



## Trabajo Práctico Nro 6 Punto Flotante IEEE

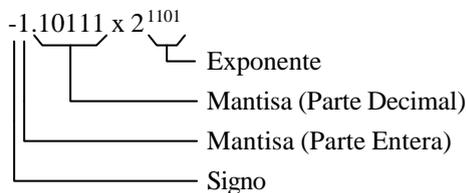
### Introducción

El punto flotante es un método muy útil para realizar operaciones numéricas cuando los números involucrados tienen una magnitud muy diferente, el microprocesador 8088 no posee en forma nativa la posibilidad de su uso, se deben recurrir a emuladores o coprocesadores para poder usarlos, en la serie x86 a partir del 80486DX y sus sucesores vino incorporado el coprocesador en el mismo microprocesador, por lo tanto es imposible contar hoy con una PC de escritorio sin manejo nativo de coma flotante, pero no pasa lo mismo con los microcontroladores que en su mayoría no lo soporta.

Es interesante entonces, conocer como es su estructura y uso en el lenguaje assembler, para luego poder ser utilizado en cualquier microprocesador o microcontrolador que no posee ninguna característica de manejo para estos números.

### Componentes

Un número en punto flotante esta formado por:



Cada una de estas partes del punto flotante tendrán una ubicación determinada dentro de la codificación del número, y su longitud dependerá del tipo de número.

### Exponente

El exponente de un número de punto flotante es modificado antes de su almacenamiento.

El número a almacenar en la posición del exponente será igual a:

$$e_{ieee} = e + 2^{m-1} - 1$$

Donde **e** será el exponente verdadero y **m** es el número de bits del exponente en el formato elegido

Esta modificación se realiza para evitar el uso de un bit de signo, lo que permite realizar comparaciones mas fácil entre exponentes, dado que estamos sumando  $2^{m-1} - 1$  que es igual a sumar la mitad del máximo valor que se puede almacenar en el exponente, transformando el exponente en un número natural.

Ejemplo.

Si nuestro tamaño de exponente es de 8 bits, le estaremos sumando al exponente el numero 127.

### Mantisa

La mantisa debe cumplir la condición de:  $1 = \text{mantisa} < 2$

Por lo tanto la parte entera será siempre 1 y solo será guardada en la número la parte decimal justificada a la derecha. (Un caso particular es el de 10-Byte real, en el cual el campo de parte entera existe, y obviamente valdrá siempre 1)

### Signo

En el caso del punto flotante, en la mantisa se guarda siempre el valor absoluto de la misma, esto significa que en el caso de los numero negativos no se guarda el complemento a 2 del mismo sino simplemente el valor de la mantisa sin signo.

Solo el bit de signo identificará que tipo de número es

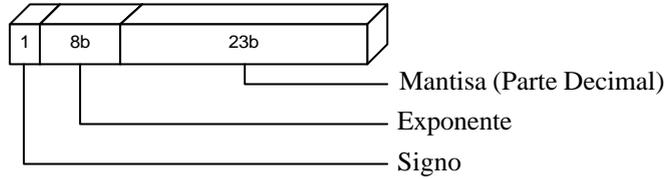
1 → Negativo

0 → Positivo



## Tipos

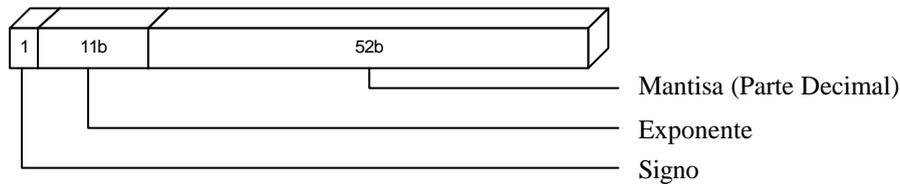
### Short Real Number



Signo	1 bit
Exponente	8 bit
Mantisa (Parte Decimal)	23 bit
Total	<u>32 bit (4 Bytes)</u>

Como la parte entera es siempre 1 directamente lo asume y no lo incluye en la codificación

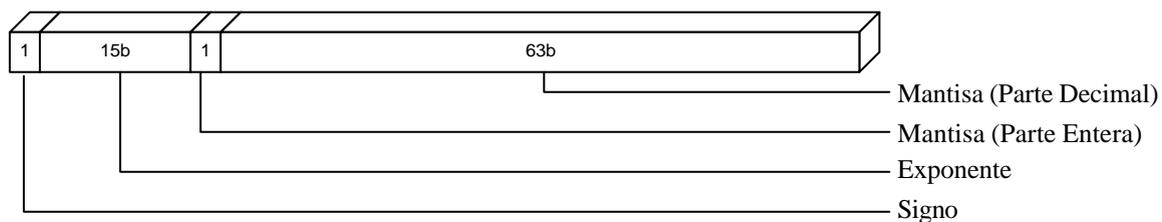
### Long Real Number



Signo	1 bit
Exponente	11 bit
Mantisa (Parte Decimal)	52 bit
Total	<u>64 bit (8 Bytes)</u>

Como la parte entera es siempre 1 directamente lo asume y no lo incluye en la codificación

### 10-Byte Real Number



Signo	1 bit
Exponente	15 bit
Mantisa (Parte Entera)	1 bit
Mantisa (Parte Decimal)	63 bit
Total	<u>80 bit (10 Bytes)</u>

En este caso particular posee parte entera, pero esta es siempre 1 y por lo tanto no es un bit de información.

## Aritmética de Punto Flotante

### Pase de un número real a Short Real IEEE

Dado un número lo pasaremos a punto flotante en base 2  
 $x = 3,625$



$$2^n = 3,625$$

$$n = \frac{\ln(3,625)}{\ln(2)} = 1,85798$$

Separando parte entera y decimal del exponente

$$2^{1,85798} = 2^{0,85798} \times 2^1 = 3,625$$

$$2^{0,85798} = 1,8125$$

### Resultado

El número será de la forma  $(-1)^s \cdot f \cdot 2^e$

Al ser el número del ejemplo positivo entonces ya resolvimos la primera incógnita  $s = 0$

$f$  deberá ser un número cuya parte entera sea 1 por lo tanto debe cumplir que  $1 \leq f < 2$ , el número obtenido de elevar 2 a la parte decimal de  $n$  da como resultado un número comprendido entre 1 y 2

La parte entera de  $n$  será entonces  $e$

### Pasamos el resultado a base 2

Parte entera = 1

Parte decimal

$$0,8125 \times 2 = 1,625 \quad \text{Entero} = 1$$

$$0,625 \times 2 = 1,25 \quad \text{Entero} = 1$$

$$0,25 \times 2 = 0,5 \quad \text{Entero} = 0$$

$$0,5 \times 2 = 1 \quad \text{Entero} = 1$$

$$f_2 = 1,1101$$

$$x = (-1)^0 \cdot 1,1101 \cdot 2^1$$

$$e = 1$$

$$s = 0$$

$$f = 1,1101$$

### Representación en formato estándar IEEE (Short Real)

Signo = 0

Mantisa = 11010000000000000000000000000000<sub>2</sub>

Exponente

$$\text{exp} = 1 + 2^7 - 1 = 1 + 127 = 128$$

$$\text{exp} = 10000000_2$$

Resultado

$$x = 3,625$$

$$x = 1,1101 \times 2^1$$

$$x = 0\_10000000\_11010000000000000000000000000000$$

$$x = 40680000_{16}$$

