tal que $e \in [\ell, u]$

Sistema Decimal

O sistema decimal usa $\beta = 10$

- $d_1 \in \{1, 2, 3, \dots, 9\}$
- $d_i \in \{0, 1, 2, 3, \dots, 9\}$
- 'e' é inteiro e tal que $\ell \leq e \leq u$, por exemplo se $\ell = -99, u = 98$ então o expoente 'e' é um inteiro que satisfaz $-99 \leq e \leq 98$.

Sistema Binário

O sistema binário usa $\beta = 2$, $FP(2, t, \ell, u)$

- $d_1 = 1$
- $d_i \in \{0, 1\}$
- $\ell \leq e \leq u$, por exemplo se $\ell = -11$ e $u = 10$,
e é um binário com dois dígitos entre -11 e 10 .

Truncamento e Arredondamento em $FP(\beta, t, \ell, u)$

Quando o número x tem mais de t dígitos, a sua aproximação (ou representação) \bar{x} em $FP(\beta, t, \ell, u)$ é obtida ou por truncamento ou por arredondamento a t dígitos significativos.

Quando usamos somente o truncamento dentro o sistema FP , então indicaremos o sistema de representação com $FP(\beta, t, \ell, u, T)$ se sem vez usassemos o arredondamento o sistema é $FP(\beta, t, \ell, u, A)$

Exemplos de Representação em $FP(10, 4, -99, 99)$

<i>Numero</i>	<i>Truncamento</i>	<i>Arredondamento</i>	Representação exata
1.256	$0.1256 * 10^1$	$0.1256 * 10^1$	Sim
10.2053	$0.1020 * 10^2$	$0.1021 * 10^2$	Não
-238.15	$-0.2381 * 10^3$	$-0.2382 * 10^3$	Não
-2.71828	$-0.2718 * 10^1$	$-0.2718 * 10^1$	Não
$7 * 10^{-9}$	$0.7 * 10^{-8}$	$0.7 * 10^{-8}$	Sim
$7.1267 * 10^{-9}$	$0.7126 * 10^{-8}$	$0.7127 * 10^{-8}$	Não
$-3.1437 * 10^2$	$-0.3143 * 10^3$	$-0.3144 * 10^3$	Não
$-3.143 * 10^2$	$-0.3143 * 10^3$	$-0.3143 * 10^3$	Sim
$7 * 10^{-100}$	$0.7 * 10^{-99}$	$0.7 * 10^{-99}$	Sim
$7 * 10^{-101}$	<i>underflow</i>	<i>underflow</i>	Não
10^{99}	<i>overflow</i>	<i>overflow</i>	Não
-10^{99}	<i>overflow</i>	<i>overflow</i>	Não

Maior valor positivo representável é $0.9999 * 10^{99}$,

Menor valor positivo representável é $0.1 * 10^{-99}$,

Maior valor negativo representável é $-0.1 * 10^{-99}$,

Menor valor negativo representável é $-0.9999 * 10^{99}$

Erro de Representação dos números reais

Cada vez que um número real x não é representado exatamente no sistema de ponto flutuante $FP(\beta, t, l, u)$ tem um erro ao considerar a sua representação $fl(x)$ obtida após o truncamento ou arredondamento.

Por exemplo no caso anterior se usássemos $FP(10, 4, -99, 99)$ com Truncamento, o valor $x = 10.2053$ é representado como $fl(x) = 0.1020 \cdot 10^2$ na FP e portanto cometemos um erro.

O erro $|x - fl(x)|$ chama-se **erro de representação** do valor x na $FP(\beta, t, l, u)$.

Os números que são representados exatamente no sistema de ponto flutuante tem um erro de representação nulo porque $x = fl(x)$.

Para os números que não são representados (porque correspondem a situação de overflow ou underflow) não se pode definir o erro de representação.

Erros de representação na aritmética finita

$FP(10, 4, -99, 99)$

Número	Trunc.	Arred.	Erro trunc.	Erro arred.
1.256	$0.1256 * 10^1$	$0.1256 * 10^1$	0	0
10.2053	$0.1020 * 10^2$	$0.1021 * 10^2$	0.0053	0.0047
-238.15	$-0.2381 * 10^3$	$-0.2382 * 10^3$	0.05	0.05
-2.71828	$-0.2718 * 10^1$	$-0.2718 * 10^1$	0.00028	0.00028
$7 * 10^{-9}$	$0.7 * 10^{-8}$	$0.7 * 10^{-8}$	0	0
$7.1267 * 10^{-9}$	$0.7126 * 10^{-8}$	$0.7127 * 10^{-8}$	$0.0007 * 10^{-9}$	$0.0003 * 10^{-9}$
$7 * 10^{-100}$	$0.7 * 10^{-99}$	$0.7 * 10^{-99}$	0	0
$7 * 10^{-101}$	<i>underflow</i>	<i>underflow</i>	Não existe	Não existe
10^{99}	<i>overflow</i>	<i>overflow</i>	Não existe	Não existe
-10^{99}	<i>overflow</i>	<i>overflow</i>	Não existe	Não existe

Valor exato e aproximação de uma medida x

Seja x um valor exato de uma medida ou de um cálculo matemático, ou de solução de um problema.

Quando modelamos o problema, ou truncamos um cálculo ou usamos um computador para computar a solução (note que os computadores usam normalmente sistemas de representação de aritmética finita com base binária $\beta = 2$)

obtemos somente uma aproximação \bar{x} em vez que o valor exato x do problema.

Erro absoluto e erro relativo

Definição do Erro Absoluto

O valor absoluto da diferença entre o valor exato x e a sua aproximação \bar{x} chama-se erro absoluto:

$$E_A(x) := |x - \bar{x}|$$

Propriedade: $|x - \bar{x}| \geq 0$,

O erro absoluto é sempre positivo ou nulo.

Os erros normalmente são consideradas como quantidades positivas ou nulas, mas as vezes será importante saber se x seja maior ou menor do valor aproximado \bar{x} .

Exemplo

Sabemos que as medidas $\bar{x} = 2112.9$ cm e $\bar{y} = 5.3$ cm aproximam respectivamente x e y a menos de um erro absoluto $E_A < 0.1$ cm. Que valor podem tomar x e y ?

Resposta: $x \in (2112.8, 2113)$,
 $y \in (5.2, 5.4)$

Erro relativo

É possível dizer qual é a melhor aproximação entre $\bar{x} \approx x$ e $\bar{y} \approx y$ se bem eles tem o mesmo erro absoluto?

A resposta é sim mas temos de analisar o erro relativo, ou seja escalar o erro absoluto respeito o tamanho do valor que queremos aproximar:

um erro de 0.1 cm tem mais peso (é mais significativo) no aproximar uma barra de comprimento tipo $x = 5.2 \text{ cm}$ que no aproximar uma barra de comprimento $y = 2112.8 \text{ cm} = 21.128 \text{ m}$

Erro relativo

Definição do Erro Relativo

O valor absoluto da diferença entre o valor exato x e a sua aproximação \bar{x} dividida por o valor absoluto do valor aproximado $|\bar{x}|$ chama-se erro relativo:

$$E_R(x) := \frac{|x - \bar{x}|}{|\bar{x}|}$$

Nalgum livro pode encontrar a definição do erro relativo dividindo por $|x|$.

Se $x = 5.2$, $\bar{x} = 5.3$ tem $E_R(x) = \frac{|x - \bar{x}|}{|\bar{x}|} = \frac{0.1}{5.3} = 0.02$
E' um erro relativo de 2% respeito \bar{x} .

Se $y = 2112.8$, $\bar{y} = 2112.9$ tem
 $E_R(y) = \frac{|y - \bar{y}|}{|\bar{y}|} = \frac{0.1}{2112.9} = 4.7 \cdot 10^{-5}$
E' um erro relativo de 0.0047% respeito \bar{y} .