

## Unidade 3

### Aritmética Computacional

#### Uma breve introdução

Autores: Fernando Gehm Moraes & Ney Laert Vilar Galazans

Porto Alegre, junho de 1998

Última revisão: 18/outubro/2001



## Sumário

### Introdução



### Aritmética Inteira

- Operações em números sem sinal (naturais)
  - » soma, subtração, multiplicação e divisão
- Representações de números com sinal (inteiros)

### Aritmética não Inteira (racionais)

- Representação de racionais
- Operações como padrão IEEE-754



## Sumário

### Introdução



## Introdução a Aritmética Computacional

Uma parte especializada do projeto de computadores

Contudo, uma parte muito, muito importante:

- gráficos, comunicações, transações bancárias, matemática computacional, cálculo de estruturas, solução de equações, entre tantas aplicações;
- Intel perdeu US\$ 300 milhões devido ao “bug” do Pentium (otimizou errado um PLA usado em ÷);
- Aqui, revisão estendida de inteiros e padrão para números racionais (IEEE-754).

## Introdução a Aritmética Computacional

### Bibliografia:

- Patterson, D. A “Computer Architecture: a quantitative approach”, Morgan Kaufmann Pubs., 1996. Appendix A
- Texas Instruments. “TMS320C4x User’s Guide”, 1996. Capítulo 5. Disponível na Internet (formato PDF):
  - » <http://www.s.ti.com/sc/psheets/spru063b/spru063b.pdf>
  - » <ftp://ftp.inf.pucrs.br/pub/calazans/texas/spru063b.pdf>

## Sumário

### Introdução



### Aritmética Inteira

- Operações em números sem sinal (naturais)
  - » soma, subtração, multiplicação e divisão



## Operações sobre naturais - Soma

Hardware mais simples - baseado em ripple-carry (propagação em onda do vai-um) e componentes simples (meiosomador e somador completo)

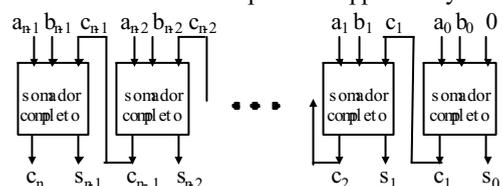
Equações dos componentes:

- meio-somador:  $s_i = a_i \oplus b_i$ ;  $c_{i+1} = a_i b_i$ ;

- somador completo:  $s_i = a_i \oplus b_i \oplus c_i$ ;  
 $c_{i+1} = a_i b_i \vee (a_i \oplus b_i) c_i$ .

## Operações sobre naturais - Soma

Estrutura do somador completo “ripple-carry”:

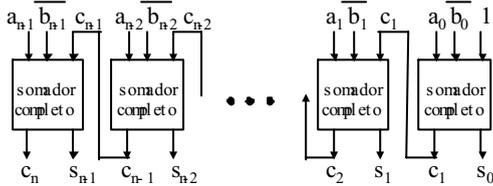


Problema: atraso de geração do vai-um  $= O(n)$ , onde  $n$  é o número de bits do somador;

Hardware adiciional  $\rightarrow$  atraso  $= O(\log n)$ .

## Operações sobre naturais - Subtração

❑ Estrutura do subtrator completo a "ripple-carry":

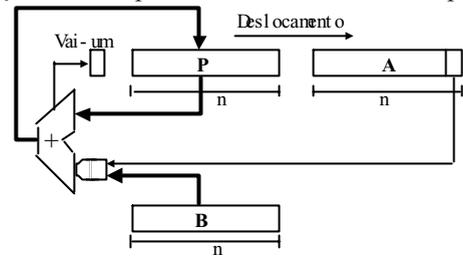


❑ Mesmo problema de atraso, solução analoga;

❑ Problema adicional, operação não definida se  $b > a$ .

## Operações sobre naturais - Multiplicação

❑ Solução natural para  $a \cdot b$ : somas sucessivas  $n$  passos;

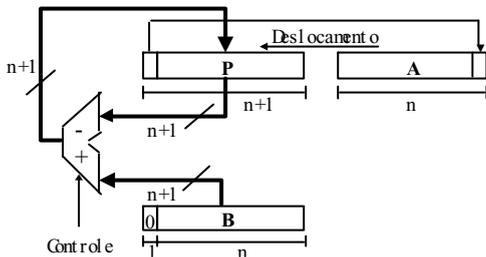


❑ Inicialmente,  $P=0$ ,  $A=a$ ,  $B=b$ . Cada passo, duas partes:

- soma carregada em P;
- P & A deslocado um bit para a direita.

## Operações sobre naturais - Divisão

❑ Solução para  $a/b$ : subtração sucessivas,  $n$  passos;



❑ Cada passo, quatro partes: 1) desloca P & A/ esq 1 bit; 2)  $P < P - B$ ; 3) If (passo  $2 < 0$ ),  $A_0 = 0$  else  $A_0 = 1$ ; 4) If (passo  $2 < 0$ ), restaura P fazendo  $P < P + B$ .

## Divisão A/B - Exemplo

A = 11011 (27)  
B = 00101 (5)

A cada passo, mostra-se P e A após as partes

- 1) - primeira linha
- 4) - segunda linha

1) ca P & A/ esq 1 bit;

2)  $P < P - B$ ;

3) If (P < 0),  $A_0 = 0$  else  $A_0 = 1$ ;

4) If (P < 0), restaura P fazendo  $P < P + B$

passo	P (conterá o resto)					A (conterá a divisão)				
0	0	0	0	0	0	1	1	0	1	1
1	0	0	0	0	0	1	0	1	1	0
2	0	0	0	0	0	1	0	1	1	0
3										
4										
5										

## Divisão A/B - Exemplo

A = 11011 (27)  
B = 00101 (5)

A cada passo, mostra-se P e A após as partes

- 1) - primeira linha
- 4) - segunda linha

1) ca P & A/ esq 1 bit;

2)  $P < P - B$ ;

3) If (P < 0),  $A_0 = 0$  else  $A_0 = 1$ ;

4) If (P < 0), restaura P fazendo  $P < P + B$

1) ca P & A/ esq 1 bit;

2)  $P < P - B$ ;

3) If (P < 0),  $A_0 = 0$  else  $A_0 = 1$ ;

4) If (P < 0), restaura P fazendo  $P < P + B$

passo	P (conterá o resto)					A (conterá a divisão)				
0	0	0	0	0	0	1	1	0	1	1
1	0	0	0	0	0	1	0	1	1	0
2	0	0	0	0	1	1	0	1	1	0
3	0	0	0	0	1	1	0	1	1	0
4										
5										

## Divisão A/B - Exemplo

A = 11011 (27)  
B = 00101 (5)

A cada passo, mostra-se P e A após as partes

- 1) - primeira linha
- 4) - segunda linha

1) ca P & A/ esq 1 bit;

2)  $P < P - B$ ;

3) If (P < 0),  $A_0 = 0$  else  $A_0 = 1$ ;

4) If (P < 0), restaura P fazendo  $P < P + B$

passo	P (conterá o resto)					A (conterá a divisão)				
0	0	0	0	0	0	1	1	0	1	1
1	0	0	0	0	0	1	0	1	1	0
2	0	0	0	0	1	1	0	1	1	0
3	0	0	0	0	1	1	0	1	1	0
4	0	0	0	0	1	1	0	1	1	0
5										

00110 - 00101 = 001

## Divisão A/B - Exemplo

A = 11011 (27)  
B = 00101 (5)

A cada passo, mostra-se P e A após as partes

- 1) - primeira linha
- 4) - segunda linha

1) ca P & A/ esq 1 bit;

2)  $P < P - B$ ;

3) If (P < 0),  $A_0 = 0$  else  $A_0 = 1$ ;

4) If (P < 0), restaura P fazendo  $P < P + B$

1) ca P & A/ esq 1 bit;

2)  $P < P - B$ ;

3) If (P < 0),  $A_0 = 0$  else  $A_0 = 1$ ;

4) If (P < 0), restaura P fazendo  $P < P + B$

passo	P (conterá o resto)					A (conterá a divisão)				
0	0	0	0	0	0	1	1	0	1	1
1	0	0	0	0	0	1	0	1	1	0
2	0	0	0	0	1	1	0	1	1	0
3	0	0	0	0	1	1	0	1	1	0
4	0	0	0	0	1	1	0	0	1	0
5										

Resto = 2

resultado = 5

## Divisão A/B - Exemplo

A = 11011 (27)  
B = 00101 (5)

A cada passo, mostra-se P e A após as partes

- 1) - primeira linha
- 4) - segunda linha

1) ca P & A/ esq 1 bit;

2)  $P < P - B$ ;

3) If (P < 0),  $A_0 = 0$  else  $A_0 = 1$ ;

4) If (P < 0), restaura P fazendo  $P < P + B$

passo	P (conterá o resto)					A (conterá a divisão)				
0	0	0	0	0	0	1	1	0	1	1
1	0	0	0	0	0	1	0	1	1	0
2	0	0	0	0	1	1	0	1	1	0
3	0	0	0	0	1	1	0	1	1	0
4	0	0	0	0	1	1	0	0	1	0
5	0	0	0	1	1	1	0	0	1	0

## Operações sobre naturais - Divisão

- Algoritmo: versão binária - procedimento lápis e papel;
- Existe versão sem restauração de P (ver H & P);
- $n$  passos, somador maior que na multiplicação;
- Deve-se testar se divisor  $\neq 0!$
- Restauração desnecessária se teste na saída do somador/subtrator, bem como somador.

## Sumário

Introdução

Aritmética Inteira

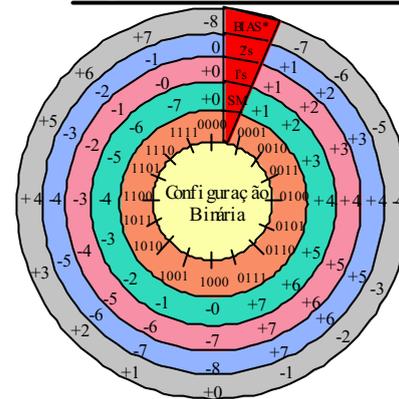
- Operações em números sem sinal (naturais)
  - soma, subtração, multiplicação e divisão
- Representações de números com sinal (inteiros)



## Representações de Inteiros

- Quatro métodos comuns (convenções) para inteiros:
  - sinal-magnitude (SM) - bit mais significativo é sinal, restante é o valor absoluto equivalente a binário sem sinal;
  - complemento de 1 ( $1$ 's) - positivos, idem a SM, negativos são positivos com valor invertido;
  - complemento de 2 ( $2$ 's) - positivos, idem a SM, negativos obtidos adicionando 1 a  $1$ 's;
  - potência de 2 (bias) - representação é a do positivo binário obtido a partir da soma de um valor  $k$ .

## Representações de Inteiros - 4 formas



- Exemplo para 4 bits
- \* potência de 2 =  $2^{(n-1)} = 8$
- Bias tem distribuição uniforme na representação binária puros;
- $2$ 's facilita soma;
- $1$ 's facilita complementação;
- SM é fácil de entender e separa sinal de valor;

## Transbordamento em Inteiros (Overflow)

- Casos de transbordamento em complemento de 2 ( $2$ 's)
  - Para 5 bits, faixa representável é  $-16$  a  $+15$

Decimal	Binário	Decimal	Binário	Decimal	Binário
Vai-um:	00111	Vai-um:	11011	Vai-um:	00001
+ 5	00101	- 5	11011	+ 5	00101
+ 7	00111	- 7	11001	- 7	11001
+12	01100	-12	10100	- 2	11110

Decimal	Binário
Vai-um:	11111
- 5	11011
+ 7	00111
+ 2	00010

## Transbordamento em Inteiros (Overflow)

- Casos de transbordamento em complemento de 2 ( $2$ 's)
  - Para 5 bits, faixa representável é  $-16$  a  $+15$

Decimal	Binário	Decimal	Binário	Decimal	Binário
Vai-um:	00111	Vai-um:	11011	Vai-um:	00001
+ 5	00101	- 5	11011	+ 5	00101
+ 7	00111	- 7	11001	- 7	11001
+12	01100	-12	10100	- 2	11110

### Transbordos positivos e negativos

Decimal	Binário	Decimal	Binário
Vai-um:	01000	Vai-um:	10000
+ 8	01000	- 8	11000
+ 9	01001	- 9	10111
+17	10001	-17	01111

Xor de 2 últimos vai-uns identifica transbordo. Negativo! Positivo!

## Sumário

Introdução

Aritmética Inteira

- Operações em números sem sinal (naturais)
  - soma, subtração, multiplicação e divisão
- Representações de números com sinal (inteiros)

Aritmética não Inteira (racionais)

- Representação de racionais



## Aritmética não Inteira (racionais)

- Muitas aplicações requerem números não-inteiros:
  - matemática computacional, engenharia, etc;
- Racionais (Q): representados como fração  $a/b$ ,  $a$  e  $b$  inteiros; Irracionais (I): têm mantissa infinita sem repetição ( $e \Rightarrow 7218\dots$  e  $\pi \Rightarrow 3.14\dots$ , por exemplo);
- Reais:  $\mathbb{C} \cup \mathbb{I}$ ;  $\mathbb{I}$  e  $\mathbb{R}$  não representáveis em computadores, por quê?
- Aproximação de reais em computadores: Q

## Aritmética não Inteira - representações

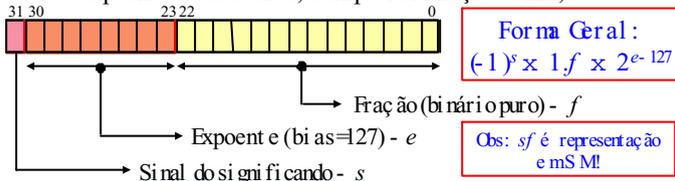
- Primos computadores - ponto (ou vírgula) fixo;
- Hoje, apenas ponto flutuante; representações possuem um *significandos* (a mantissa do número), um *expoente* e uma *base*, e o número é dado por:  $s \times b^e$ ;
- Antes, muitos formatos, hoje, padrão quase universal: definido pela IEEE (IEEE-754-1985), quatro formatos, dois fixos (precisão simples, SP e precisão dupla, DP) e dois variáveis (precisão simples, SE, e dupla, DE, estendidas). Igual ao padrão internacional IEC-559.

## Uma Representação de racionais - IEEE-754-1985

- Diferenças para formatos anteriores à padronização:
  - ao arredondar um resultado no meio da faixa, pega valor par mais próximo;
  - inclui valores especiais:
    - NaN - Not a Number (ex: raiz de negativo);
    - ∞ e -∞ - Mais ou menos infinito (ex: -1/0 e +1/0);
  - números denormalizados para resultados com valor menor que  $+1.0 \times 2^{\text{Emín}}$ ;
  - arredonda para mais próximo (default) mas tem mais três modos de arredondamento;
  - recursos sofisticados para lidar com exceções.

## Uma Representação de racionais - IEEE-754-1985

- Formato SP ocupa exatamente 32 bits:
  - 1 bit para sinal do significando - s;
  - significando com 24 bits de precisão, primeiro sempre 1, exceto quando denormalizado, onde é 0 (1º bit implícito);
  - expoente e de 8 bits, polarização = 127;



## IEEE-754-1985 - Exemplos

1) Número positivo, maior que zero

Forma Geral:  $(-1)^s \times 1.f \times 2^{e-127}$

010000001 010000000000000000000000

$((-1)^0 \times 1.01 \times 2^{129-127})_2 = (+1.01 \times 2^2)_2 = (+5)_{10}$

2) Número negativo, menor que zero

101111110 011100000000000000000000

$((-1)^1 \times 1.0111 \times 2^{126-127})_2 = (-0.10111)_2 = (-0.71875)_{10}$

## IEEE-754-1985 - Valores especiais e denormalização

- Principais novidades do padrão é existência de valores especiais, que permitem tratar exceções:
  - valores infinitos;
  - divisão por zero;
  - operações para os quais os reais não são fechados, como raiz quadrada;
- Denormalização permite situações de "underflow" gradual, tal como: 00000001 000000000000000000000000 (=  $2^{-126}$ ) dividido por  $2^5$ , representável se o primeiro dígito for 0 ao invés de 1, por: 00000000 000100000000000000000000.

## IEEE-754-1985

- Há 5 casos que definem valor de número em algum formato do padrão IEEE-754 (exemplo para SP):

1) $e=255, f \neq 0$	$v = \text{NaN}$ (not a number)
2) $e=255, f=0$	$v = (-1)^s \cdot \infty$
3) $0 < e < 255$	$v = (-1)^s \times (1.f) \times 2^{e-127}$
4) $e=0, f \neq 0$	$v = (-1)^s \times (0.f) \times 2^{-126}$
5) $e=0, f=0$	$v = (-1)^s \times 0$ (zero)

## IEEE-754-1985 - Valores especiais e denormalização

- Os diferentes formatos e valores para os parâmetros que os definem

formato -> parâmetros	precisão simples (SP)	precisão simples estendida (SE)	precisão dupla (DP)	precisão dupla estendida (DE)
bits de precisão (p)	24	≥32	53	≥64
Emáx	127	≥1023	1023	≥16383
Emín	-126	≤-1022	-1022	≤-16382
Polarização (bias)	127	depende	1023	depende
Total de bits	32, exatamente	variável, ≥43, <64	64, exatamente	variável, ≥79

## Sumário

- Introdução
- Aritmética Inteira
  - Operações em números sem sinal (naturais)
    - soma, subtração, multiplicação e divisão
  - Representação de números com sinal (inteiros)
- Aritmética não Inteira (racionais)
  - Representação de racionais
    - Operações como padrão IEEE-754



- ☒ Operação mais fácil de implementar em hardware:
  - multiplicação e não soma
    - » adaptação de significandos devido a diferentes expoentes complicada soma;
    - » multiplicação é direta, multiplica significandos e soma expoentes, exceto quando resultado é caso especial;
- ☒ Veremos aqui introdução a ambos, multiplicação e soma.

- ☒ 3 Passos:
  - multiplicar significandos (não fração, descompactar o número) usando multiplicação inteira, sem sinal (SM);
  - calcular expoente
    - » lembrar da polarização.
  - arredondamento devido ao aumento da precisão após operação;

**Operação de multiplicação como padrão IEEE-754**

- ☒ Exemplo de multiplicação:
  - 1 10000010 000000000000000000000000 =  $-1 \times 2^3 = -8$
  - 0 10000011 000000000000000000000000 =  $1 \times 2^4 = 16$
  - 1) Descompactando  $\rightarrow 1.0 \times 1.0 = 1.0$ 
    - » logo, resultado tem a forma:
  - 1 ???????? 000000000000000000000000
  - 2) Expoente - fórmula para cálculo do expoente:
    - (exp polarizado  $(e_1 + e_2)_{2's}$ ) = (exp polarizado  $(e_1)$ ) + (exp polarizado  $(e_2)$ ) + (-polarização) $_{2's}$ , ou seja,

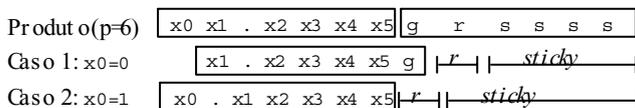
$$\begin{array}{r}
 10000010 = 130 \\
 10000011 = 131 \\
 +10000001 = -127 \\
 \hline
 10000110 = 134 = e \rightarrow E = 134 - 127 = 7!
 \end{array}$$

**Operação de multiplicação como padrão IEEE-754**

- 3) arredondamento - precisão é importante:
    - » casos de arredondamento (em decimal, análogo a binário):
- a)  $1.23 \times 6.78 = 8.3394$   $r=9, 9 > 5$ , então arredonda p/8 .34
- b)  $2.83 \times 4.47 = 12.6501$   $r=5$ , e pelo menos um dígito após diferente de 0, arredonda p/  $1.27 \times 10^1$
- c)  $1.28 \times 7.81 = 9.9968$   $r=6, 6 > 5$ , então arredonda p/  $1.00 \times 10^1$
- » em binário, não da faixa (5 em decimal) é dígito 0!
  - » negrito - dígitos significativos; após, dígito arredondador, r.

**Operação de multiplicação como padrão IEEE-754**

- 3) arredondamento (contínuação)
  - » se r é menor que 5 - resultado pronto;
  - » se r é maior que 5 - soma-se 1 ao número em negrito;
  - » se arredondador exatamente 5 (em binário, 1) - examinar bits seguintes, até achar um diferente de 0 ou chegar ao fim:
    - técnica - usa o "bit grudado" (sticky bit), durante a multiplicação, o CUI ló gico de todos os bits a partir do bit r;
    - Caso 1 - desloca um bit p/ esq; Caso 2 - incrementa expoente.



**Operação de multiplicação como padrão IEEE-754**

- 3) arredondamento (contínuação)
  - » após acertar expoente e resultado, pode-se finalmente arredondar:
    - se r=0, resultado correto;
    - se r=1 e s=1, soma P+1 para obter o produto dos significandos;
    - se r=1 e s=0, exatamente no meio da faixa - IEEE-754 possui quatro possibilidades, cujo comportamento depende do sinal do resultado.

**IEEE-754-1985 - Multiplicação e denormalização**

- ☒ Controlar underflow é complicado, devido aos denormalizados:
  - por exemplo,  $1 \times 2^{-64} \times 1 \times 2^{-65} = 1 \times 2^{-129}$ , expoente não representável no formato normalizado, mas representável como  $0.125 \times 2^{-126}$ ;
  - se o expoente não polarizado for menor que -126, produto deve ser deslocado bit a bit e expoente incrementado até -126. Se todo o significando se anular, aí sim houve underflow
- ☒ Quando um dos operandos é denormalizado, gera-se 0s à esquerda;
- ☒ Denormalizados causam problemas p/ multiplicação;
- ☒ Multiplicadores de alto desempenho ignoram denormalizados, gerando exceções para o software cuidar;
- ☒ Denormalizados não são frequentes, perda em tempo é estatisticamente pequena.

**IEEE-754-1985 - Multiplicação, 0 e Precisão**

- ☒ Se um dos multiplicandos é 0, acelera-se multiplicação testando:
  - antes - ambos operandos;
  - depois - neste caso, cuidado com 0 :  $\infty$ , resultado deve ser NaN
  - sinal deve ser mantido, +0 é diferente de -0;
- ☒ Ao multiplicar pode-se precisar do dobro de bits em inteiros; aplicação define se é aceitável apenas a metade inferior do resultado ou se todo o resultado deve ser usado;
- ☒ Em linguagens de alto nível, multiplicação inteira sempre usamos a primeira opção, mas ponto flutuante é diferente, e as duas são usadas, utilidade é grande na solução de equações lineares;

- Tipicamente, operação em ponto flutuante recebe dois números de mesma precisão e retorna resultado com mesma precisão,  $p$ ;
- Algoritmo ideal (erro menor) calcula resultado exato e arredonda;
- Multiplicação funciona assim;
- Para somar, existem procedimentos mais efetivos;
- Exemplo com números de 6 bits:  $1.1001_2$  e  $1.10001_2 \times 2^{-5}$ ;
- Usando um somador de 6 bits, tem-se:

$$\begin{array}{r} 1.10011 \\ +0.00001 \\ \hline 1.10100 \end{array}$$

### Operação de adição de $a_1$ e $a_2$ - Algoritmo

- Se  $e_1 < e_2$ , trocar operandos (para que diferença  $e_1 - e_2 \geq 0$ ). Fazer o expoente do resultado igual a  $e_1$ , temporariamente;
- Se sinais de  $a_1$  e  $a_2$  diferem, substituir  $s_2$  por seu complemento de 2;
- Colocar  $s_2$  em um registrador de  $p$  bits e deslocá-lo  $d = e_1 - e_2$  posições para a direita (entrando com 1's se  $s_2$  foi complementado no passo 2). Os bits deslocados para fora do registrador, guardar o último em um flip-flop  $g$ , o penúltimo em um flip-flop  $r$  e armazenar o ou de todos os restantes com *sticky bit*.
- ... Este e mais outros quatro passos são concluídos como o passo 3, somando 8 passos no algoritmo. Etudo isso implementado em hardware!!!

### Soma

- passo 4: SOMA
  - $1.111 + 0.010 = 0.001$  e  $cout = 1$
- passo 5: *mito complotado* ...
  - Se mesmo sinal: desloca para a direita, inserindo 1 e atualiza expoente
  - $1.0001$  e expoente passa a ser 1
- passo 6: atualiza  $g, r, s$ 
  - $g = 1, r = 0, s = 1$
- passo 7: arredonda
  - $1.000101 \Rightarrow 1.0010$  (ou seja:  $10.001 \Rightarrow 2, 125$ )
- passo 8: calcula o sinal *mito complotado* ...
  - Se mesmo sinal: não muda

### Exercícios

Supor que tenhamos a seguinte representação para ponto flutuante: 1 bit para sinal, 4 para expoente e 7 para a parte fracionária (ou seja, na norma IEEE 754 para 12 bits, com as mesmas condições para NaN,  $\infty$ ).

Qual o valor da polarização e quais os expoentes mínimo e máximo?  
**Valor da polarização: 7;**  
**Expoente máximo +7 (1110-7) e exp mínimo -7 (0000-7).**

Converta para base decimal: **0 1010 1011000** e **1 0111 0101000**  
 $+2^{(10-7)} * 1.1011 = +2^3 * 1.1011 = 1101.1 = 13.5$   
 $-2^{(7-7)} * 1.0101 = 2^0 * 1.0101 = 1.0101 = -1.3125$

- No exemplo, bit descartado é 1, logo resto deveria ser examinado;
- Novamente, apenas se precisa saber se um destes bits é não-zero, e pode-se assumir "sticky bits", como na multiplicação;
- Logo, para somar números de  $p$  bits, um somador de  $p$  bits chega, desde que se guarde o primeiro bit descartado e o "sticky bit" correspondente;
- No exemplo acima, o sticky é 1, e o resultado final fica  $1.10101_2$ ;
- Subtração é similar, se se trabalha em complemento de dois;
- A seguir, apresenta-se o algoritmo para somar dois números representados no formato IEEE-754-1985.

### Soma

- fazer:  $-1.001 * 2^{-2} + -1.111 * 2^0 (a_1 + a_2)$
- passo 1:
  - se  $a_1 < a_2$  swap  $a_1$  e  $a_2$
  - calcula a distância entre expoentes: ( $d=2$ )
  - expoente igual ao expoente máximo (0)
- passo 2:
  - se sinais diferentes substituir  $a_2$  pelo seu complemento de 2
- passo 3: desloca  $a_2$   $d$  dígitos para a direita, seta  $g, r, s$ 
  - no exemplo:  $0.01001$ ,  $log_2 g = 0, r = 1, s = 0$

### Exercícios

Supor que tenhamos a seguinte representação para ponto flutuante: 1 bit para sinal, 4 para expoente e 7 para a parte fracionária (ou seja, na norma IEEE 754 para 12 bits, com as mesmas condições para NaN,  $\infty$ ).

Pergunta-se:

- Qual o valor da polarização e quais os expoentes mínimo e máximo?
- Converta os seguintes números para base decimal:  
**0 1010 1011000**  
**1 0111 0101000**
- Multiplicar os dois números acima, mostrando o procedimento da multiplicação para ponto flutuante, com arredondamento.
- Qual o resultado, em decimal, arredondado, e qual o erro advindo do arredondamento?

### Exercícios

Supor que tenhamos a seguinte representação para ponto flutuante: 1 bit para sinal, 4 para expoente e 7 para a parte fracionária (ou seja, na norma IEEE 754 para 12 bits, com as mesmas condições para NaN,  $\infty$ ).

Multiplicar os dois números anteriores (**0 1010 1011000** e **1 0111 0101000**), mostrando o procedimento da multiplicação para ponto flutuante, com arredondamento.

**Resposta: expoente:  $10+7-7 = 10$**   
**partes fracionárias:  $1.1011 * 1.0101 = 10.00110111$**   
**fica  $2^{10} * 10.00110111 = 2^{11} * 1.000110111$**

**Soma-se um menos signficativo pois round=1 e sticky=1**

**1 1011 0001 110 = -17.75**

## Exercícios

Supor que tenhamos a seguinte representação para ponto flutuante: 1 bit para sinal, 4 para expoente e 7 para a parte fracionária (conforme a norma IEEE 754 para a 12 bits, com as mesmas condições para NaN,  $\infty$ ).

Qual o resultado, em decimal, arredondado, e qual o erro advindo do arredondamento?

**Resposta: 17.75, ao invés de 17.71875 ( $3.5 * 1.3125$ )**

## Finalmente acabou (está parte)!



Finalmente acabou (está parte)!