

“A principal diferença entre algo que pode dar errado e algo que não pode dar errado de jeito nenhum é que, quando algo que não pode dar errado de jeito nenhum dá errado, geralmente acaba sendo impossível de consertar” (Douglas Adams - O Guia do Mochileiro das Galáxias).

Ponto Flutuante e IEEE 754

Paulo Ricardo Lisboa de Almeida



Números reais e o Hardware

Faça um programa que soma 0.1 10x e mostra o resultado.

```
#include <stdio.h>

int main() {
    double val = 0.0;
    for (int i = 0; i < 10; i++)
        val += 0.1;

    printf("%.16lf\n", val);
    return 0;
}
```

Números reais e o Hardware

Faça um programa que soma 0.1 10x e mostra o resultado.

É impossível representar qualquer número real na máquina.

Por quê?

Para lembrar...

Converter $4,1_{10}$ para binário.

Para lembrar...

Converter $4,1_{10}$ para binário.

1. Converter a parte inteira para binário com divisões sucessivas.

$$4_{10} = 100_2$$

2. Converter a parte fracionária usando múltiplas multiplicações.

a. $0,1_{10} = 00011001100\dots_2$

$$4,1_{10} = 100,00011001100\dots_2$$

Entrada: r_{10} , entre 0 e 1

Saída: r_2 representado por $((0, d_1), d_2, \dots, d_j)$

1: $k = 1, F = r_{10}$

2: **Faça:**

3: $F = 2 \times F$

4: $d_k = \text{parteInteira}(F)$

5: $F = F - d_k$

6: $k = k + 1$

7: **Enquanto** ($F > 0$)

Números reais e o Hardware

É impossível representar qualquer número real na máquina.

Temos uma infinidade de números reais, e o hardware é finito.

Armazenamos **aproximações**.

Ponto Flutuante

Uma forma de armazenar essas aproximações é através de ponto flutuante.

Conceito implementado em grande parte dos processadores comerciais.

Ponto Flutuante

Uma forma de armazenar essas aproximações é através de ponto flutuante.

Conceito implementado em grande parte dos processadores comerciais.

Similar à notação científica normalizada.

O número tem um e somente um dígito antes da casa decimal, e não possui zeros antes da casa decimal.

Exemplos:

$8.0_{10} \times 10^{-9}$ é normalizado.

$0.1_{10} \times 10^{-8}$ não é normalizado.

$10.0_{10} \times 10^{-10}$ não é normalizado.

Ponto Flutuante

Podemos fazer o mesmo com números binários.

Vamos exibir a base e a potência na base
10 para simplificar a visualização.

Exemplo:

$1.0_2 \times 2^1$ está normalizado.

Vamos chamar o ponto decimal de “ponto binário” para a base 2.

Convenção de Patterson e Hennessy (2020).

Exemplo: normalizar 1111.11_2 .

Normalizando

Normalizar o valor 1111.11_2

$$1111.11_2 = 1111.11_2 \times 2^0$$

$$= 111.111_2 \times 2^1$$

$$= 11.1111_2 \times 2^2$$

$$= 1.11111_2 \times 2^3 \leftarrow \text{Normalizado}$$

O número tem um, e somente um, bit antes do ponto, e não possui zeros antes do ponto.

Faça você mesmo

Normalize os seguintes valores binários:

a. 11.01_2

b. 111_2

c. 0.000001_2

Faça você mesmo

Normalize os seguintes valores binários:

a. 11.01_2 $1.101_2 \times 2^1$

b. 111_2 $1.11_2 \times 2^2$

c. 0.000001_2 $1.0_2 \times 2^{-6}$

Pergunta

Para armazenar um valor binário normalizado arbitrário na memória, como $1.1111_2 \times 2^3$, quais campos são importantes?

Ponto Flutuante

Para armazenar um valor binário normalizado arbitrário na memória, como $1.1111_2 \times 2^3$, quais campos são importantes?

Não precisamos armazenar o 1 antes do ponto binário, nem a base.

Os valores então **sempre** tem o formato $(+/-)1.xxxxxxxx \times 2^{yyyy}$.

Onde xxxxxxxx é a **mantissa** (ou fração) e yyyy é o **expoente**.

Armazenamos apenas a **mantissa**, o **expoente**, e o **sinal**.

IEEE 754

Utilizado em grande parte dos processadores comerciais.

Inclusive no seu x86-64 e no seu smartphone.


Quando não disponível no hardware, é simulado via software.

Compilador injeta as instruções necessárias.

IEEE 754 - Precisão Simples

31	30	29	28	27	26	25	24	23	22	21	20	19	18	17	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1	0
s	expoente								mantissa																						
1b									8 bits								23 bits														

IEEE 754 - Precisão Simples



Sinal da mantissa.
Representação com **sinal e magnitude**.
0 é positivo, 1 é negativo.

Precisão Simples - Declarado como *float* em C.

Overflow e Underflow

Overflow: o expoente é muito grande para caber na memória.

Underflow: o expoente é muito pequeno para caber na memória.

IEEE 754 – Precisão Dupla

IEEE 754 – Precisão **dupla**.

52 bits para mantissa, e 11 para expoente.

Declarado como **double** em C.

Quais as vantagens e desvantagens da precisão dupla em relação à simples?

IEEE 754 – Precisão Dupla

Quais as vantagens e desvantagens da precisão dupla em relação à simples?

- + Consegue armazenar uma extensão maior de valores;
- + Maior precisão devida a mantissa ser muito maior;
- Ocupa mais memória;
- Pode precisar de mais ciclos do processador para efetuar cálculos.

Valores Especiais

Como representar o número 0? Qual a dificuldade?

Valores Especiais

Como representar o número 0? Qual a dificuldade?

Concordamos que o **1 antes do ponto binário é implícito**, e não é representado pelo hardware
 $(+/-)1.xxxxxxxxx * 2^{yyy}$.

Mas o número 0 em especial não tem 1 antes do ponto binário!

Essas e outras exceções são tratadas com **valores especiais**.

Valores Especiais

Precisão Simples		Precisão Dupla		Descrição
Expoente	Mantissa	Expoente	Mantissa	
0	0	0	0	0
0	Diferente de Zero	0	Diferente de Zero	+/- número desnormalizados
[1..254]	Qualquer	[1..2046]	Qualquer	+/- número em ponto flutuante
255	0	2047	0	+/- infinito
255	Diferente de Zero	2047	Diferente de Zero	NaN (<i>Not a Number</i>)

IEEE 754 - Exemplo

$$-1.11111_2 \times 2^{-2}$$

31	30	29	28	27	26	25	24	23	22	21	20	19	18	17	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1	0
s	expoente								mantissa																						


IEEE 754 - Exemplo

$$-1.11111_2 \times 2^{-2}$$

31	30	29	28	27	26	25	24	23	22	21	20	19	18	17	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1	0
s	expoente								mantissa																						


IEEE 754 - Exemplo

$$-1.11111_2 \times 2^{-2}$$




IEEE 754 - Exemplo

$$-1.11111_2 \times 2^{-2}$$



IEEE 754 - Exemplo



Sinal do Expoente

E o sinal do expoente?

Poderíamos utilizar complemento de 2.

Ou então sinal e magnitude, como na mantissa.

Sinal do Expoente

E o sinal do expoente?

Poderíamos utilizar complemento de 2.

Ou então sinal e magnitude, como na mantissa.

Para que facilitar, se podemos complicar?

Notação com bias

O IEEE 754 especifica que o expoente utiliza uma **notação com bias**.

Biased Exponent.

O **bias** é o **valor intermediário** entre todos os possíveis de serem representados no expoente.

127_{10} ($0111\ 1111_2$) para precisão simples.

1023_{10} ($011\ 1111\ 1111_2$) para precisão dupla.

No caso geral, o bias é $2^{x-1}-1$, onde x é o número de bits no expoente.

O expoente é somado ao bias.

Notação com bias

Exemplos:

O expoente -1_{10} na notação com bias se torna

$$-1_{10} + 127_{10} = 126_{10} = 01111110_2$$

O expoente 1_{10} na notação com bias se torna

$$1_{10} + 127_{10} = 128_{10} = 10000000_2$$

IEEE 754

Um ponto flutuante é então representado por:

$$(-1)^{\text{ sinal }} \times (1.0 + \text{ mantissa }) \times 2^{(\text{ expoente } - \text{ bias })}$$

Apenas os itens em azul são armazenados na memória.

Exemplo

Representar -0.75_{10} em precisão simples

Exemplo

Representar -0.75_{10} em precisão simples

Convertendo para binário pelo método da multiplicação: 0.11_2

Normalizando: $0.11_2 \times 2^0 = 1.1_2 \times 2^{-1}$

Mantissa: 1 (somente a parte fracionária)

Expoente: $-1 + 127 = 126_{10} = 01111110_2$

Sinal: 1 (negativo)

[illegible]

Exemplo

Converte para decimal.

[illegible]

Exemplo

Converte para decimal.

31	30	29	28	27	26	25	24	23	22	21	20	19	18	17	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1	0
1	1	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

O expoente é $10000001_2 = 129_{10}$

Subtraindo o bias temos $129 - 127 = 2_{10}$

A mantissa é $1.01_2 = 1 \times 2^0 + 0 \times 2^{-1} + 1 \times 2^{-2} = 1.25_{10}$

O bit de sinal é 1 (negativo)

Logo temos $-1.25 \times 2^2 = -5_{10}$

Relembrando...

Realizar uma adição utilizando notação científica.

Vamos realizar na base 10, mas o procedimento é o mesmo na base 2.

Considere a seguinte adição: $9.999_{10} \times 10^1 + 1.610_{10} \times 10^{-1}$.

Considerando que podemos representar 4 dígitos na memória.

Relembrando...

Considere a seguinte adição: $9.999_{10} \times 10^1 + 1.610_{10} \times 10^{-1}$.

Considerando que podemos representar 4 dígitos na memória.

Primeiro precisamos igualar o expoente do número com o menor expoente, com o número de maior expoente.

$$1.610_{10} \times 10^{-1} = 0.01610_{10} \times 10^1.$$

Relembrando...

Considere a seguinte adição: $9.999_{10} \times 10^1 + 1.610_{10} \times 10^{-1}$.

Considerando que podemos representar 4 dígitos na memória.

Primeiro precisamos igualar o expoente do número com o menor expoente, com o número de maior expoente.

$$1.610_{10} \times 10^{-1} = 0.01610_{10} \times 10^1.$$

Problema: só podemos armazenar 4 dígitos.

$$1.610_{10} \times 10^{-1} = 0.016_{10} \times 10^1.$$

Relembrando...

Feito isso, basta adicionar as mantissas:

$$9.999_{10} \times 10^1 + 0.016_{10} \times 10^1 = 10.015_{10} \times 10^1$$

Relembrando...

Feito isso, basta adicionar as mantissas:

$$9.999_{10} \times 10^1 + 0.016_{10} \times 10^1 = 10.015_{10} \times 10^1$$

O resultado não está normalizado. Normalizar:

$$1.0015_{10} \times 10^2$$

Relembrando...

Feito isso, basta adicionar as mantissas:

$$9.999_{10} \times 10^1 + 0.016_{10} \times 10^1 = 10.015_{10} \times 10^1$$

O resultado não está normalizado. Normalizar:

$$1.0015_{10} \times 10^2$$

Mais uma vez não cabe em 4 casas. Arredondando:

$$1.002_{10} \times 10^2$$

Relembrando...

Feito isso, basta adicionar as mantissas:

$$9.999_{10} \times 10^1 + 0.016_{10} \times 10^1 = 10.015_{10} \times 10^1$$

O resultado não está normalizado. Normalizar:


$$1.0015_{10} \times 10^2$$

Mais uma vez não cabe em 4 casas. Arredondando:

$$1.002_{10} \times 10^2$$

Se não tivéssemos que truncar/arredondar os valores para caber em 4 casas, o resultado correto seria $1,00151 \times 10^2$.

Soma



Multiplicação

Soma os expoentes (tomando cuidado com o bias).

Multiplicar as mantissas.

Arredondamento

O IEEE 754 define 4 formas de arredondamento, que podem ser setadas no processador (quando implementado no hardware):

- Arredondar para cima (teto).

- Arredondar para baixo (pisso).

- Truncar (ignorar as demais casas).

- Nearest even (par mais próximo) <- Mais utilizado.

Detalhes sobre o arredondamento e suas implementações, são encontrados em Patterson e Hennessy (2020).

- Requerem que o processador mantenha bits extras para gerência.

IEEE 754

Comumente o padrão é embutido no hardware.

Hardware simples podem não implementar o padrão.

Ex.: microcontroladores.

Nesse caso, o padrão é implementado via software.

De qualquer forma, **independe de linguagem.**

Um ponto flutuante de precisão simples (float) é o mesmo em C, Java, C#, Python, ...

Outras Precisões

Existem ainda os padrões IEEE 754 para.

- Precisão estendida (comum em processadores x86-64);

- Half-Precision;

- Quad-Precision.

Exercícios

1. Represente -0.75 em precisão dupla. Compare a resposta com a obtida durante a aula para precisão simples.
2. Qual o maior e o menor valor que podem ser representados em ponto flutuante de precisão dupla e simples (desconsiderando $+/ - \infty$)? Quais são seus equivalentes em decimal?
3. Exiba os seguintes valores em ponto flutuante. Quando necessário trunque (ignore os bits que não couberem) os valores. Faça o desenho da memória como nos exemplos e coloque os endereços dos bits (para deixar claro a ordem dos bits).
 - a. -16.015625_{10} para precisão simples
 - b. -0.1_{10} para precisão simples
 - c. 0.125_{10} em “meia precisão” (half-precision): 10 bits pra mantissa, 5 para expoente e 1 para sinal.
4. Sabendo-se que um número em quad precision possui 15 bits no expoente, responda (deduza você mesmo, sem pesquisar).
 - a. Qual o bias para esses números.
 - b. Qual o maior e o menor valor que podem ser representados (desconsiderando o $+/ -$ infinito)?


Exercícios

Considerando seus conhecimentos sobre representação de números em IEEE 754, o que pode dar errado com o programa em C a seguir. Como corrigir?


```
//...  
  
double valor;  
//faz alguns cálculos  
  
if (valor == 5){  
    printf("O resultado é ...");  
}  
//...
```

Referências


Patterson, Hennessy.
Computer Organization and
Design RISC-V Edition: The
Hardware Software
Interface. 2020.




Patterson, Hennessy. Computer
Organization and Design MIPS
Edition: The Hardware/Software
Interface. 2020.




Stallings, W. Organização de
Arquitetura de Computadores.
10a Ed. 2016.



Ruggiero, Lopes. Cálculo
numérico: aspectos teóricos e
computacionais. 1996.



Floyd. Sistemas Digitais:
Fundamentos e Aplicações.
2009.



Licença

Esta obra está licenciada com uma Licença [Creative Commons Atribuição 4.0 Internacional](https://creativecommons.org/licenses/by/4.0/).