

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* $\rightarrow$ *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
 $187.27_{(10)} \rightarrow 10111011.0100010100_{(2)}$
2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
 $10111011.0100010100 \times 2^0$
 $1011101.10100010100 \times 2^1$
 $101110.110100010100 \times 2^2$
 $10111.0110100010100 \times 2^3$
 $1011.10110100010100 \times 2^4$
 $101.110110100010100 \times 2^5$
 $10.1110110100010100 \times 2^6$
 $1.01110110100010100 \times 2^7$
 $.101110110100010100 \times 2^8$
Note que as 7 linhas acima representam o mesmo número.
3. Como o número é positivo, seu sinal é 0.
4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
 $23_{(10)} \rightarrow 10111_{(2)}$
5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 0 1 0 1 0 1 1 0 0 1 1 0 0
1 1 1 1 1 1 1 1 0 0 1 1 1 0 0 0

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

1 0 1 1 0 1 0 1 1 1 1 0 1 0 1 1
0 1 1 1 0 0 0 0 1 0 1 1 0 0 1 1
1 1 0 1 0 1 0 1 1 0 0 0 0 0 0 0
1 1 1 1 0 0 1 0 0 0 0 1 0 0 1 0

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

99
-56.66

Responda aqui

1.	2.		
		//// //// //// ////	//// //// //// ////
3.	4.	5.	6.
7			
8			



Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentativa de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127..0..127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

11111111

...

10000001

10000000

00000000

...

01111111

=

=

=

=

=

=

$-(2^6 + \dots + 2^1 + 2^0) = -127$

-1

$-0 (?)$

0

$2^6 + 2^5 + \dots + 2^0 = 127$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número (1011)₂ como expressão de um negativo (1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o

primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty.. \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 \dots d_n \times \beta^{\pm e_1 e_2 \dots e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 \dots e_m$ também com o seu sinal. O conjunto $d_1 d_2 \dots d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

s_1	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	s_2	e_1	e_2	e_3	e_4
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	----------	-------	-------	-------	-------	-------

 s_1 sinal do número (da mantissa). $0 \rightarrow$ positivo e $1 \rightarrow$ negativo
 $d_1 \dots d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: $0 \rightarrow +$ e $1 \rightarrow -$
 $e_1 \dots e_4$ expoente
Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.11111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.01111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.11111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, \dots, d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

```
1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 0 1 0 0
```

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

```
1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0
```

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1110110110110010101 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0010010010011010 e agora, soma-se 1 e fica 0010010010011011 . A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1100110001000010 , devemos estudar a distribuição de bits. Vamos lá

```
1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m m
```

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0001000010 , que deve ter um 1 colocado à frente dando o binário de 11 bits 100010000010 . Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625.

Vamos ao quarto caso: 01100001111001010 ou 0110000101110010100 número é positivo, e seu expoente é $-15+24=9$. A mantissa é $10111001010 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* → *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
 $187.27_{(10)} \rightarrow 10111011.0100010100_{(2)}$
2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
 $10111011.0100010100 \times 2^0$
 $1011101.10100010100 \times 2^1$
 $101110.110100010100 \times 2^2$
 $10111.0110100010100 \times 2^3$
 $1011.10110100010100 \times 2^4$
 $101.110110100010100 \times 2^5$
 $10.1110110100010100 \times 2^6$
 $1.01110110100010100 \times 2^7$
 $.101110110100010100 \times 2^8$
Note que as 7 linhas acima representam o mesmo número.
3. Como o número é positivo, seu sinal é 0.
4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
 $23_{(10)} \rightarrow 10111_{(2)}$
5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

👉 Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 1 0 0 0 0 1 1 1 1 0 0 0 0
1 1 1 1 1 0 0 1 1 1 1 0 0 1 1 0

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

0 1 1 0 0 1 0 0 0 1 1 0 1 0 1 0
0 0 0 0 0 1 1 1 0 1 0 0 0 1 0 1
1 1 0 0 1 1 0 0 1 0 1 1 0 0 1 1
0 0 1 1 1 0 1 1 1 1 1 1 1 1 0 0

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

115
-53.64

Responda aqui

1.	2.		
		//// //// //// ////	//// //// //// ////
3.	4.	5.	6.
7			
8			

Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentação de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127...127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

$$\begin{aligned} 11111111 &= -(2^6 + \dots + 2^1 + 2^0) = -127 \\ \dots & \\ 10000001 &= -1 \\ 10000000 &= -0 (?) \\ 00000000 &= 0 \\ \dots & \\ 01111111 &= 2^6 + 2^5 + \dots + 2^0 = 127 \end{aligned}$$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número $(1011)_2$ como expressão de um negativo

(1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty... \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 \dots d_n \times \beta^{\pm e_1 e_2 \dots e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 \dots e_m$ também com o seu sinal. O conjunto $d_1 d_2 \dots d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

s_1	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	s_2	e_1	e_2	e_3	e_4
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	----------	-------	-------	-------	-------	-------

s_1 sinal do número (da mantissa). $0 \rightarrow$ positivo e $1 \rightarrow$ negativo
 $d_1 \dots d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: $0 \rightarrow +$ e $1 \rightarrow -$
 $e_1 \dots e_4$ expoente

Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.1111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.0111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.1111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, \dots, d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

1 1 0 1 1 0 1 0 1 1 0 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 0 1 0 0

São eles: -9371 e -5388
Agora, ache os flutuantes, com 7 casas decimais, de

1 1 0 0 1 1 0 0 0 1 0 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1 1 0 1 1 0 1 0 1 1 0 0 1 0 1 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 0 e agora, soma-se 1 e fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 1. A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo. Quanto ao terceiro caso, o flutuante 1 1 0 0 1 1 0 0 1 0 0 0 0 1 0, devemos estudar a distribuição de bits. Vamos lá

1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m m

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0 0 0 1 0 0 0 0 1 0, que deve ter um 1 colocado à frente dando o binário de 11 bits 1 0 0 0 1 0 0 0 0 1 0. Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625.

Vamos ao quarto caso: 0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0 ou 0 | 1 1 0 0 0 | 0 1 1 1 0 0 1 0 1 0 O número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1,0 1 1 1 0 0 1 0 1 0 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* $\rightarrow$ *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
 $187.27_{(10)} \rightarrow 10111011.0100010100_{(2)}$
2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
 $10111011.0100010100 \times 2^0$
 $1011101.10100010100 \times 2^1$
 $101110.110100010100 \times 2^2$
 $10111.0110100010100 \times 2^3$
 $1011.10110100010100 \times 2^4$
 $101.110110100010100 \times 2^5$
 $10.1110110100010100 \times 2^6$
 $1.01110110100010100 \times 2^7$
 $.101110110100010100 \times 2^8$
Note que as 7 linhas acima representam o mesmo número.
3. Como o número é positivo, seu sinal é 0.
4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
 $23_{(10)} \rightarrow 10111_{(2)}$
5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 1 1 0 0 1 1 0 0 0 0 1 0 0
1 1 1 1 0 0 1 0 0 0 0 0 0 1 0 0

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

1 0 0 0 1 0 0 0 1 0 0 1 1 1 1 0
1 1 0 1 1 1 1 0 1 1 1 0 0 0 1 0
0 0 0 1 0 0 0 1 0 0 1 0 0 0 0 1
1 1 1 0 0 0 1 1 0 1 0 1 1 0 1 1

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

125
-53.26

Responda aqui

1.	2.		
		//// //// ////	//// //// ////
3.	4.	5.	6.
7			
8			



Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentativa de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127..0..127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

11111111

...

10000001

10000000

00000000

...

01111111

=

=

=

=

=

=

$-(2^6 + \dots + 2^1 + 2^0) = -127$

-1

$-0 (?)$

0

$2^6 + 2^5 + \dots + 2^0 = 127$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número (1011)₂ como expressão de um negativo (1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o

primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty.. \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 \dots d_n \times \beta^{\pm e_1 e_2 \dots e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 \dots e_m$ também com o seu sinal. O conjunto $d_1 d_2 \dots d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

s_1	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	s_2	e_1	e_2	e_3	e_4
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	----------	-------	-------	-------	-------	-------

 s_1 sinal do número (da mantissa). $0 \rightarrow$ positivo e $1 \rightarrow$ negativo
 $d_1 \dots d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: $0 \rightarrow +$ e $1 \rightarrow -$
 $e_1 \dots e_4$ expoente
Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.11111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.01111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.11111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, \dots, d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$

se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$

se $e = 0$ e $f = 0$ então este número é zero

se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

```
1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 0 1 0 0
```

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

```
1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0
```

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 0 e agora, soma-se 1 e fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 1. A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0, devemos estudar a distribuição de bits. Vamos lá

```
1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m m
```

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0 0 0 1 0 0 0 1 0, que deve ter um 1 colocado à frente dando o binário de 11 bits 1 0 0 0 1 0 0 0 0 1 0. Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625.

Vamos ao quarto caso: 0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0 ou 0 | 1 1 0 0 0 | 0 1 1 1 0 0 1 0 1 0 O número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1.0 1 1 1 0 0 1 0 1 0 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* $\rightarrow$ *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
 $187.27_{(10)} \rightarrow 10111011.0100010100_{(2)}$
2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
 $10111011.0100010100 \times 2^0$
 $1011101.10100010100 \times 2^1$
 $101110.110100010100 \times 2^2$
 $10111.0110100010100 \times 2^3$
 $1011.10110100010100 \times 2^4$
 $101.110110100010100 \times 2^5$
 $10.1110110100010100 \times 2^6$
 $1.01110110100010100 \times 2^7$
 $.101110110100010100 \times 2^8$
Note que as 7 linhas acima representam o mesmo número.
3. Como o número é positivo, seu sinal é 0.
4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
 $23_{(10)} \rightarrow 10111_{(2)}$
5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 0 1 1 0 1 0 1 1 0 1 0 0 0
1 1 1 0 1 1 0 1 1 1 1 1 1 0 1 0

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

0 0 0 1 0 0 0 0 1 1 0 1 1 1 0 0
0 1 0 1 1 0 0 0 1 1 0 1 1 0 1 1
0 1 0 1 0 0 1 0 1 0 0 1 0 0 1 1
1 1 0 0 0 0 0 0 0 1 0 0 0 1 1 1

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

97
-45.48

Responda aqui

1.	2.		
		//// //// //// ////	//// //// //// ////
3.	4.	5.	6.
7			
8			



Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentativa de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127..0..127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

11111111	=	$-(2^6 + ... + 2^1 + 2^0) = -127$
...		
10000001	=	-1
10000000	=	-0 (?)
00000000	=	0
...		
01111111	=	$2^6 + 2^5 + ... + 2^0 = 127$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número (1011)₂ como expressão de um negativo (1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o

primeiro bit era 1, então -5. Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty.. \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 ... d_n \times \beta^{\pm e_1 e_2 ... e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 ... e_m$ também com o seu sinal. O conjunto $d_1 d_2 ... d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

s_1	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	s_2	e_1	e_2	e_3	e_4
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	----------	-------	-------	-------	-------	-------

s_1 sinal do número (da mantissa). $0 \rightarrow$ positivo e $1 \rightarrow$ negativo
 $d_1 .. d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: $0 \rightarrow +$ e $1 \rightarrow -$
 $e_1 .. e_4$ expoente
Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.11111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$. Já o maior valor é $0.1111111111.01111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.11111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de -15..15 a 0..31. Isto é possível porque usando o sinal, tinham-se duas representações para o zero (+0 e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, ... d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

```
1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 1 0 1 0 0
```

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

```
1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0
```

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 0 e agora, soma-se 1 e fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 1. A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0, devemos estudar a distribuição de bits. Vamos lá

```
1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m m
```

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0 0 0 1 0 0 0 1 0, que deve ter um 1 colocado à frente dando o binário de 11 bits 1 0 0 0 1 0 0 0 0 1 0. Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625.

Vamos ao quarto caso: 0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0 ou 0 | 1 1 0 0 0 | 0 1 1 1 0 0 1 0 1 0 O número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1.0 1 1 1 0 0 1 0 1 0 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* → *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

- 1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
187.27₍₁₀₎ → 10111011.0100010100₍₂₎
- 2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
10111011.0100010100 × 2⁰
1011101.10100010100 × 2¹
101110.110100010100 × 2²
10111.0110100010100 × 2³
1011.10110100010100 × 2⁴
101.110110100010100 × 2⁵
10.1110110100010100 × 2⁶
1.01110110100010100 × 2⁷
.101110110100010100 × 2⁸
Note que as 7 linhas acima representam o mesmo número.
- 3. Como o número é positivo, seu sinal é 0.
- 4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
23₍₁₀₎ → 10111₍₂₎
- 5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
- 6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
- 7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

🔗 Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 1 1 0 0 1 1 1 1 0 1 1 0 0
1 1 1 1 1 0 1 0 0 1 0 1 0 0 1 0

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

0 1 1 1 0 0 1 1 1 0 1 1 1 0 0 1
1 0 1 0 0 1 1 1 1 0 0 1 0 1 0 1
0 0 0 0 0 0 1 1 0 1 0 0 1 0 0 1
0 0 1 0 0 1 1 1 1 0 0 1 0 1 0 0

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

107
-40.06

Responda aqui

1.	2.		
		//// //// //// ////	//// //// //// ////
3.	4.	5.	6.
7			
8			

Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentativa de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127..0..127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

11111111

...

10000001

10000000

00000000

...

01111111

=

=

=

=

=

=

$-(2^6 + \dots + 2^1 + 2^0) = -127$

-1

$-0 (?)$

0

$2^6 + 2^5 + \dots + 2^0 = 127$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número (1011)₂ como expressão de um negativo (1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o

primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty.. \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 \dots d_n \times \beta^{\pm e_1 e_2 \dots e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 \dots e_m$ também com o seu sinal. O conjunto $d_1 d_2 \dots d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

<u>s</u> ₁	<u>d</u> ₁	<u>d</u> ₂	<u>d</u> ₃	<u>d</u> ₄	<u>d</u> ₅	<u>d</u> ₆	<u>d</u> ₇	<u>d</u> ₈	<u>d</u> ₉	<u>d</u> ₁₀	<u>s</u> ₂	<u>e</u> ₁	<u>e</u> ₂	<u>e</u> ₃	<u>e</u> ₄
-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	------------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------

 s_1 sinal do número (da mantissa). 0 $\rightarrow$ positivo e 1 $\rightarrow$ negativo
 $d_1 \dots d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: 0 $\rightarrow$ + e 1 $\rightarrow$ -
 $e_1 \dots e_4$ expoente
Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.11111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.01111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.11111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, \dots, d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

```
1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 1 0 1 0 0
```

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

```
1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0
```

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 0 e agora, soma-se 1 e fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 1. A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0, devemos estudar a distribuição de bits. Vamos lá

```
1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m m
```

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0 0 0 1 0 0 0 1 0, que deve ter um 1 colocado à frente dando o binário de 11 bits 1 0 0 0 1 0 0 0 0 1 0. Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625.

Vamos ao quarto caso: 0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0 ou 0 | 1 1 0 0 0 | 0 1 1 1 0 0 1 0 1 0 O número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1.0 1 1 1 0 0 1 0 1 0 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* $\rightarrow$ *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
 $187.27_{(10)} \rightarrow 10111011.0100010100_{(2)}$
2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
 $10111011.0100010100 \times 2^0$
 $1011101.10100010100 \times 2^1$
 $101110.110100010100 \times 2^2$
 $10111.0110100010100 \times 2^3$
 $1011.10110100010100 \times 2^4$
 $101.110110100010100 \times 2^5$
 $10.1110110100010100 \times 2^6$
 $1.01110110100010100 \times 2^7$
 $.101110110100010100 \times 2^8$
Note que as 7 linhas acima representam o mesmo número.
3. Como o número é positivo, seu sinal é 0.
4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
 $23_{(10)} \rightarrow 10111_{(2)}$
5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 0 1 0 1 1 1 0 0 1 0 1 0 1
1 1 0 1 1 1 0 0 0 1 0 1 1 0 0 0

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

0 0 1 0 1 1 0 0 1 1 0 1 0 0 0 1
0 1 1 1 0 1 0 0 0 1 1 1 1 0 0 1
0 0 0 0 0 0 1 1 1 0 1 1 1 0 0 1
0 0 1 1 1 0 0 1 0 0 0 0 1 0 1 0

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

116
-44.36

Responda aqui

1.	2.		
		//// //// //// ////	//// //// //// ////
3.	4.	5.	6.
7			
8			



Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentação de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127...127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

```
11111111 = -(2^6 + ... + 2^1 + 2^0) = -127
...
10000001 = -1
10000000 = -0 (?)
00000000 = 0
...
01111111 = 2^6 + 2^5 + ... + 2^0 = 127
```

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número $(1011)_2$ como expressão de um negativo

(1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty... \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 ... d_n \times \beta^{\pm e_1 e_2 ... e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 ... e_m$ também com o seu sinal. O conjunto $d_1 d_2 ... d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

<u>s</u> ₁	<u>d</u> ₁	<u>d</u> ₂	<u>d</u> ₃	<u>d</u> ₄	<u>d</u> ₅	<u>d</u> ₆	<u>d</u> ₇	<u>d</u> ₈	<u>d</u> ₉	<u>d</u> ₁₀	<u>s</u> ₂	<u>e</u> ₁	<u>e</u> ₂	<u>e</u> ₃	<u>e</u> ₄
-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	------------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------

s_1 sinal do número (da mantissa). $0 \rightarrow$ positivo e $1 \rightarrow$ negativo
 $d_1..d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: $0 \rightarrow +$ e $1 \rightarrow -$
 $e_1..e_4$ expoente

Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.1111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.0111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.1111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, ... d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	<i>exp</i> ₁₀	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

```
1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 0 1 0 0
```

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

```
1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0
```

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1101101101100101 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0010010010011010 e agora, soma-se 1 e fica 0010010010011011 . A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1100110001000010 , devemos estudar a distribuição de bits. Vamos lá

```
1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m m
```

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0001000010 , que deve ter um 1 colocado à frente dando o binário de 11 bits 100010000010 . Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625 .

Vamos ao quarto caso: 0110000111001010 ou 0110000101110010 número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1,0111001010 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* → *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

- 1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
187.27₍₁₀₎ → 10111011.0100010100₍₂₎
- 2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
10111011.0100010100 × 2⁰
1011101.10100010100 × 2¹
101110.110100010100 × 2²
10111.0110100010100 × 2³
1011.10110100010100 × 2⁴
101.110110100010100 × 2⁵
10.1110110100010100 × 2⁶
1.01110110100010100 × 2⁷
.101110110100010100 × 2⁸
Note que as 7 linhas acima representam o mesmo número.
- 3. Como o número é positivo, seu sinal é 0.
- 4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
23₍₁₀₎ → 10111₍₂₎
- 5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
- 6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
- 7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

👉 Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 1 1 1 1 0 0 1 0 0 0 1 1 1
1 1 1 1 0 1 0 1 0 1 1 1 0 0 1 0

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

0 1 1 0 1 1 1 1 1 1 0 0 1 1 0 0
1 0 0 1 0 0 1 0 0 1 0 1 1 1 0 0
1 0 1 1 0 1 1 0 0 0 0 1 0 0 0 0
0 0 1 1 1 1 0 1 0 0 1 0 1 1 0 1

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

135
-43.16

Responda aqui

1.	2.		
		//// //// ////	//// //// ////
3.	4.	5.	6.
7			
8			

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* → *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

- 1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
187.27₍₁₀₎ → 10111011.0100010100₍₂₎
- 2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
10111011.0100010100 × 2⁰
1011101.10100010100 × 2¹
101110.110100010100 × 2²
10111.0110100010100 × 2³
1011.10110100010100 × 2⁴
101.110110100010100 × 2⁵
10.1110110100010100 × 2⁶
1.01110110100010100 × 2⁷
.101110110100010100 × 2⁸
Note que as 7 linhas acima representam o mesmo número.
- 3. Como o número é positivo, seu sinal é 0.
- 4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
23₍₁₀₎ → 10111₍₂₎
- 5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
- 6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
- 7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

👉 Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 1 0 0 0 1 1 0 1 1 0 1 1 0
1 1 0 1 1 1 0 0 0 1 0 0 0 1 1 1

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

0 0 1 1 0 1 0 1 0 0 1 1 0 1 0 0
0 1 0 0 0 0 0 0 1 0 1 0 0 0 1 0
0 0 0 1 1 1 1 1 1 1 1 0 0 1 0 0
1 1 0 1 0 0 1 1 1 0 1 0 0 1 0 0

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

103
-42.94

Responda aqui

1.	2.		
		//// //// ////	//// //// ////
3.	4.	5.	6.
7			
8			

Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentação de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=(((5**0.5)**2)-5)
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127...127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

$$\begin{aligned} 11111111 &= -(2^6 + \dots + 2^1 + 2^0) = -127 \\ &\dots \\ 10000001 &= -1 \\ 10000000 &= -0 \text{ (?) } \\ 00000000 &= 0 \\ &\dots \\ 01111111 &= 2^6 + 2^5 + \dots + 2^0 = 127 \end{aligned}$$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número $(1011)_2$ como expressão de um negativo

(1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty... \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 \dots d_n \times \beta^{\pm e_1 e_2 \dots e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 \dots e_m$ também com o seu sinal. O conjunto $d_1 d_2 \dots d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

s_1	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	s_2	e_1	e_2	e_3	e_4
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	----------	-------	-------	-------	-------	-------

s_1 sinal do número (da mantissa). $0 \rightarrow$ positivo e $1 \rightarrow$ negativo
 $d_1 \dots d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: $0 \rightarrow +$ e $1 \rightarrow -$
 $e_1 \dots e_4$ expoente

Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.1111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.0111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.1111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, \dots, d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 0 1 0 0

São eles: -9371 e -5388
Agora, ache os flutuantes, com 7 casas decimais, de

1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 0 e agora, soma-se 1 e fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 1. A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo. Quanto ao terceiro caso, o flutuante 1 1 0 0 1 1 0 0 1 0 0 0 0 1 0, devemos estudar a distribuição de bits. Vamos lá

1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m m

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0 0 0 1 0 0 0 1 0, que deve ter um 1 colocado à frente dando o binário de 11 bits 1 0 0 0 1 0 0 0 0 1 0. Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625.

Vamos ao quarto caso: 0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0 ou 0 | 1 1 0 0 0 | 0 1 1 1 0 0 1 0 1 0 O número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1,0 1 1 1 0 0 1 0 1 0 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* → *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

- 1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
187.27₍₁₀₎ → 10111011.0100010100₍₂₎
- 2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
10111011.0100010100 × 2⁰
1011101.10100010100 × 2¹
101110.110100010100 × 2²
10111.0110100010100 × 2³
1011.10110100010100 × 2⁴
101.110110100010100 × 2⁵
10.1110110100010100 × 2⁶
1.01110110100010100 × 2⁷
.101110110100010100 × 2⁸
Note que as 7 linhas acima representam o mesmo número.
- 3. Como o número é positivo, seu sinal é 0.
- 4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
23₍₁₀₎ → 10111₍₂₎
- 5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
- 6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
- 7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

🔗 Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 0 0 1 0 1 1 1 1 0 1 0 0 0
1 1 1 1 1 1 1 0 0 0 1 0 0 0 1 0

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

0 0 0 1 1 0 1 0 0 1 0 0 0 1 1 1
0 0 1 0 0 1 0 0 0 1 1 0 0 1 1 0
0 0 1 1 1 0 1 0 1 0 0 1 1 1 0 0
0 0 1 1 0 0 1 1 0 0 0 0 0 0 0 1

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

136
-40.76

Responda aqui

1.	2.		
		//// //// //// ////	//// //// //// ////
3.	4.	5.	6.
7			
8			

Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentativa de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127..0..127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

$$\begin{aligned} 11111111 &= -(2^6 + \dots + 2^1 + 2^0) = -127 \\ \dots & \\ 10000001 &= -1 \\ 10000000 &= -0 (?) \\ 00000000 &= 0 \\ \dots & \\ 01111111 &= 2^6 + 2^5 + \dots + 2^0 = 127 \end{aligned}$$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número (1011)₂ como expressão de um negativo (1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o

primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty.. \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 \dots d_n \times \beta^{\pm e_1 e_2 \dots e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 \dots e_m$ também com o seu sinal. O conjunto $d_1 d_2 \dots d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

s_1	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	s_2	e_1	e_2	e_3	e_4
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	----------	-------	-------	-------	-------	-------

s_1 sinal do número (da mantissa). $0 \rightarrow$ positivo e $1 \rightarrow$ negativo
 $d_1 \dots d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: $0 \rightarrow +$ e $1 \rightarrow -$
 $e_1 \dots e_4$ expoente
Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.11111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.01111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.11111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, \dots, d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

```
1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 1 0 1 0 0
```

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

```
1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0
```

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 110110110110010101 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0010010010011010 e agora, soma-se 1 e fica 00100100100110101 . A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1100110001000010 , devemos estudar a distribuição de bits. Vamos lá

```
1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m m
```

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0001000010 , que deve ter um 1 colocado à frente dando o binário de 11 bits 100010000010 . Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625.

Vamos ao quarto caso: 01100001111001010 ou 0110000101110010100 número é positivo, e seu expoente é $-15+24=9$. A mantissa é $10111001010 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* $\rightarrow$ *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
 $187.27_{(10)} \rightarrow 10111011.0100010100_{(2)}$
2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
 $10111011.0100010100 \times 2^0$
 $1011101.10100010100 \times 2^1$
 $101110.110100010100 \times 2^2$
 $10111.0110100010100 \times 2^3$
 $1011.10110100010100 \times 2^4$
 $101.110110100010100 \times 2^5$
 $10.1110110100010100 \times 2^6$
 $1.01110110100010100 \times 2^7$
 $.101110110100010100 \times 2^8$
Note que as 7 linhas acima representam o mesmo número.
3. Como o número é positivo, seu sinal é 0.
4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
 $23_{(10)} \rightarrow 10111_{(2)}$
5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 0 0 1 0 0 0 1 0 1 0 0 0 0
1 1 1 0 1 1 1 0 0 1 0 0 1 0 1 1

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

1 0 0 1 0 0 1 1 0 0 0 1 1 0 1 1
1 0 1 0 0 0 0 0 1 0 0 0 0 0 1 0
0 1 0 1 0 1 0 1 1 1 1 1 0 1 0 1
0 0 0 1 0 1 1 0 0 1 0 0 1 1 1 0

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

100
-58.38

Responda aqui

1.	2.		
		//// //// //// ////	//// //// //// ////
3.	4.	5.	6.
7			
8			



Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentativa de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127..0..127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

11111111

...

10000001

10000000

00000000

...

01111111

=

=

=

=

=

=

$-(2^6 + \dots + 2^1 + 2^0) = -127$

-1

-0 (?)

0

$2^6 + 2^5 + \dots + 2^0 = 127$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número (1011)₂ como expressão de um negativo (1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o

primeiro bit era 1, então -5. Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty.. \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 \dots d_n \times \beta^{\pm e_1 e_2 \dots e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 \dots e_m$ também com o seu sinal. O conjunto $d_1 d_2 \dots d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

s_1	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	s_2	e_1	e_2	e_3	e_4
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	----------	-------	-------	-------	-------	-------

 s_1 sinal do número (da mantissa). 0 $\rightarrow$ positivo e 1 $\rightarrow$ negativo
 $d_1 \dots d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: 0 $\rightarrow$ + e 1 $\rightarrow$ -
 $e_1 \dots e_4$ expoente
Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.11111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$. Já o maior valor é $0.1111111111.01111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.11111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de -15..15 a 0..31. Isto é possível porque usando o sinal, tinham-se duas representações para o zero (+0 e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, \dots, d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

```
1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 0 1 0 0
```

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

```
1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0
```

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 0 e agora, soma-se 1 e fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 1. A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0, devemos estudar a distribuição de bits. Vamos lá

```
1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m m
```

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0 0 0 1 0 0 0 1 0, que deve ter um 1 colocado à frente dando o binário de 11 bits 1 0 0 0 1 0 0 0 0 1 0. Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625.

Vamos ao quarto caso: 0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0 ou 0 | 1 1 0 0 0 | 0 1 1 1 0 0 1 0 1 0 O número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1.0 1 1 1 0 0 1 0 1 0 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* → *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

- 1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
187.27₍₁₀₎ → 10111011.0100010100₍₂₎
- 2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
10111011.0100010100 × 2⁰
1011101.10100010100 × 2¹
101110.110100010100 × 2²
10111.0110100010100 × 2³
1011.10110100010100 × 2⁴
101.110110100010100 × 2⁵
10.1110110100010100 × 2⁶
1.01110110100010100 × 2⁷
.101110110100010100 × 2⁸
Note que as 7 linhas acima representam o mesmo número.
- 3. Como o número é positivo, seu sinal é 0.
- 4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
23₍₁₀₎ → 10111₍₂₎
- 5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
- 6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
- 7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

🔗 Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 0 1 1 1 1 1 1 1 1 0 0 1 0 0
1 1 1 0 0 1 1 0 1 0 0 1 0 0 1 1

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

0 1 0 1 0 1 0 1 0 1 1 0 0 0 0 1
0 0 1 0 0 0 0 0 0 1 0 0 1 0 1 1
0 0 1 1 0 0 1 0 1 1 1 0 1 1 0 1
1 0 0 0 0 0 0 0 1 1 1 1 0 0 1 0

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

106
-49.76

Responda aqui

1.	2.		
		//// //// ////	//// //// ////
3.	4.	5.	6.
7			
8			

Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentação de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127...127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

$$\begin{aligned} 11111111 &= -(2^6 + \dots + 2^1 + 2^0) = -127 \\ \dots & \\ 10000001 &= -1 \\ 10000000 &= -0 (?) \\ 00000000 &= 0 \\ \dots & \\ 01111111 &= 2^6 + 2^5 + \dots + 2^0 = 127 \end{aligned}$$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número $(1011)_2$ como expressão de um negativo

(1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty... \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 \dots d_n \times \beta^{\pm e_1 e_2 \dots e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 \dots e_m$ também com o seu sinal. O conjunto $d_1 d_2 \dots d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

s_1	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	s_2	e_1	e_2	e_3	e_4
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	----------	-------	-------	-------	-------	-------

s_1 sinal do número (da mantissa). $0 \rightarrow$ positivo e $1 \rightarrow$ negativo
 $d_1 \dots d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: $0 \rightarrow +$ e $1 \rightarrow -$
 $e_1 \dots e_4$ expoente

Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.1111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.0111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.1111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, \dots, d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

```
1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 1 0 1 0 0
```

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

```
1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0
```

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1101101101100101 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0010010010011010 e agora, soma-se 1 e fica 0010010010011011 . A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1100110001000010 , devemos estudar a distribuição de bits. Vamos lá

```
1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s   e e e e e   m m m m m m m m m m
```

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0001000010 , que deve ter um 1 colocado à frente dando o binário de 11 bits 100010000010 . Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625.

Vamos ao quarto caso: 011000011100101010 ou 011000010111001010 número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1,0111001010 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* → *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

- 1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
187.27₍₁₀₎ → 10111011.0100010100₍₂₎
- 2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
10111011.0100010100 × 2⁰
1011101.10100010100 × 2¹
101110.110100010100 × 2²
10111.0110100010100 × 2³
1011.10110100010100 × 2⁴
101.110110100010100 × 2⁵
10.1110110100010100 × 2⁶
1.01110110100010100 × 2⁷
.101110110100010100 × 2⁸
Note que as 7 linhas acima representam o mesmo número.
- 3. Como o número é positivo, seu sinal é 0.
- 4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
23₍₁₀₎ → 10111₍₂₎
- 5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
- 6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
- 7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

👉 Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 0 1 1 0 1 0 0 1 0 1 1 1 0 1
1 1 1 0 1 1 1 0 1 1 0 1 0 0 0 1

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

0 0 0 0 1 1 0 0 1 0 1 0 0 1 0 1
1 0 1 0 1 0 1 1 1 1 1 0 0 1 1 0
1 0 0 0 0 1 0 0 1 0 1 0 1 1 0 0
0 0 0 0 0 0 1 1 1 1 0 1 0 1 0 0

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

120
-48.74

Responda aqui

1.	2.		
		//// //// ////	//// //// ////
3.	4.	5.	6.
7			
8			



Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentação de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127...127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

$$\begin{aligned} 11111111 &= -(2^6 + \dots + 2^1 + 2^0) = -127 \\ \dots & \\ 10000001 &= -1 \\ 10000000 &= -0 (?) \\ 00000000 &= 0 \\ \dots & \\ 01111111 &= 2^6 + 2^5 + \dots + 2^0 = 127 \end{aligned}$$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número $(1011)_2$ como expressão de um negativo

(1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty... \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 \dots d_n \times \beta^{\pm e_1 e_2 \dots e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 \dots e_m$ também com o seu sinal. O conjunto $d_1 d_2 \dots d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

s_1	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	s_2	e_1	e_2	e_3	e_4
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	----------	-------	-------	-------	-------	-------

s_1 sinal do número (da mantissa). $0 \rightarrow$ positivo e $1 \rightarrow$ negativo
 $d_1 \dots d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: $0 \rightarrow +$ e $1 \rightarrow -$
 $e_1 \dots e_4$ expoente

Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.1111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.0111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.1111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, \dots, d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 0 1 0 0

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 0 e agora, soma-se 1 e fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 1. A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1 1 0 0 1 1 0 0 1 0 0 0 0 1 0, devemos estudar a distribuição de bits. Vamos lá

1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0 0 0 1 0 0 0 1 0, que deve ter um 1 colocado à frente dando o binário de 11 bits 1 0 0 0 1 0 0 0 0 1 0. Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625.

Vamos ao quarto caso: 0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0 ou 0 | 1 1 0 0 0 | 0 1 1 1 0 0 1 0 1 0 O número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1,0 1 1 1 0 0 1 0 1 0 = 1482$. Ao final, o número é $2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* $\rightarrow$ *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
 $187.27_{(10)} \rightarrow 10111011.0100010100_{(2)}$
2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
 $10111011.0100010100 \times 2^0$
 $1011101.10100010100 \times 2^1$
 $101110.110100010100 \times 2^2$
 $10111.0110100010100 \times 2^3$
 $1011.10110100010100 \times 2^4$
 $101.110110100010100 \times 2^5$
 $10.1110110100010100 \times 2^6$
 $1.01110110100010100 \times 2^7$
 $.101110110100010100 \times 2^8$
Note que as 7 linhas acima representam o mesmo número.
3. Como o número é positivo, seu sinal é 0.
4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
 $23_{(10)} \rightarrow 10111_{(2)}$
5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 0 1 1 1 1 0 1 1 1 1 1 1 0 1
1 1 1 1 0 0 1 1 0 1 0 1 1 1 1 0 0

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

1 1 0 1 0 0 0 0 1 1 0 1 0 0 1 0
0 0 1 1 1 0 0 1 1 1 0 0 1 0 0 0
0 0 1 0 0 0 1 0 0 0 0 0 0 1 1 1
0 1 0 0 1 0 1 0 0 0 0 1 0 0 1 1

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

114
-57.8

Responda aqui

1.	2.		
		//// //// //// ////	//// //// //// ////
3.	4.	5.	6.
7			
8			



Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentação de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=(((5**0.5)**2)-5)
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127...127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

$$\begin{aligned} 11111111 &= -(2^6 + \dots + 2^1 + 2^0) = -127 \\ \dots & \\ 10000001 &= -1 \\ 10000000 &= -0 (?) \\ 00000000 &= 0 \\ \dots & \\ 01111111 &= 2^6 + 2^5 + \dots + 2^0 = 127 \end{aligned}$$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número $(1011)_2$ como expressão de um negativo

(1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1


Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty... \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 \dots d_n \times \beta^{\pm e_1 e_2 \dots e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 \dots e_m$ também com o seu sinal. O conjunto $d_1 d_2 \dots d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é



$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.1111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.0111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.1111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, \dots, d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	<i>exp</i> ₁₀	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 0 1 0 0

São eles: -9371 e -5388
Agora, ache os flutuantes, com 7 casas decimais, de

1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 0 e agora, soma-se 1 e fica 0 0 1 0 0 1 0 0 1 0 0 1 1 0 1 1. A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo. Quanto ao terceiro caso, o flutuante 1 1 0 0 1 1 0 0 1 0 0 0 0 1 0, devemos estudar a distribuição de bits. Vamos lá

1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m m

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0 0 0 1 0 0 0 1 0, que deve ter um 1 colocado à frente dando o binário de 11 bits 1 0 0 0 1 0 0 0 0 1 0. Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625.

Vamos ao quarto caso: 0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0 ou 0 | 1 1 0 0 0 | 0 1 1 1 0 0 1 0 1 0 O número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1,0 1 1 1 0 0 1 0 1 0 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* → *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

- 1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
187.27₍₁₀₎ → 10111011.0100010100₍₂₎
- 2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
10111011.0100010100 × 2⁰
1011101.10100010100 × 2¹
101110.110100010100 × 2²
10111.0110100010100 × 2³
1011.10110100010100 × 2⁴
101.110110100010100 × 2⁵
10.1110110100010100 × 2⁶
1.01110110100010100 × 2⁷
.101110110100010100 × 2⁸
Note que as 7 linhas acima representam o mesmo número.
- 3. Como o número é positivo, seu sinal é 0.
- 4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
23₍₁₀₎ → 10111₍₂₎
- 5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
- 6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
- 7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

👉 Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 1 0 0 0 1 0 0 1 0 1 0 0 1
1 1 0 1 1 1 1 0 1 1 1 0 0 0 1 0

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

0 1 0 0 1 1 0 1 0 1 1 1 0 1 1 0
0 1 0 0 0 1 1 0 0 1 1 0 1 0 1 1
1 1 0 1 1 1 1 1 0 0 1 1 0 1 0 0
1 0 1 1 0 1 0 0 0 0 0 0 1 0 1 0

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

116
-57.3

Responda aqui

1.	2.		
		//// //// //// ////	//// //// //// ////
3.	4.	5.	6.
7			
8			



Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* → *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

- 1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
187.27₍₁₀₎ → 10111011.0100010100₍₂₎
- 2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
10111011.0100010100 × 2⁰
1011101.10100010100 × 2¹
101110.110100010100 × 2²
10111.0110100010100 × 2³
1011.10110100010100 × 2⁴
101.110110100010100 × 2⁵
10.1110110100010100 × 2⁶
1.01110110100010100 × 2⁷
.101110110100010100 × 2⁸
Note que as 7 linhas acima representam o mesmo número.
- 3. Como o número é positivo, seu sinal é 0.
- 4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
23₍₁₀₎ → 10111₍₂₎
- 5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
- 6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
- 7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

👉 Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 0 0 0 0 0 1 0 1 1 0 0 0 1
1 1 0 1 1 1 0 1 1 1 1 0 0 1 0 0

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

1 1 0 0 1 1 1 0 0 1 0 0 1 0 0 1
0 0 1 1 0 0 0 0 1 1 1 0 1 1 0 1
0 0 0 1 1 1 1 1 1 0 0 0 0 1 0 0
1 0 1 0 1 0 1 1 0 1 0 0 0 1 0 1

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

137
-59.56

Responda aqui

1.	2.		
		//// //// //// ////	//// //// //// ////
3.	4.	5.	6.
7			
8			

Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentação de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=(((5**0.5)**2)-5)
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127...127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

```
11111111 = -(2^6 + ... + 2^1 + 2^0) = -127
...
10000001 = -1
10000000 = -0 (?)
00000000 = 0
...
01111111 = 2^6 + 2^5 + ... + 2^0 = 127
```

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número $(1011)_2$ como expressão de um negativo

(1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty... \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$\pm d_1 d_2 ... d_n \times \beta^{\pm e_1 e_2 ... e_m}$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 ... e_m$ também com o seu sinal. O conjunto $d_1 d_2 ... d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

<u>s</u> ₁	<u>d</u> ₁	<u>d</u> ₂	<u>d</u> ₃	<u>d</u> ₄	<u>d</u> ₅	<u>d</u> ₆	<u>d</u> ₇	<u>d</u> ₈	<u>d</u> ₉	<u>d</u> ₁₀	<u>s</u> ₂	<u>e</u> ₁	<u>e</u> ₂	<u>e</u> ₃	<u>e</u> ₄
-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------	------------------------	-----------------------	-----------------------	-----------------------	-----------------------	-----------------------

s_1 sinal do número (da mantissa). $0 \rightarrow$ positivo e $1 \rightarrow$ negativo
 $d_1..d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: $0 \rightarrow +$ e $1 \rightarrow -$
 $e_1..e_4$ expoente

Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$

Nesse esquema, o menor valor representável é $0.1000000000.1111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.0111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.1111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$v = (-1)^s (0.f)_2 2^{e-15}$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, ... d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$v = (-1)^s (1.f)_2 2^{e-15}$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	<i>exp</i> ₁₀	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

```
1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 1 0 1 0 0
```

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

```
1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0
```

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 110110110110100101 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0010010010011010 e agora, soma-se 1 e fica 0010010010011011 . A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1100110001000010 , devemos estudar a distribuição de bits. Vamos lá

```
1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s e e e e e m m m m m m m m m m
```

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0001000010 , que deve ter um 1 colocado à frente dando o binário de 11 bits 100010000010 . Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625 .

Vamos ao quarto caso: 011000011100101010 ou 011000010111001010 número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1,0111001010 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* → *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

- 1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
187.27₍₁₀₎ → 10111011.0100010100₍₂₎
- 2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
10111011.0100010100 × 2⁰
1011101.10100010100 × 2¹
101110.110100010100 × 2²
10111.0110100010100 × 2³
1011.10110100010100 × 2⁴
101.110110100010100 × 2⁵
10.1110110100010100 × 2⁶
1.01110110100010100 × 2⁷
.101110110100010100 × 2⁸
Note que as 7 linhas acima representam o mesmo número.
- 3. Como o número é positivo, seu sinal é 0.
- 4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
23₍₁₀₎ → 10111₍₂₎
- 5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
- 6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
- 7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

👉 Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 0 1 1 1 1 0 1 0 0 1 1 1 0
1 1 1 1 0 0 0 1 1 0 0 0 0 1 1 1

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

0 1 0 0 0 1 1 0 0 0 1 1 1 1 1 0
1 0 0 0 1 1 1 0 0 0 0 0 1 0 0 0
0 1 1 0 1 0 1 0 1 1 0 1 0 1 1 1
1 0 0 1 1 1 0 1 1 0 1 0 1 1 1 0

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

97
-57.84

Responda aqui

1.	2.		
		//// //// ////	//// //// ////
3.	4.	5.	6.
7			
8			

Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentação de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127...127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

$$\begin{aligned} 11111111 &= -(2^6 + \dots + 2^1 + 2^0) = -127 \\ \dots & \\ 10000001 &= -1 \\ 10000000 &= -0 (?) \\ 00000000 &= 0 \\ \dots & \\ 01111111 &= 2^6 + 2^5 + \dots + 2^0 = 127 \end{aligned}$$

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número $(1011)_2$ como expressão de um negativo

(1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1

Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty... \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 \dots d_n \times \beta^{\pm e_1 e_2 \dots e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 \dots e_m$ também com o seu sinal. O conjunto $d_1 d_2 \dots d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é

s_1	d_1	d_2	d_3	d_4	d_5	d_6	d_7	d_8	d_9	d_{10}	s_2	e_1	e_2	e_3	e_4
-------	-------	-------	-------	-------	-------	-------	-------	-------	-------	----------	-------	-------	-------	-------	-------

s_1 sinal do número (da mantissa). $0 \rightarrow$ positivo e $1 \rightarrow$ negativo
 $d_1 \dots d_{10}$ mantissa com 10 dígitos binários significativos
 s_2 sinal do expoente: $0 \rightarrow +$ e $1 \rightarrow -$
 $e_1 \dots e_4$ expoente

Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.1111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.0111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.1111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, \dots, d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

```
1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 1 0 1 0 0
```

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

```
1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0
```

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 110110110110100101 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0010010010011010 e agora, soma-se 1 e fica 0010010010011011 . A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1100110001000010 , devemos estudar a distribuição de bits. Vamos lá

```
1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s   e e e e e   m m m m m m m m m m
```

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0001000010 , que deve ter um 1 colocado à frente dando o binário de 11 bits 100010000010 . Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625 .

Vamos ao quarto caso: 011000011100101010 ou 011000010111001010 número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1,0111001010 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* $\rightarrow$ *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
 $187.27_{(10)} \rightarrow 10111011.0100010100_{(2)}$
2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
 $10111011.0100010100 \times 2^0$
 $1011101.10100010100 \times 2^1$
 $101110.110100010100 \times 2^2$
 $10111.0110100010100 \times 2^3$
 $1011.10110100010100 \times 2^4$
 $101.110110100010100 \times 2^5$
 $10.1110110100010100 \times 2^6$
 $1.01110110100010100 \times 2^7$
 $.101110110100010100 \times 2^8$
Note que as 7 linhas acima representam o mesmo número.
3. Como o número é positivo, seu sinal é 0.
4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
 $23_{(10)} \rightarrow 10111_{(2)}$
5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 0 1 0 1 0 0 0 1 0 0 1 1 1
1 1 1 1 0 0 1 0 0 1 1 0 1 0 0 1

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

1 0 1 0 0 1 0 1 0 1 0 1 0 1 0 0
1 0 0 0 0 0 1 1 0 1 1 1 1 1 1 1
1 0 0 1 1 1 1 0 0 0 1 1 1 0 1 1
0 1 0 0 0 1 0 0 1 0 0 1 1 1 0 1

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

107
-44.22

Responda aqui

1.	2.		
		//// //// //// ////	//// //// //// ////
3.	4.	5.	6.
7			
8			



Representação de números em máquinas

Qualquer máquina digital (computadores, celulares, fornos de microondas, impressoras, I-pads, automóveis, aviões, máquinas fotográficas, geladeiras, televisores, máquinas de dinheiro,...) precisa manusear e armazenar números. Embora lá nos primórdios do século XX tenha havido a tentação de representar números por medidas analógicas, rapidamente a qualidade da representação digital se impôs.

Todas essas máquinas usam lógica binária e portanto usam bits (0 ou 1) internamente. Agradecemos a George Boole e a Claude Shannon por isso. Em geral, para guardar um número, todas trabalham com quantidades fixas de bits, o que ao fim e ao cabo implica em uma quantidade finita de números representáveis. Ou seja, na matemática computacional estamos presos à matemática finita de Karl Gauss e aos grupos de Evariste Galois.

Todos os demais números são obtidos por proximidade a algum número desses que é representável, gerando aqui um erro de representação. Por exemplo, 2, seu quadrado e o número 4 podem ser representados em um computador usando Python. Já, a raiz quadrada de 5 não pode (e quando obtida é forçosamente arredondada) daí:

```
>>> 2**2 == 4
True
>>> ((5**0.5)**2) == 5
False
>>> dif=((5**0.5)**2)-5
>>> print(f'{dif:.24f}')
0.0000000000000000888178420
```

Inteiros

Os inteiros podem ser corretamente representados, limitados ao tamanho do **registro** assim entendido como a unidade de bits que são alocados ao armazenamento de um número. Supondo n bits, pode-se guardar até o número $2^n - 1$. Por exemplo, se $n = 4$ pode-se guardar até o 15. Não acredite em mim, faça as representações para se convencer. Se $n = 8$, guarda-se até o 255. Se $n = 16$ o limite agora é 65535, e assim por diante. Note-se que esta representação é para inteiros sem sinal (ou positivos). Se, se necessitar guardar números negativos também, perde-se um bit (o mais à esquerda) para o sinal e portanto o maior número passa a ser $2^{n-1} - 1$ e o menor, que lá no caso sem sinal era o zero, agora é -2^{n-1} . Por exemplo, se $n = 8$ o intervalo de representação é $-127...127$. Convenciona-se usar o bit 0 para positivo e o bit 1 para negativo e daqui:

```
11111111 = -(2^6 + ... + 2^1 + 2^0) = -127
...
10000001 = -1
10000000 = -0 (?)
00000000 = 0
...
01111111 = 2^6 + 2^5 + ... + 2^0 = 127
```

As memórias têm crescido muito nos últimos anos, e os tamanhos agora são bem generosos. Por exemplo, em C++, inteiros podem ser de 8 ou 16 bits (já visto antes) mas também de 32 bits (limite de 4.294.967.296) ou de 64 bits (limite de 18.446.744.073.709.551.616) ou a metade disso se houver sinal. A menos de algum detalhe obscuro, todas as plataformas de computadores compartilham estes valores.

Inteiros negativos

Os negativos inteiros são representados como complemento para 2. Esta operação naturalmente levará o primeiro bit a ser 1 (positivos têm primeira posição igual a zero). Mas a representação do número é um pouco diferente do que seria esperado. A regra é simples: Troque zeros por uns e vice-versa. Some 1. Pronto. Eis um exemplo: Suponha o número $(1011)_2$ como expressão de um negativo

(1º bit=1). Trocando uns-zeros fica (0100). Somando 1 fica (0101) que corresponde a 5. Como o primeiro bit era 1, então -5 . Acompanhe na tabela de 4 bits:

Binário	Hexad	Decimal	Compl. 2
0000	0	0	0
0001	1	1	1
0010	2	2	2
0011	3	3	3
0100	4	4	4
0101	5	5	5
0110	6	6	6
0111	7	7	7
1000	8	8	-8
1001	9	9	-7
1010	A	10	-6
1011	B	11	-5
1100	C	12	-4
1101	D	13	-3
1110	E	14	-2
1111	F	15	-1


Reais ou flutuantes

A dificuldade inicial é como representar o intervalo $-\infty... \infty$ em um número limitado e fixo de bits. Agora os bits disponíveis terão que ser distribuídos em diversos componentes do número a representar, a saber

$$\pm d_1 d_2 ... d_n \times \beta^{\pm e_1 e_2 ... e_m}$$

Considerando que a base β é fixa na arquitetura, ela não precisa ser guardada a cada número. Restam os dígitos $d_1 d_2 d_n$ junto com o seu sinal, além dos dígitos $e_1 e_2 ... e_m$ também com o seu sinal. O conjunto $d_1 d_2 ... d_n$ é conhecido como mantissa do número e está normalizado entre 0 e 1. Em outras palavras, o número 127.345 seria representado por 0.127345×10^3 .

Padrão 16 bits original Esta representação clássica nem é mais usada, mas vai-se começar com ela por razões didáticas. Eis como funcionava um sistema em ponto flutuante, com base binária ($\beta = 2$), com $t = 10$ dígitos binários na mantissa e expoentes limitados entre $I = -15$ e $S = +15$, lembrando que $(15)_{10} = (1111)_2$ e portanto o registro é



Nessa representação os números são armazenados no formato normalizado (entre 0 e 1) logo, $d_1 \neq 0$ e portanto o número é

$$v = (-1)^{\pm s_1} (0.f)_2 2^{\pm exp}$$

Nesse esquema, o menor valor representável é $0.1000000000.1111$ e este valor é $+(0.1)_2 \times 2^{-15} = (2^{-1} \times 2^{-15})_{10} = (2^{-16})_{10} = 0.0000152587890625$.

Já o maior valor é $0.1111111111.0111$ Que vem a ser $(32736)_{10} \approx 2^{15}$.

Finalmente o zero é $0.0000000000.1111$. Lembrando que este é o único número não normalizado, pois sua mantissa é toda zero. Todo número menor que o menor valor representável acarreta *underflow* enquanto todo número maior que o maior representável acarreta *overflow*.

Otimizações - padrão IEEE754

Algumas características do exposto foram alteradas para ampliar a faixa de representação e organizar a representação. Primeiro, a mantissa e o expoente têm seus locais invertidos.

Polarização A idéia é inventar um valor fixo e somá-lo a todos os expoentes, transformando um número de 4 bits mais sinal em um número de 5 bits. Neste caso (16 bits) o valor de polarização é 15 e agora passa-se de $-15..15$ a $0..31$. Isto é possível porque usando o sinal, tinham-se duas representações para o zero ($+0$ e -0) e isto é desnecessário. Agora o número é visto como

$$v = (-1)^s (0.f)_2 2^{e-15}$$

Desprezo de d_1 Não se armazena o d_1 que como se viu vale sempre 1. Agora a mantissa representada passa a ter os dígitos $d_2, d_3, ... d_{t+1}$ e a posição normalizada do ponto passa a ser à direita de $d_1 = 1$ ou seja

$$v = (-1)^s (1.f)_2 2^{e-15}$$

flexibilização da normalização na mantissa O explicado acima tenderia a levantar o valor da menor representação possível. Para evitar isso, quando $e = 00000$ (após a subtração de 15) a normalização do $d_1 = 1$ é eliminada. Agora o menor valor possível é $0.00000.0000000001$ que é igual a 0.0009765625 . O padrão ficou assim:

s	e (5d)	f (10d)
1	2..6	7..16

O número aqui armazenado obedece a algumas regras:

se $0 < e < 31$ então $v = (-1)^s 2^{e-15} (1.f)_2$
se $e = 0$ e $f \neq 0$ então $v = (-1)^s 2^{-14} (0.f)$
se $e = 0$ e $f = 0$ então este número é zero
se $e = 31 = 2^5 - 1$ então v pertence à região de overflow.

Outros formatos

Esta especificação foi levada a outros formatos, a saber

A	B	C	D
formato	exp	exp_{10}	mant
binary16	5 dig	31	10 d
binary32	8 dig	255	23 d
binary64	11 dig	2047	52 d
binary128	15 dig	32767	112 d

Exemplo

Ache os valores negativos (por complemento a 2) das variáveis

```
1 1 0 1 1 0 1 1 0 1 1 0 0 1 0 1
1 1 1 0 1 0 1 0 1 1 1 1 0 1 0 0
```

São eles: -9371 e -5388

Agora, ache os flutuantes, com 7 casas decimais, de

```
1 1 0 0 1 1 0 0 0 1 0 0 0 0 1 0
0 1 1 0 0 0 0 1 1 1 0 0 1 0 1 0
0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 1
1 0 1 0 1 1 1 1 1 0 0 0 1 0 1 0
```

As respostas são -8.515625, 370.5, 1113.0000000 e -0.0588989257

Vamos ver etapa a etapa, como os resultados acima foram encontrados: Começando com o inteiro 1101101101100101 (caso 1, acima). Como o primeiro bit é 1, o número é negativo e precisamos invertê-lo. Fica 0010010010011010 e agora, soma-se 1 e fica 0010010010011011 . A conversão deste número para base decimal é $1+2+8+16+128+1024+8192=9371$. Portanto a resposta é -9371.

Tente achar por sua conta o segundo exemplo.

Quanto ao terceiro caso, o flutuante 1100110001000010 , devemos estudar a distribuição de bits. Vamos lá

```
1 | 1 0 0 1 1 | 0 0 0 1 0 0 0 0 1 0
s   e e e e e   m m m m m m m m m m
```

O sinal do número é obtido fazendo -1^s e neste caso o número será negativo.

O expoente é $-15+19=4$, portanto ao final ter-se-á que multiplicar a mantissa por $2^4 = 16$

Finalmente a mantissa, é o número 0001000010 , que deve ter um 1 colocado à frente dando o binário de 11 bits 100010000010 . Convertendo este número a decimal tem-se $2+64+1024=1090$, que deve ser dividido por $2^{11} = 2048$ dando $1090/2048 = 0.5322265625$ que multiplicado por 16 da $0.5322265625 \times 16 = 8.515625$ ou -8.515625 .

Vamos ao quarto caso: 0110000111001010 ou 0110000101110010 número é positivo, e seu expoente é $-15+24=9$. A mantissa é $1,0111001010 = 1482$. Ao final, o número é $+2^9 \times (1482/2048) = 370.5$.

Tente resolver agora o quinto e o sexto casos.

Como o sistema converte

Agora, a grande questão: quando você digita um número em um programa ou em uma tela, o computador precisa registrar este número na memória, usando um dos formatos aqui estudados. Vamos estudar o processo de conversão *decimal* → *float* e para campos de 16 bits. Vale a referência de este tamanho de campo não é mais usado, e só está aqui pela facilidade e simplicidade dos cálculos envolvidos. Vamos por etapas:

- 1. Dado um número real, por exemplo 183.27, a primeira coisa a fazer é converter este número em binário. Fica:
187.27₍₁₀₎ → 10111011.0100010100₍₂₎
- 2. Agora, o ponto decimal deve ser levado à esquerda, até o primeiro 1 do número. A cada casa, o expoente deve ser incrementado. Acompanhe:
10111011.0100010100 × 2⁰
1011101.10100010100 × 2¹
101110.110100010100 × 2²
10111.0110100010100 × 2³
1011.10110100010100 × 2⁴
101.110110100010100 × 2⁵
10.1110110100010100 × 2⁶
1.01110110100010100 × 2⁷
.101110110100010100 × 2⁸
Note que as 7 linhas acima representam o mesmo número.
- 3. Como o número é positivo, seu sinal é 0.
- 4. A potência do número é 8 que deve ser somado com 15, totalizando 23. Agora, é hora de converter o expoente em binário:
23₍₁₀₎ → 10111₍₂₎
- 5. Finalmente, e hora de pegar 10 bits da mantissa, lembrando que o primeiro 1 (aquele que fica depois do ponto) é omitido. A mantissa fica: 0111011010
- 6. o numero binario em formato binary16 é
0 | 1 0 1 1 1 | 0 1 1 1 0 1 1 0 1 0
- 7. Se você converter este número para decimal, vai encontrar 187.25, o que demonstra a baixa precisão deste formato (e explica porque ele não é usado).

👉 Para você fazer

Interprete os 2 números binários a seguir como *binary16* inteiros e negativos e ache os valores decimais
1 e 2.

1 1 1 1 1 1 0 1 0 0 0 1 1 0 1 1
1 1 1 0 0 0 0 0 1 1 0 1 1 1 0 1

e agora interprete os 4 números a seguir como *binary16* flutuantes e ache os decimais equivalentes com 5 casas decimais
3, 4, 5 e 6.

1 0 1 1 0 0 0 1 1 0 1 0 0 1 0 0
0 0 0 0 1 1 1 1 1 1 1 1 1 1 0 0
0 1 1 0 1 1 1 1 0 0 0 0 1 0 0 0
0 0 1 0 1 1 1 0 1 0 1 0 1 1 0 0

Finalmente, converta os valores abaixo que estão em decimal para o formato *binary16*
7 e 8.

140
-56.98

Responda aqui

1.	2.		
		//// //// ////	//// //// ////
3.	4.	5.	6.
7			
8			