



Laboratório de Pesquisa em Redes e Multimídia

Representação de Números em Ponto Flutuante

OBS: Esta aula é uma reprodução, sob a forma de slides, da aula em vídeo disponibilizada pelo prof. Rex Medeiros, da UFRN/ECT, em <https://youtu.be/OVuyMcnPKOc>



Universidade Federal do Espírito Santo
Departamento de Informática

Ponto Flutuante na Forma Normalizada

- A notação em ponto flutuante na forma normalizada é análoga à notação científica, com a diferença que a parte inteira é sempre igual a zero e o primeiro dígito após a vírgula (d_1) é sempre diferente de zero. Ex: $0,5678 \times 10^3$

$$\begin{aligned}x &= \pm 0, d_1 d_2 \dots d_p \times \beta^e \\ &= d \times \beta^e\end{aligned}$$

$$x \neq 0 \quad d_1 \neq 0 \quad d_1, \dots, d_p \in \{0, \dots, \beta - 1\}$$

- $d_1 d_1 d_2 \dots d_p =$ mantissa (5678)
- $p =$ precisão (4), que determina o número de dígitos na mantissa
- $\beta =$ base de numeração (10)
- $e =$ expoente (3)

Exemplos

1) Colocar na notação de ponto flutuante em forma normalizada, usando a base 10

- $2345,89 = 0,23589 \times 10^3$
- $0,0000586 = 0,586 \times 10^{-4}$
- $-12\ 000\ 000\ 000\ 000 = -0,12 \times 10^{14}$

2) Colocar o número $(-3,625)_{10}$ na notação de ponto flutuante em forma normalizada, usando a base 2

- Convertendo o número para a base 2: $(-11,101)_2$
- Normalizando: $(-0,11101 \times 2^2)$

Sistemas de Numeração em Ponto Flutuante

- Os sistemas computacionais representam os números reais por meio de um sistema de numeração em ponto flutuante, cuja forma padrão geral é:

Sistemas de Numeração em Ponto Flutuante

$$F(\beta, p, m, M)$$

β é a base, p é a precisão, m e M são os valores mínimos e máximos que o expoente pode assumir.

Exemplos

1) Escrever o número $(-3,625)_{10}$ no sistema $F(10,5,-3,3)$

1^o passo: colocar o número na forma normalizada, observando que ele já se encontra na base do sistema em questão

$$(-0,3625 \times 10^1)$$

2^o passo: verificar se o número de dígitos na mantissa é menor, igual ou maior do que a precisão do sistema de ponto flutuante. Se for menor acrescentamos zeros, se for igual já estará ok, e se for maior haverá um truncamento da mantissa, com arredondamento do seu dígito menos significativo. No caso do exemplo, o número de dígitos da mantissa (4) é menor do que a precisão (5) do sistema, então teremos de acrescentar um zero à direita.

$$(-0,36250 \times 10^1)$$

Exemplos

2) Escrever o número $(-3,625)_{10}$ no sistema $F(2,5,-3,3)$

1º passo: devemos primeiramente transformar o número da sua base 10 para a base 2, que é a base de numeração do sistema

$$(-0,3625)_{10} = (-11,101)_2$$

2º passo: colocar o número na forma normalizada


$$(-0,11101 \times 10^2)$$

3º passo: verificar se o número de dígitos na mantissa é menor, igual ou maior do que a precisão do sistema de ponto flutuante. Neste exemplo, o número de dígitos da mantissa (5) é exatamente igual à precisão (5) do sistema, então o número já está perfeitamente representado neste sistema de ponto flutuante

$$R: (-0,11101 \times 10^2)$$

Armazenamento de Números em PF na Memória

- A estratégia de armazenamento mais usada é a IEEE 754.
- Como exemplo, dado o sistema de ponto flutuante $F(2,3,-3,3)$, quantos bits são necessários para armazenar os números deste sistema na memória do computador?



Exemplo

- Como é representado o número $(1,75)_{10}$ na memória de um computador que trabalha com o sistema de ponto flutuante $F(2,3,-3,3)$?
- 1º passo: devemos converter o número $(1,75)_{10}$ para a base 2, que é a base usada pelo sistema


$$(1,75)_{10} = (1,11)_2$$

- 2º passo: colocar o resultado na forma normalizada:

$$(0,111 \times 2^1)$$

- 3º passo: observar o número de dígitos da mantissa (3) e comparar com a precisão do sistema (3). Como são iguais não precisamos fazer nada, já que temos exatamente 3 dígitos na mantissa.
- 4º passo: observar se o expoente está dentro do intervalo $(-3,+3)$ do sistema, o que é o caso. O número $(0,111 \times 2^1)$ está então perfeitamente representado no sistema F.

Exemplo



Representação em memória do número $(1,75)_{10} = (0,111 \times 2^1)_2$

Números Máximos e Mínimos em um Sistema de PF

1) Qual é o maior número representável no sistema $F(2,3,-3,3)$?

$$0,111 \times 2^3 = (2^{-1} + 2^{-2} + 2^{-3}) \times 2^3 = (2^2 + 2^1 + 2^0) = (4+2+1) = 7$$

2) Qual é o menor número representável no sistema $F(2,3,-3,3)$?

$$0,100 \times 2^{-3} = (2^{-1}) \times 2^{-3} = 2^{-4} = 1/16 = 0,062510$$

Fórmula Geral

Menor real positivo representado em $F(\beta, p, m, M)$

$$\begin{aligned}x_m &= 0, \underbrace{10\dots 0}_{p \text{ dígitos}} \times \beta^m \\ &= \beta^{m-1}\end{aligned}$$

Maior real positivo representado em $F(\beta, p, m, M)$

$$\begin{aligned}x_M &= 0, \underbrace{(\beta - 1)(\beta - 1)\dots(\beta - 1)}_{p \text{ dígitos}} \times \beta^M \\ &= (1 - \beta^{-p})\beta^M\end{aligned}$$

Exemplo 1

Representar $(8,25)_{10}$ em $F(2,3,-3,3)$.

1. Convertendo para a base 2: $(8,25) = 1000,01$
2. Normalizando: $0,100001 \times 2^4$
3. Acertando a mantissa: $0,100 \times 2^4$

(o tamanho da mantissa [6] é maior do que a precisão do sistema [3], então ocorre o truncamento. Como o quarto dígito da mantissa é zero, não há necessidade de arredondamento).

- Expoente: o valor do expoente do número normalizado (4) é maior do que o maior expoente do sistema (3), ou seja, o número $(8,25)_{10}$ não pode ser armazenado neste sistema já que ele é maior do que o maior número positivo suportado pelo sistema.
- Conclusão: OVERFLOW

Exemplo 2


Representar $(0,04)_{10}$ em $F(2,3,-3,3)$.

- Convertendo para a base 2: $(0,04) = 0,0000101000\dots$
- Normalizando: $0,101000 \times 2^{-4}$
- Acertando a mantissa: $0,101 \times 2^{-4}$

(como o tamanho da mantissa é maior do que a precisão do sistema [3], ocorre o truncamento. O quarto dígito da mantissa é zero, então não há arredondamento).

- Expoente: o valor do expoente do número normalizado (-4) é menor do que o menor expoente do sistema (-3); por isso, o número $(0,04)_{10}$ não pode ser armazenado neste sistema.
- Conclusão: UNDERFLOW!!


Intervalos de Representação em PF



Overflow: expoente maior que o expoente máximo
Underflow: expoente menor que o expoente mínimo

Exemplo

F(2,3,-3,3):



Maior número representável no sistema F(2,3,-3,3)?

$$0,111 \times 2^3 = (2^{-1} + 2^{-2} + 2^{-3}) \times 2^3 = (4+2+1) = 7_{10}$$

Menor número representável no sistema F(2,3,-3,3)?

$$0,100 \times 2^{-3} = (2^{-1}) \times 2^{-3} = 2^{-4} = (4+2+1) = 0,0625_{10}$$

Erros de Arredondamento

Representar $(2,8)_{10}$ em $F(2,3,-3,3)$.

- Convertendo para a base 2: $(2,8)_{10} = 10,110011001100\dots$
- Normalizando: $0,1011001100\dots \times 2^2$
- Acertando a mantissa: ao se truncar a mantissa no terceiro dígito observa-se que quarto dígito da mantissa é 1, então tem que haver um arredondamento.
- Arredondando: $0,1011001100 \dots \times 2^2 = 0,110 \times 2^2$
- Expoente: o valor do expoente do número normalizado (2) é menor do que o maior expoente positivo do sistema (+3).
- Conclusão: o número $(2,8)_{10}$ pode ser armazenado neste sistema de PF, observando-se que ocorre um erro de arredondamento.

Erros de Arredondamento (cont.)

- Convertendo o número $(0,110 \times 2^2)$ para a base 10, obtemos:
 $(1 \times 2^{-1} + 1 \times 2^{-2}) \times 2^2 = (2 + 1) = 3$
- Assim, o número real 2,8 é representado pelo número inteiro 3 no sistema de ponto flutuante $F(2,3,-3,3)$. Ocorre, portanto, um erro de arredondamento.
- Podemos quantificar este erro de arredondamento através do cálculo do *Erro Relativo*.

$$Er = \left| \frac{\text{valor verdadeiro} - \text{valor representado}}{\text{valor verdadeiro}} \right|$$

Erro Relativo

$$Er = \left| \frac{\text{valor verdadeiro} - \text{valor representado}}{\text{valor verdadeiro}} \right|$$

$$Er = |(2,8 - 3) / 2,8| = 0,0714... = 0,07 = 7\%$$

Epsilon (“ ϵ ”) do Sistema

- Dado um sistema de ponto flutuante qualquer, qual é o erro relativo máximo (epsilon “ ϵ ” do sistema) que podemos ter?

Epsilon (ϵ) de um sistema em ponto flutuante

$$F(\beta, p, m, M)$$

$$\epsilon = \frac{\beta^{1-p}}{2}$$

Para o sistema $F(2,3,-3,3)$:

$$\epsilon = \frac{2^{1-3}}{2} = 0,125$$

Aritmética em Ponto Flutuante

- Multiplicação:
 - Multiplica-se as mantissas e somam-se os expoentes
- Divisão:
 - Divide-se as mantissas e diminuem-se os expoentes
- Calcular $(0,2135 \times 10^2) \times (0,3064 \times 10^{-2})$ em $F(10, 4, -7, 7)$
 - Multiplicando: $(0,2135) \times (0,3064) \times (10^{2-2}) = 0,0654164 \times 10^0$
 - Normalizando: $0,654164 \times 10^{-1}$
 - Ajustando a precisão para 4 dígitos: $0,6542 \times 10^{-1}$
 - Observe que houve a necessidade de arredondamento
 - Resultado final: $0,6542 \times 10^{-1}$

Aritmética em Ponto Flutuante (cont.)

- Soma e Subtração:
 - Igualam-se os expoentes (i.e. iguala-se o valor do expoente menor ao maior)
 - Soma-se/subtrai-se as mantissas
- Calcular $(0,1101 \times 2^1) + (0,1010 \times 2^0)$ em $F(2, 4, -3, 3)$
 - Igualando-se o menor expoente ao maior: $(0,1010 \times 2^0) = (0,01010 \times 2^1)$
 - Somando-se as mantissas: $(0,1101) + (0,01010) = 0,1110010$
 - Resultado: $(1,00100 \times 2^1)$
 - Normalizando o resultado: $(0,100100 \times 2^2)$
 - Ajustando a precisão para 4 dígitos: $(0,1001 \times 2^2)$
 - Não houve necessidade de arredondamento
 - Resultado final: $(0,1001 \times 2^2)$

Operações Críticas

- Adição e Subtração de Números com Ordens de Grandezas Muito Diferentes
 - Nestes casos, geralmente o menor número perde muita precisão pois nesta situação seus dígitos menos podem ser descartados durante a operação.
 - Calcular $(0,1101 \times 2^2) + (0,1010 \times 2^{-1})$ em $F(2, 4, -3, 3)$
 - Igualando-se os expoentes: $(0,1010 \times 2^{-1}) = (0,0001010 \times 2^2)$
 - Somando-se as mantissas: $(0,1101) + (0,0001010) = 0,11100010$
 - Resultado: $0,11100010 \times 2^2$ (já está normalizado)
 - Ajustando a precisão para 4 dígitos: $(0,1110 \times 2^2)$
 - Observe que ao ajustar a mantissa para 4 dígitos, a contribuição do segundo número para a soma foi apenas 0,0001, descartando-se os dígitos 010 menos significativos.

Operações Críticas (cont.)

- Subtração de Números Quase Iguais
 - Nestes casos, geralmente o menor número perde muita precisão pois nesta situação seus dígitos menos podem ser descartados durante a operação.
- Calcular $(0,1011 \times 2^{-1}) - (0,1010 \times 2^{-1})$ em $F(2, 4, -3, 3)$
 - Expoentes já são iguais
 - Subtraindo-se as mantissas: $(0,1011) - (0,1010) = 0,0001$
 - Resultado: $(0,0001) \times 2^{-1}$
 - Normalizando: $(0,1 \times 2^{-3}) \times 2^{-1} = 0,1 \times 2^{-4}$
 - Ajustando a precisão para 4 dígitos: $(0,1000 \times 2^{-4})$
 - Observe que o expoente (-4) é menor do que o expoente mínimo do sistema (-3).
 - Conclusão: UNDERFLOW!!