

REPRESENTAÇÃO DE NÚMEROS EM VÍRGULA FLUTUANTE

TeSP de Aplicações Móveis

André Martins Pereira



REPRESENTAÇÃO EM VÍRGULA FIXA

- Valores “reais” (fracionários) são representados com um nº de *bits* **fixo** antes e depois da vírgula/ponto:
 - $4.5_{10} = 1*2^2+0*2^1+0*2^0+1*2^{-1}+0*2^{-2} = 100.10_2$
- Problema:
 - Como representar números muito próximos de zero? 4.00001, por exemplo?
 - › Muitos bits depois da vírgula/ponto...
 - › $4.000001_{10} = 100.???_2$
 - E um número muito grande?
 - › $4*2^{365}_{10} = 01000000000...0_2$ (“100” seguido de 365 zeros)
- Existe forma mais eficiente de representar estes casos?

REPRESENTAÇÃO EM VÍRGULA FLUTUANTE

- Solução: usar uma norma, uma notação científica
 - 20 000 000 = $2 \cdot 10^7$,
 - 400 000 000 000 = 4E11
- Representação de valores na seguinte forma: $V = (-1)^s * M * \text{Radix}^E$
 - RADIX = 2 -> binário ; RADIX = 10 -> decimal
- **S** -> Bit do sinal
 - $S = 0 \rightarrow V > 0$; $S = 1 \rightarrow V < 0$
- **M** -> Mantissa (ou parte fracionária **F**)
 - Valor fracionário em binário ($1 \leq M < 2$, ou $0 \leq M < 1$).
- **E** -> Expoente
 - Usado para aumentar a amplitude do valor

FLOATING POINT - NORMALIZAÇÃO

- Notação científica permite representar o mesmo nº de várias formas
 - $43.789 \cdot 10^{12} = 0.43789 \cdot 10^{14}, 43789 \cdot 10^9$
- Objetivo: normalizar!
 - Impedir que o mesmo número tenha representações diferentes
- Um número está normalizado se a Mantissa (**M**) se encontra no intervalo **]Radix , 1]**
 - Ou seja, existe sempre um dígito diferente de 0 à esquerda do ponto decimal
 - $1.4 \cdot 10^5$ -> **Normalizado!**
 - $0.14 \cdot 10^6$ -> **Desnormalizado!**
- E em binário? Qual o valor de **M** para que esteja normalizado?
 - $2 > M \geq 1$

FLOATING POINT – BIT “ESCONDIDO”

- Valor **normalizado** tem sempre um dígito diferente de zero
 - À esquerda do ponto decimal
- Se um valor é **normalizado**, não faz sentido representar um valor que é sempre igual!
- Só é necessário para efetuar as operações
- Logo, aquando da representação, **não se representa a parte inteira**

FLOATING POINT – EXPOENTE

- Representação: **Excesso $2^{n-1}-1$**
- Porquê?
 - É uma representação contínua
 - Mais fácil o *hardware* comparar grandezas
 - Exemplo: comparar dois números
 - › 0 01011011 10110011010010101101101
 - ↑
 - › 0 10000100 01101010110010111101101
 - ↑

FLOATING POINT - NORMALIZAÇÃO

- Representação normalizada: $V = (-1)^S * 1.M * 2^E$
 - E = Exp - Excesso
- **Problema:** Números muito próximos do zero não estão abrangidos!
- **Solução:** Considerar menor valor possível do expoente para representação **APENAS** de valores **desnormalizados**
- Todas as outras representações designam-se por **não normalizadas**
- Representação desnormalizada: $V = (-1)^S * 0.M * 2^E$
 - E = - (Excesso - 1)

FLOATING POINT – INTERVALO VALORES REPRESENTÁVEIS

- O objetivo passa **sempre** por:
 - Obter o maior intervalo de representação possível: representar o maior número possível de valores
 - Conseguir melhor precisão: diminuir distância entre 2 valores consecutivos
- Número limitado de *bits* para **M** e **Exp**
 - O que acontece ao aumentar um e outro?
 - Intervalo depende de **Exp**; Precisão depende de **N**
- Número total de *bits* **tem de ser** um múltiplo de 8
 - Uma célula de memória tem... 8 bits!
 - Se nº bits não for múltiplo de 8 vão ser desperdiçados *bits* em memória
 - Exemplo: **S** -> 1 bit; **M** -> 5 bits; **Exp** -> 13 bits

| | |
|------------------------|--------|
| 01 01 11 11 | 0x0001 |
| 01 11 11 10 | 0x0002 |
| 101 - - - - | 0x0003 |
| ... | 0x0004 |
| ... | 0x0005 |
| ... | 0x0006 |
| ... | 0x0007 |
| ... | 0x0008 |
| ... | 0x0009 |
| ... | 0x000A |

FLOATING POINT – INTERVALO VALORES REPRESENTÁVEIS

- Número total de *bits* deve ser pelo menos 32
 - Com 16 -> 1 *bit* para sinal, 15 *bits* para **M** + **Exp**
 - 15 *bits* são **insuficientes** apenas para **M**
 - Precisão seria apenas de 4 algarismos
- Assim, com 32 *bits* usamos:
 - **8** para **Exp**: permite representar uma gama da ordem de grandeza dos 10^{39}
 - **23** para **M**: permite uma precisão equivalente a 7 algarismos decimais

FLOATING POINT – NORMA IEEE 754 (1985)

- Representação com o formato definido até aqui ainda tem imprecisões
 - Várias combinações para representar o mesmo número
 - Como representar valores **desnormalizados**?
 - E valores fora do intervalo permitido com a notação normalizada?
- Norma IEEE 754 define claramente estas imprecisões
- Representação do sinal e parte fracionária
 - Formato definido anteriormente
- Representação do expoente
 - Excesso 127
 - Varia entre -127 e 128

FLOATING POINT – NORMA IEEE 754 (1985)

- Valor decimal de um *fp* em binário (normalizado):
 - $V = (-1)^S * (1.F) * 2^{E-127}$
- Representação de valores desnormalizados
 - $V = (-1)^S * (0.F) * 2^{-126}$
 - Norma IEEE reserva o valor de $E = 0000\ 0000_2$ para representar valores desnormalizados
- Representação do zero
 - $E = 0$ e $F = 0$
- Representação de $\pm\infty$
 - $E = 1111\ 1111_2$ e $F = 0$
- Representação de n.º não real
 - $E = 1111\ 1111_2$ e $F \neq 0$

FLOATING POINT – NORMA IEEE 754 (1985)

| | | | |
|--------------|---|-------------------------------|-------------------------|
| Normalized | ± | $0 < \text{Exp} < \text{Max}$ | Any bit pattern |
| Denormalized | ± | 0 | Any nonzero bit pattern |
| Zero | ± | 0 | 0 |
| Infinity | ± | 1 1 1...1 | 0 |
| Not a number | ± | 1 1 1...1 | Any nonzero bit pattern |

← Sign bit

FLOATING POINT - EXERCÍCIOS

- Pequeno 1
 - $V = (-1)^S * 1.F * 2^{E-7}$
 - › Expoente: 4 bits
 - › Mantissa: 3 bits
- Pequeno 2
 - $V = (-1)^S * 1.F * 2^{E-3}$
 - › Expoente: 3 bits
 - › Mantissa: 4 bits

REPRESENTAÇÃO DE NÚMERO EM VÍRGULA FLUTUANTE

