

Codage des nombres

23 janvier 2024

Le site suivant <http://www.binaryconvert.com/index.html> propose quelques conversions possibles.

1 Écriture d'un entier naturel dans une base b

Le système décimal est une invention de l'homme, qui est désormais utilisé par tous les pays du monde. Il a pourtant fallu attendre plusieurs siècles pour cela...

1. Généralités

En base 10, $523 = 5 \times 10^2 + 2 \times 10^1 + 3 \times 10^0$.

En base 7, $(523)_7 = 5 \times 7^2 + 2 \times 7^1 + 3 \times 7^0$.

Réciproquement, pour décomposer 523 en base 7, on effectue des divisions euclidiennes successives par 7 :

algorithme : decomposition_base
Entrées : $n, b \in \mathbb{N}$ avec $b \geq 2$
Résultat : l'écriture en base b de l'entier n
Variables : a, d deux entiers et une chaîne de caractère mot
 $a \leftarrow n$
 $mot \leftarrow ' ' \#$ mot vide
Tant que $a \neq 0$, Faire
 $d \leftarrow$ le reste de la division de a par b
 $mot \leftarrow d + mot \#$ ajoute le caractère d à mot
 $a \leftarrow a/b$
Fin du Tant que
Renvoyer mot

Cet algorithme est de complexité logarithmique. Le nombre d'itérations correspond au nombre de chiffres en base b de l'entier n , qui vaut

$$\lfloor \log_b(n) \rfloor + 1.$$

2. Le cas de la base 2

En base deux, il n'y a que deux chiffres 0 ou 1. Par exemple, $(1011)_2 = 8 + 2 + 1 = 11$. Les 4 chiffres qui constituent l'écriture en base 2 de 11 sont appelés des bits. On dit aussi que 1011 est un mot binaire de 4 bits. Un octet correspond à 8 bits.

Le mot binaire $\underbrace{100 \dots 00}_{n \text{ zéros}}$ code l'entier naturel 2^n (l'équivalent en base 10 est par exemple $1000 = 10^3$).

Avec n bits, on peut coder 2^n entiers donc tous les entiers de 0 à $2^n - 1$.

Le plus grand entier naturel codé sur n bits est $\underbrace{(111 \dots 11)}_{n \text{ bits}}_2$, il vaut $2^n - 1$ (l'équivalent en base 10 est par exemple $999 = 10^3 - 1$).

Remarques :

- multiplier par 2^k revient à rajouter k zéros sur la droite. Par exemple, $(101101)_2 \times 2^3 = (101101 \ 000)_2$.
- rappelons une approximation utile en informatique : $2^{10} = 1024 \sim 1000 = 10^3$.

3. Le cas de la base hexadécimale (base 16)

Considérons le nombre $(A8C)_{16}$ en base 16.

$$\begin{aligned} (A8C)_{16} &= 10 \times 16^2 + 8 \times 16^1 + 12 \times 16^0 \\ &= (1010)_2 \times (2^4)^2 + (1000)_2 \times (2^4) + (1100)_2 \\ &= (1010 \ 0000 \ 0000)_2 + (1000 \ 0000)_2 + (1100)_2 \\ &= (\underbrace{1010}_A \ \underbrace{1000}_8 \ \underbrace{1100}_C)_2 \end{aligned}$$

Un mot de 4 bits est un entier compris entre 0 et 15, donc un chiffre en base 16. En regroupant par paquets de 4 bits à partir de la droite, on obtient une correspondance facile entre la base 2 et la base 16.

L'avantage de la base 16 étant qu'elle nécessite moins de chiffres et est donc plus lisible pour un humain.

Remarque : les fonctions `bin` (resp. `hex`) de Python renvoie les décompositions binaires (resp. hexadécimales) d'un entier.

```
>>> hex(2700)
'0xa8c'
```

```
>>> bin(2700)
'0b101010001100'
```

4. Comme à l'école primaire. Additions et multiplications posées...

2 Représentation binaire d'un entier relatif

Comment coder un entier relatif sur n bits ? Une solution pourrait être par exemple d'utiliser le premier bit pour coder le signe de l'entier relatif. Par exemple avec $n = 4$ bits, le plus petit entier serait -7 codé par le mot $\boxed{1111}$ et le plus grand serait $+7$ codé par le mot $\boxed{0111}$. Dans ce cas, deux inconvénients se présentent :

- le nombre zéro a deux représentations différentes $\boxed{0000}$ et $\boxed{1000}$
- l'algorithme de l'addition ne fonctionne pas si on ajoute des nombres de signe différent. En effet, l'entier -2 est codé par le mot $\boxed{1010}$, et l'entier 1 par le mot $\boxed{0001}$. L'addition des mots $\boxed{1010}$ et $\boxed{0001}$ donne le mot $\boxed{1011}$ qui représente le nombre -3 au lieu du nombre -1 résultat de $-2 + 1 = -1$ dont la représentation est $\boxed{1001}$.

2.1 Représentation en complément à deux ou modulo 2^n

On va procéder autrement, et utiliser une représentation dite «en complément à deux» ou «représentation modulo 2^n ».

Définition 1 (Représentation d'un nombre relatif en complément à deux) *Voici le principe : avec n bits nous allons coder 2^n entiers dont la moitié sont positifs ou nuls. Plus précisément nous allons pouvoir représenter les entiers naturels de 0 à $2^{n-1} - 1$ et les entiers négatifs de -1 à -2^{n-1} :*

- si $x \in \llbracket 0, 2^{n-1} - 1 \rrbracket$, on représente x par son mot binaire associé
- si $x \in \llbracket -2^{n-1}, -1 \rrbracket$, on représente x par le mot binaire qui code l'entier naturel $x + 2^n$.




FIGURE 1 – La représentation des nombres relatifs en complément en deux sur n bits

Remarques :

- si $x \in \llbracket -2^{n-1}, -1 \rrbracket$, le nombre $x + 2^n$ est compris entre $2^n - 2^{n-1}$ et $2^n - 1$, c'est-à-dire entre 2^{n-1} et $2^n - 1$. Il est donc le reste de la division euclidienne de x par 2^n . La représentation ci-dessus peut donc s'interpréter avec un point de vue plus mathématique :

si $x \in \llbracket -2^{n-1}, 2^{n-1}-1 \rrbracket$, x est représenté par le mot binaire codant son unique représentant modulo 2^n dans $\llbracket 0, 2^n - 1 \rrbracket$.

- il est facile de tester si un nombre est négatif. Sa représentation binaire commence par un 1.
- additionner deux entiers relatifs revient à additionner leur représentation. C'est une conséquence du fait qu'on puisse additionner deux congruences modulo 2^n . En effet, si x et y sont deux entiers de $\llbracket 0, 2^n - 1 \rrbracket$, en notant $\pi(x)$ et $\pi(y)$ leur représentation, on a $x \equiv \pi(x) \pmod{2^n}$ et $y \equiv \pi(y) \pmod{2^n}$, donc $x + y \equiv \pi(x) + \pi(y) \pmod{2^n}$. Ainsi $\pi(x + y) = \pi(x) + \pi(y)$.

2.2 Un exemple avec $n = 3$

Si $n = 3$, on peut coder les huit entiers $0, 1, 2, 3$ et $-1, -2, -3, -4$. comme $3 = (011)_2$, 3 est codé par le mot $\boxed{011}$. Le nombre -3 est négatif, on considère alors $-2 + 2^3 = 6 = (110)_2$, son représentant modulo 2^3 . On code ainsi -3 par le mot $\boxed{110}$.

Attention, il faut donc bien distinguer un nombre de sa représentation.




FIGURE 2 – La représentation des nombres relatifs avec $n = 3$ bits

Regardons toute de suite une conséquence : l'addition de deux nombres positifs peut donner un résultat négatif. En effet, quel résultat est renvoyé si l'on demande $2 + 3$ sachant que 5 ne peut être représenté en complément à deux avec 3 bits ? Et bien 2 est représenté par $\boxed{010}$, 3 par $\boxed{011}$, on additionne leur représentation, cela donne $\boxed{101}$, qui code l'entier négatif -3 puisque $(5 - 8 = -3)$.

2.3 Quel nombre de bits n en pratique dans les langages de programmation ?

Dans la plupart des langages de programmation comme C, Java, Fortran,..., les entiers relatifs sont codés sur 64 bits, ce qui correspond à la taille des registres du processeur, et qui permet d'effectuer des calculs très rapides. En Python, un autre choix a été fait, les entiers de type `int`

n'ont pas de taille maximale. Cela a des avantages, mais aussi des inconvénients, les calculs ne seront pas très rapides. Par exemple sur 64 bits, le plus grand entier positif représentable est $x = 2^{63} - 1$ et on voit que Python manipule bien $x + 1$.

```
>>> x = 2**63-1
>>> x
9223372036854775807
>>> x+1
9223372036854775808
```

En Python, tous les entiers ne sont pas forcément de type `int`. En effet avec le module `numpy` spécialisé dans le calcul numérique (il repose sur une librairie C), on peut manipuler des entiers codés de différentes manières.

```
>>> import numpy as np
>>> y = np.int64(x) # on convertit l'entier x en un entier relatif <<numpy>> codé sur 64 bits
>>> y + np.int64(1)
-9223372036854775808
```

Cette fois-ci, $y + 1$ donne le nombre négatif -2^{63} , ce qui est conforme au codage modulo 2^{64} . De même, si on demande de calculer $2y = 2(2^{63} - 1) = 2^{64} - 2 \equiv -2 \pmod{2^{64}}$, cela renverra -2 .

3 Un peu de mathématiques : écriture décimale et binaire d'un rationnel

1. En base 10

On a $5,387 = 5 + 3 \times 10^{-1} + 8 \times 10^{-2} + 7 \times 10^{-3}$.

On appelle nombre décimal, tout nombre réel qui s'écrit avec un nombre fini de chiffres après la virgule, c'est-à-dire de la forme $\frac{a}{10^n}$ avec $a \in \mathbb{Z}$ et $n \in \mathbb{N}$. On note $\mathbb{D}$ l'ensemble des nombres décimaux.

Tout nombre décimal est rationnel, mais la réciproque est fautive puisque $\frac{1}{3} = 0,333\dots$ n'est pas décimal. Un autre argument plus arithmétique est de dire que si $\frac{1}{3} = \frac{a}{10^n}$, alors $3a = 10^n$ et donc 3 divise 10^n , ce qui n'est pas. Pour obtenir la décomposition décimale d'un rationnel, on fait des divisions euclidiennes successives. Exemples : $\frac{43}{5} = 8,6$, mais $\frac{25}{7} = 3,571428\ 571428\ \dots$. On parle de développement décimal illimité mais périodique.

2. En base 2

On a $(1,011)_2 = 1 + \frac{1}{2^2} + \frac{1}{2^3}$.

On appelle nombre dyadique, tout nombre réel qui s'écrit avec un nombre fini de chiffres en base deux après la virgule, c'est-à-dire de la forme $\frac{a}{2^n}$ avec $a \in \mathbb{Z}$ et $n \in \mathbb{N}$. On note $\mathbb{D}_2$ l'ensemble des nombres dyadiques.

Par exemple, $\frac{5}{32} = \frac{1}{32} + \frac{4}{32} = \frac{1}{2^5} + \frac{1}{2^3} = (0,00101)_2$. De même, $6.125 = 6 + \frac{1}{8} = (110,001)_2$.

Cet exemple est important, il montre que l'on ne peut représenter de manière exacte en base deux, un nombre aussi simple que $\frac{1}{5} = 0,2$. En effet, en base 16, $\frac{1}{5} = (0,333\dots)_{16}$ d'où en base deux, $\frac{1}{5} = (0,0011\ 0011\ \dots)_2$.

4 Représentation des nombres flottants

Dans de nombreux domaines, on nécessite de faire des calculs avec des «nombres à virgule» qui ne sont pas forcément entiers (des prix, des masses, des volumes, certaines constantes physiques comme le nombre D'Avogadro, la constante de Boltzmann). On représente ces nombres par un type informatique, appelé «nombre flottant».

```
>>> type(2.5)
<class 'float'>
```

4.1 Principe de codage des flottants à l'aide de l'écriture scientifique binaire

Nous allons pouvoir représenter des «nombres à virgule» écrits en base deux, sous forme «scientifique». Nous les appellerons des nombres flottants :

$$x = \pm 1.m \times 2^e$$

où m est un mot binaire appelé **mantisse** et e un mot binaire représentant un entier relatif, appelé **exposant**. Le zéro sera codé à part.

Par exemple, l'«écriture scientifique binaire» du nombre $x = 21,5$ est $(1.01011)_2 \times 2^4$, car :

$$21.5 = (16 + 4 + 1) + \frac{1}{2} = (10101)_2 + (0.1)_2 = (10101.1)_2 = (1.01011)_2 \times 2^4 = (1.01011)_2 \times 2^{(100)_2}.$$

Ici la mantisse est 01011 codée sur 5 bits, et l'exposant est 100 codé sur 3 bits.

Supposons maintenant que la mantisse soit codée sur 2 bits, que l'exposant minimal vaut -1 et l'exposant maximal 2 (ainsi il y a 4 valeurs d'exposants possibles, donc l'exposant est codé aussi avec 2 bits). On réserve aussi 1 bit pour le signe. On a ainsi $\underbrace{|s|}_{1 \text{ bit}} \underbrace{|e|}_{2 \text{ bits}} \underbrace{|m|}_{2 \text{ bits}}$. Avec 5

bits, nous pouvons coder 2^5 nombres flottants. Voici la liste des 16 positifs :

$(1.00)_2 \times 2^{-1} = 0.5$	$(1.10)_2 \times 2^{-1} = 1/2 + 1/4$
$(1.00)_2 \times 2^0 = 1$	$(1.10)_2 \times 2^0 = 1 + 1/2$
$(1.00)_2 \times 2^1 = 2$	$(1.10)_2 \times 2^1 = 3$
$(1.00)_2 \times 2^2 = 4$	$(1.10)_2 \times 2^2 = 6$
$(1.01)_2 \times 2^{-1} = 1/2 + 1/8$	$(1.11)_2 \times 2^{-1} = 1/2 + 1/4 + 1/8$
$(1.01)_2 \times 2^0 = 1 + 1/4$	$(1.11)_2 \times 2^0 = 1 + 3/4$
$(1.01)_2 \times 2^1 = 2 + 1/2$	$(1.11)_2 \times 2^1 = 3 + 1/2$
$(1.01)_2 \times 2^2 = 5$	$(1.11)_2 \times 2^2 = 7$


Le plus grand flottant 7 est obtenu avec une mantisse maximale et un exposant maximal. Le plus petit flottant positif 0,5 est obtenue avec la mantisse nulle et l'exposant le plus petit ici (-1).

La mantisse étant constituée de 2 bits, on dit que l'on a une précision avec 2 chiffres binaires significatifs.

Si on place ces flottants sur une droite graduée, on remarque qu'ils ne sont pas uniformément répartis sur $[0.5; 7]$, ils sont plus concentrés autour de 0,5.

Voici un graphique où l'on a représenté les nombres flottants que l'on peut coder avec 8 bits.

5. Quel est le plus petit nombre flottant strictement supérieur à 1 ? Il s'agit de $1 + 2^{-52}$. Son développement binaire est $1.\underbrace{00 \dots 001}_{52 \text{ bits}}$. Sa représentation flottante est donc obtenue avec un exposant nul $e = 0$ donc $E = 1023$.



Remarque : le nombre 2^{-52} est appelé «l'epsilon» de la machine. Comme $2^{-52} \approx 2.22 \times 10^{-16}$, cela signifie que lorsqu'on calcule avec des nombres flottants, on ne pourra jamais avoir une précision supérieure à 15 ou 16 chiffres significatifs en base 10 ! Ceci est confirmé par Python :

```
>>> 1+10** -15
1.0000000000000001
```

```
>>> 1+10**-16
1.0
```

4.3 Observations et explications

L'«arithmétique flottante» et la propagation des erreurs d'arrondi est une problématique vraiment délicate. Nous pouvons néanmoins retenir ces quelques points :

- ## 1. Phénomène d'absorption

```
>>> 1.0 + (2**53 - 2**53)
1.0 # ok
>>> (1.0 + 2**53) - 2**53
0.0 #oops,
>>> 1.0+2**53 == 2**53
True # phénomène d'absorption, la petite quantité 1.0 a été absorbée par la grande
>>> (1+ 2**53) - 2**53
1 # et ici ça marche car on ne travaille pas avec des flottants, mais avec des entiers
```

Explication : la mantisse représente le nombre de chiffres binaires significatifs, donc 52. Par exemple, le nombre $1 + 2^{-53} = (1.0000...01)_2$ nécessiterait une mantisse de 53 bits.

Or on ne dispose que de 52 bits, on va donc perdre le dernier bit égal à 1 et représenter $1 + 2^{-53}$ par $(1.\underbrace{0000\dots 0}_{52 \text{ bits}})_2$, donc par 1.

Le nombre 2^{-53} lui est bien représentable car $2^{-53} = 1.0 \times 2^{-53}$, donc s'écrit avec une mantisse nulle et un exposant $e = -53$ donc $E = 1023 - 53$.

Recommandation : ne pas additionner de nombres dont l'écart relatif est très grand. Dans une somme de plusieurs termes, on commencera par additionner les petites quantités.

Remarque mathématique : l'addition des nombres flottants n'est donc pas associative.

2. Des erreurs d'arrondi

On a déjà vu que le nombre 0.1 n'était pas dyadique, il a un nombre infini de chiffres binaires après la virgule, on va tronquer son développement binaire et le représenter par un flottant qui ne sera pas tout à fait égal à 0.1. Ceci explique que $(0.2 + 0.1) - 0.3$ ne soit pas tout à fait égal à 0.

```
>>> (0.1+0.2) - 0.3 == 0
False
```

Par exemple, on a vu que $\frac{1}{5} = 1.(1001\ 1001\ 1001\ \dots)_2 \times 2^{-3}$ donc $\frac{1}{5}$ sera arrondi à la valeur $\frac{1}{5} = 1.(1001\ 1001\ 1001\ \dots)_2 \times 2^{-3}$.

Recommandation : **ne jamais tester l'égalité entre deux nombres flottants**, mais tester si leur distance est inférieure à un nombre très petit.

3. Phénomène de «cancellation»

Recommandation : ne pas soustraire des quantités voisines sous peine de perdre beaucoup de précision.

Voici un exemple pour comprendre, on prend $x = (1.\underbrace{000\dots\mathbf{11011}}_{52\ bits})_2$ et $y = (1.\underbrace{000\dots\mathbf{00110}}_{52\ bits})_2$.

Les nombres x et y sont très proches, ils ne diffèrent que par leurs 5 dernières «décimales».

On a $x - y = (0.\underbrace{000\dots\mathbf{010101}}_{52\ bits})_2 = (1.0101)_2 \times 2^{-48}$. Au lieu des 54 chiffres significatifs

après la virgule, on n'en a plus que 4. Ce problème peut se rencontrer si l'on calcule par exemple $\frac{1}{x} - \frac{1}{x+1}$. Dans ce cas, il sera préférable de plutôt calculer $\frac{1}{x(x+1)}$.