CODAGE DE L'INFORMATION
NOMBRES ET CARACTÈRES

ISO-8859-1																
	x0	x1	x2	x3	x4	x5	x6	x7	x8	x9	xA	xB	xC	xD	xE	xF
0x	NUL	SOH	STX	ETX	EOT	ENQ	ACK	BEL	BS	HT	LF	VT	FF	CR	SO	SI
1x	DLE	DC1	DC2	DC3	DC4	NAK	SYN	ETB	CAN	EM	SUB	ESC	FS	GS	RS	US
2x	SP	!	"	#	$	%	&	'	(	)	*	+	,	-	.	/
3x	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4x	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5x	P	Q	R	S	T	U	V	W	X	Y	Z	[	\	]	^	_
6x	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7x	p	q	r	s	t	u	v	w	x	y	z	{	|	}	~	DEL
8x	PAD	HOP	BPH	NBH	IND	NEL	SSA	ESA	HTS	HTJ	VTS	PLD	PLU	RI	SS2	SS3
9x	DCS	PU1	PU2	STS	CCH	MW	SPA	EPA	SOS	SGCI	SCI	CSI	ST	OSC	PM	APC
Ax	NBSP	¡	¢	£	¤	¥	¦	§	¨	©	ª	«	¬	-	®	¯
Bx	°	±	²	³	´	µ	¶	·	¸	¹	º	»	¼	½	¾	¿
Cx	À	Á	Â	Ã	Ä	Å	Æ	Ç	È	É	Ê	Ë	Ì	Í	Î	Ï
Dx	Ð	Ñ	Ò	Ó	Ô	Õ	Ö	×	Ø	Ù	Ú	Û	Ü	Ý	Þ	ß
Ex	à	á	â	ã	ä	å	æ	ç	è	é	ê	ë	ì	í	î	ï
Fx	ð	ñ	ò	ó	ô	õ	ö	÷	ø	ù	ú	û	ü	ý	þ	ÿ

Objectifs

A la fin de la séquence d'enseignement les élèves doivent :

- décrire le principe de la représentation des nombres entiers en mémoire.
- décrire le principe de la représentation des nombres réels en mémoire.
- citer et prévenir les conséquences de la représentation limitée des nombres réels en machine

Table des matières

1 Problématique

OBJECTIF : coder les nombres et les caractères à l'aide de codes binaires.

En effet, un ordinateur traite de l'information sous forme numérique binaire. L'information se caractérise par son contenu (ce qu'elle représente), sa forme (la manière de la formuler), son support (le moyen de la véhiculer).

Le contenu peut concerner des grandeurs numériques (code postal, entier relatif, pixels, etc.), mais aussi des grandeurs analogiques (son, vitesse de rotation, etc.).

On s'intéresse ici à la forme des informations à traiter et à la notion de **codage des nombres et des caractères**.

Un code constitue une correspondance entre des symboles et des objets à désigner.

Un code binaire est une correspondance arbitraire entre un ensemble de **symboles** (0 et 1) et un ensemble d'**objets** (chiffres, lettres, couleurs, etc.).

ATTENTION ! norme CEI de 2004 (IEEE 1541) :

On appelle :

- **bit (b) :** binary digit, unité d'information pouvant prendre la valeur 0 ou la valeur 1
- **octet (o) :** un mot binaire de 8 bits.
- **byte (B) :** terme anglo-saxon équivalent à octet

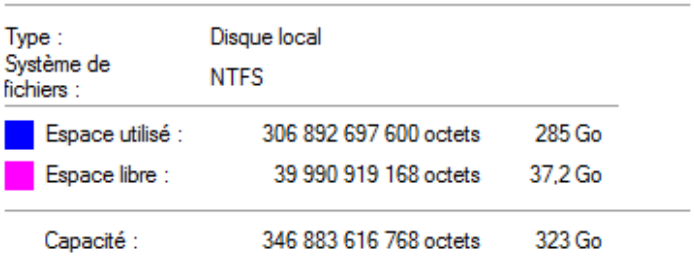

Préfixes binaires (préfixes CEI)		
Nom	Symb.	Puissance de 2
Kibi	Ki	2^{10} = 1 024
Mébi	Mi	2^{20} = 1 048 576
Gibi	Gi	2^{30} = 1 073 741 824
Tébi	Ti	2^{40} = 1 099 511 627 776
Pébi	Pi	2^{50} = 1 125 899 906 842 624

Préfixes décimaux (préfixes SI)			
Nom	Symb.	Puissance de 10	Err.
Kilo	k	10^3 = 1 000	2 %
Méga	M	10^6 = 1 000 000	5 %
Giga	G	10^9 = 1 000 000 000	7 %
Téra	T	10^{12} = 1 000 000 000 000	10 %
Péta	P	10^{15} = 1 000 000 000 000 000	13 %

REMARQUE:

dans ce deuxième tableau, l'erreur indiquée dans la colonne de droite est celle effectuée quand on utilise un préfixe SI à la place d'un préfixe binaire. L'usage de cette norme ne s'est pas encore généralisé.

Microsoft Windows continue à utiliser à tort les préfixes SI : par exemple 1 ko = 1024 o au lieu de 1000 o. D'autres, comme les systèmes d'exploitation libres de type GNU/Linux, adoptent les préfixes binaires.

2 Système de numération

2.1 Base de la numération

2.1.1 Définition

Une base $B_N = \{C_i\}_{i=1}^{N}$ est un système libre de N éléments (chiffres ou caractères) tel que:

$$\forall a \in \mathbb{N}, \exists m \in \mathbb{N} / a = \sum_{j=0}^{m} C_j.N^j \quad \text{avec } C_j \in \{C_i\}_{i=1}^{N}$$

$$\forall a \in \mathbb{R}^+, \exists \{C_j\}_{j=-\infty}^{\infty} / a = \sum_{j=-\infty}^{+\infty} C_j.N^j \quad \text{avec } C_j \in \{C_i\}_{i=1}^{N}$$

2.1.2 Bases de numération usuelles

Les 3 bases les plus utilisées dans les systèmes industriels sont :

- Base décimale :

  $B_{10} = \{0, 1, 2, 3, 4, 5, 6, 7, 8, 9\}$

- Base binaire :

  $B_2 = \{0, 1\}$

  Les chiffres sont alors appelés bit, pour binary digit

- Base hexadécimale :

  $B_{16} = \{0, 1, 2, 3, 4, 5, 6, 7, 8, 9, A, B, C, D, E, F\}$

Base décimale B_{10}	Base binaire B_2	Base hexadécimale B_{16}
0	**0**	**0**
1	**1**	**1**
2	**10**	**2**
3	**11**	**3**
4	**100**	**4**
5	**101**	**5**
6	**110**	**6**
7	**111**	**7**
8	**1000**	**8**
9	**1001**	**9**
10	**1010**	**A**
11	**1011**	**B**
12	**1100**	**C**
13	**1101**	**D**
14	**1110**	**E**
15	**1111**	**F**

2.1.3 Exemples

Décomposons $(2018)_{10}$ en base 10, 2 et 16:

Base 10	$(2020)_{10}$	$2.10^3 + 0.10^2 + 2.10^1 + 0.10^0$
Base 2	$(11111100100)_2$	$1.2^{10} + 1.2^9 + 1.2^8 + 1.2^7 + 1.2^6 + 1.2^5 + 0.2^4 + 0.2^3 + 1.2^2 + 0.2^1 + 0.2^0$
Base Hex	$(7E4)_{16}$	$7.16^2 + 14.16^1 + 4.16^0$

REMARQUE: Pour différencier les bases, on reporte le numéro de la base en indice : $(2020)_{10}$

2.2 Changement de bases

2.2.1 Passage d'une base B_N à la base décimale B_{10}

En base B_N, chaque chiffre est affecté d'un poids (N^n) avec n le nombre de chiffres à sa droite dans le nombre complet. Pour obtenir le nombre en base 10, il suffit de faire la somme des chiffres du nombre en base N multipliés, par leur poids.

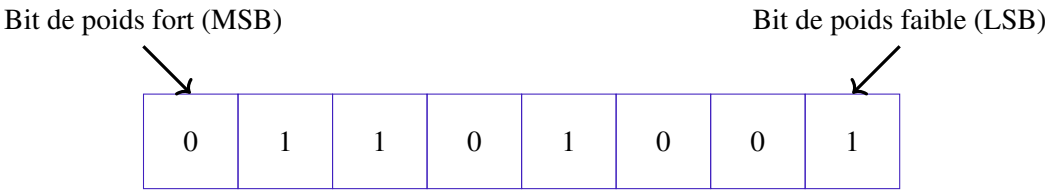

Poids respectifs $\longrightarrow 0\times2^7+1\times2^6+1\times2^5+0\times2^4+1\times2^3+0\times2^2+0\times2^1+1\times2^0 = 105$

2.2.2 Passage de la base décimale B_{10} à une base B_N

La passage de la base décimale B_{10} à une base B_N se fait en recherchant la puissance de N immédiatement inférieure au nombre décimal à convertir, puis la puissance de N immédiatement inférieure au reste, et ainsi de suite jusqu'à un reste nul.

$$a = \sum_{j=0}^{m} a_j.N^j \quad \text{En factorisant par } N\text{, on obtient :} \quad a = N.\left(\sum_{j=0}^{m-1} a_{j+1}.N^j\right) + a_0$$

Le reste de la division de a par N est égale au coefficient a_0. Par division successive par N, on obtient les autres cœfficients associés aux puissances de B_N:

$$a = N.\left(N.\left(\sum_{j=0}^{m-2} a_{j+2}.N^j\right) + a_1\right) + a_0$$

EXEMPLE : $(105)_{10} \Leftrightarrow (?)_2$

$$\begin{aligned} 105 &= 52 \times 2 + \\ 52 &= 26 \times 2 + \\ 26 &= 13 \times 2 + \\ 13 &= 6 \times 2 + \\ 6 &= 3 \times 2 + \\ 3 &= 1 \times 2 + \\ 1 &= 0 \times 2 + \end{aligned}$$

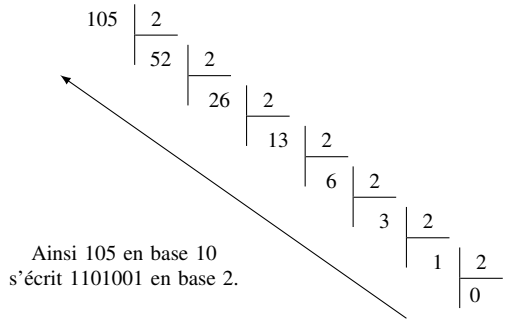

Algorithm 1 Passage de la base décimale à la base 2

donnée: n : un nombre entier positif exprimé en base 10
résultat: r : une chaîne de caractères représentant le code binaire naturel du nombre n

```
r ← "" initialisation
tant que n ≠ 0 faire
    si n modulo 2 == 0 alors
        r = "0" + r
    sinon
        r = "1" + r
    fin si
    n = n//2
fin tant que
renvoi: r
```

2.2.3 Passage de la base 2^p à la base 2^q

Pour le passage de la base 2^p à la base 2^q, le plus simple est de repasser par la base 2, pour convertir chaque chiffre en son équivalent binaire. Ainsi chaque chiffre de la base 2^p se code en p chiffres de la base binaire (p bits). En convertissant le nombre binaire par paquet de q chiffres (bits), nous obtenons les chiffres du nombre en base q.

EXEMPLE : $(247)_8 \Leftrightarrow (?)_4$
La base 8 se code sur 3 bits ($8 = 2^3$), et la base 4 se code sur 2 bit ($4 = 2^2$)

$$\begin{aligned} (A)_8 &= 247 \\ (A)_8 &= \underbrace{2}_{010}\ \underbrace{4}_{100}\ \underbrace{7}_{111} \\ (A)_2 &= 10100111 \\ (A)_2 &= \underbrace{10}_{2}\ \underbrace{10}_{2}\ \underbrace{01}_{1}\ \underbrace{11}_{3} \\ (A)_4 &= 2213 \end{aligned}$$

3 Le codage des nombres

3.1 Les nombres entiers naturels

DÉFINITION: Codage à champ fixe

> *Codage sur un nombre de bits n constant (exemple n=8 pour l'octet). La position occupée par le bits (en partant de 0 et de droite) correspond à son poids en puissance de 2.*

Il est alors possible de représenter un entier naturel N tel que $0 \leq N \leq 2^n - 1$.

Un entier naturel codé sur un octet est forcément compris entre 0 et 255. Lorsqu'il est codé sur 32 bits, alors il est compris entre 0 et 4294967295.

L'Unité Arithmétique Logique (UAL) du processeur est capable de traiter des mots binaires de 32 bits (ou 64 bits).

A la suite d'opérations arithmétiques, des dépassements de capacité (**overflow**) sont possibles. Ils sont en général évités pour les entiers naturels en découpant si nécessaire le mot binaire en plusieurs de taille acceptable par le processeur, le nombre est recomposé par la suite.

Les langages de programmation comme Python, peuvent donc traiter des nombres entiers de taille quasiment infinie.

3.2 Les nombres entiers relatifs

3.2.1 Signe et valeur absolue (idée 0)

On sacrifie 1 bit pour représenter le signe : + est représenté par `0` et − par `1`.

On code ainsi avec un mot de n bits les entiers relatifs Z tels que : $-(2^{n-1} - 1) \leq Z \leq 2^{n-1} - 1$.

PROBLÈME:

- on a deux représentations différentes de `0` : 00 . . . 0 et `10`. . . 0 .
- Il est difficile d'effectuer des opérations sur les nombres car le bit de signe doit être traité à part.

3.2.2 Complément logique (ou complément à 1 - idée 1)

Dans le cas du complément logique, les nombres positifs sont simplement représentés par leur écriture en base 2. Pour les nombres négatifs, on remplace chaque bit à 0 par 1 et vice versa.

EXEMPLE : Représentation de `−3` sur 4 bits

`3` est représenté par `0011`. Donc en complément à 1, `−3` sera représenté par `1100`.
Pour retrouver le nombre à partir de sa représentation en complément à 1 :

- si le bit de gauche est `0`, le nombre est positif et on a sa représentation en binaire
- si le bit de gauche est `1`, alors le nombre est négatif et pour trouver sa valeur absolue, on inverse les bits.

On code ainsi avec un mot de n bits les entiers relatifs Z tels que : $-(2^{n-1} - 1) \leq Z \leq 2^{n-1} - 1$.

EXEMPLE : `6−3=3` avec `6=0110` et `3=0011`.

Calcul en décimal	Calcul en binaire
6	0110
Facile, on connaît : - 3	+ ⇒ +
3	

PROBLÈME: `0` est codé de deux façons différentes : `00...0` et `11...1` .

3.2.3 Complément arithmétique (ou complément à 2 - idée 2)

Même méthode que précédemment, sauf qu'il faut encore ajouter 1 au résultat pour la représentation des entiers négatifs. Ainsi :

- traduire la valeur absolue du nombre négatifs en binaire. Ainsi : sur 4 bits `3` → `0011` .
- prendre le complément logique de nombre binaire obtenu : `0011` → `1100` .
- ajouter 1 au nombre complémenté : `1100+0001` → `1101` .
- il est possible alors de faire les opérations.

En décimal	En binaire
6	0110
- 3	+ 1101
3	1 0011

REMARQUE: 0 est codé d'une seule façon : `-0` est représenté par `0000` . En effet, `1111+0001=10000` mais on ne retient que les 4 bits de droite.

Pour retrouver le nombre à partir de sa représentation en complément à 2 :

- si le bit de gauche est `0` , le nombre est positif et on a sa représentation en binaire ;
- si le bit de gauche est `1` , alors le nombre est négatif et pour trouver sa valeur absolue, on inverse les bits et on ajoute 1.

Ainsi avec un mot de n bits, on code les entiers relatifs Z tels que : $-2^{n-1} \leq Z \leq 2^{n-1} - 1$.

REMARQUE: on gagne un nombre négatif par rapport au complément à un.

3.3 Les nombres rationnels

3.3.1 Nombres à virgule et bases

On peut ajouter une partie fractionnaire à un nombre dans sa représentation en base N en ajoutant des puissances négatives de N. Les chiffres obtenus seront ajoutés à la suite et séparés par une virgule.

EXEMPLE : $(63,5)_{(10)}$ est l'écriture en base 10 de $6.10^1 + 3.10^0 + 5.10^{-1}$.

Il n'y a pas forcément de solution exacte dans le codage de la partie fractionnaire d'un nombre décimal et le nombre de puissances négatives dépend des capacités de la machine et de la précision souhaitée.

On code ainsi avec un mot de n bits dont k bits pour la partie fractionnaire, les réels R tels que :

$$-2^{n-1-k} \leq R \leq 2^{n-1-k} - 2^{-k}$$

Le codage en virgule fixe (**fixed point**) sur n bits, ne permet de représenter qu'un intervalle de 2^n valeurs. Pour un grand nombre d'applications, cet intervalle est trop restreint. La représentation à virgule flottante a été introduite pour répondre à ce besoin et améliorer la précision des calculs.

3.3.2 Virgule flottante (floating point)

On peut représenter les nombres sous la forme d'un triplet (s,e,m) : $x = s.m.B^e$, avec B la **base**. Dans ce triplet, s est le signe, e est l'exposant et m est la mantisse. Ce triplet est assemblé dans l'ordre signe, exposant, mantisse pour former un

nombre.

La norme IEEE [1] 754 définit alors le codage, avec $B = 2$ (nombres codés en binaire), d'un nombre en simple précision sur 32 bits et en double précision . sur 64 bits

- le signe $s = \pm 1$ est codé sur 1 bit (MSB le bit de poids le plus fort) : `0` pour positif, `1` pour négatif
- l'exposant e est un entier codé sur 8 bits en simple précision, 11 en double précision. L'exposant peut être positif ou négatif. Cependant, la représentation habituelle des nombres signés (complément à 2) rendrait la comparaison entre les nombres flottants un peu plus difficile. Pour régler ce problème, l'exposant est décalé, afin de le stocker sous forme d'un nombre non signé. Ce décalage de $2^{n_e-1} - 1$ est appelé biais (n_e représente le nombre de bits de l'exposant) ; il s'agit donc d'une valeur constante une fois que le nombre de bits n_e est fixé.
- la mantisse m est un nombre à virgule tel que $m \in [1, 2[$, codé sur 23 bits en simple précision, 52 en double précision. En base binaire, m peut toujours s'écrire $m = 1, \ldots$. Le chiffre 1 n'a pas besoin d'être représenté. Seuls les chiffres après la virgule de la mantisse sont codés en binaire.

IEEE 754 simple précision : sur 32 bits
s : 1 bit ; e : 8 bits ; m : 23 bits

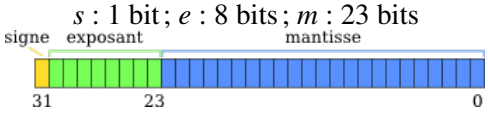

IEEE 754 double précision : sur 64 bits
s : 1 bit ; e : 11 bits ; m : 52 bits

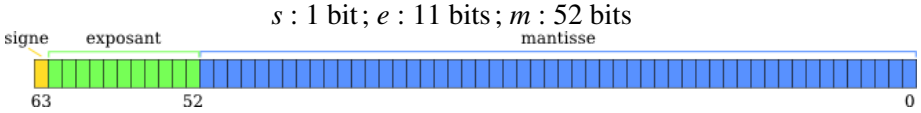

EXEMPLE : : représenter 525,5 au format IEEE 754 simple précision.

- Ecrire 525,5 en base 2 : $(525,5)_{(10)} = (1000001101,1)_{(2)}$
- Trouver l'exposant : $(525,5)_{(10)} = (1,0000011011)_{(2)}.2^9$
- Identifier le triplet (s, e, m) :
  - $s = 0$ car le nombre est positif
  - $e_b = e + \underbrace{2^{n_e-1} - 1}_{biais} = 9 + 2^{8-1} - 1 = (136)_{(10)} = (10001000)_{(2)}$ en base 2 sur 8 bits
  - $m = (00000110110000000000000)_{(2)}$
- Assembler : $(525,5)_{(10)} = (0\ 10001000\ 00000110110000000000000)_{(2)}$

3.3.3 Dépassement de capacité et nombres dénormalisés

En arithmétique à virgule flottante, on peut obtenir un résultat valable, ou alors rencontrer un problème de dépassement par valeur supérieure (overflow) lorsque le résultat est trop grand pour pouvoir être représenté, ou par valeur inférieure (underflow) lorsque le résultat est trop petit.

EXEMPLE : sur 4 bits, que donne 5+4 ?

Certaines représentations sont réservées à la représentation de l'infini ou de codes d'erreurs.

La partie décrit comment coder des nombres avec un exposant biaisé e_b strictement compris entre 0 et Val_Max (255 en simple précision et 2047 en double précision). Ainsi, si $e_b \in \{0, Val\_Max\}$, alors on est dans l'un des cas suivants :

- $e_b = 0, m = 0$: le nombre est ± 0 (représentation dénormalisée)
- $e_b = Val\_Max, m = 0, s = \pm 1$: c'est la représentation de $\pm\infty$

1. Institute of Electrical and Electronics Engineers

- $e_b = Val\_Max$, $m \neq 0$: NaN (Not a Number), réservé aux codes d'erreurs (par exemple résultat d'une division par 0)
- $e_b = 0$, $m \neq 0$: on dit que la représentation est **dénormalisée** ; dans ce cas, le nombre codé est $x = \pm 0{,}m.B^{(biais-1)}$.

Cette situation arrive lorsqu'un résultat est trop petit pour pouvoir être représenté. Le standard IEEE 754 résout partiellement le problème en autorisant dans ce cas une représentation dénormalisée.

Une représentation dénormalisée est caractérisée par le fait d'avoir un code d'exposant complètement nul, ce qui est interprété comme une indication du fait que le bit de poids fort de la mantisse, implicite, est cette fois à 0 au lieu d'être à 1. De cette façon, le plus petit nombre "exprimable" en simple précision est : $2^{-23} \times 2^{2^{8-1}-1} = 2^{-23-127} = 2^{-150} \approx 10^{-45}$.

Cependant, il faut remarquer que plus le nombre représenté est petit, moins sa mantisse comportera de bits significatifs.

La norme IEEE spécifie quatre modes d'arrondi : vers $+\infty$, vers $-\infty$, vers 0 et au plus près (si le nombre est entre deux, il est arrondi à la valeur la plus proche avec un bit de poids faible à 0 (mode d'arrondi par défaut).

3.3.4 Résumé

3.3.4.1 En simple précision

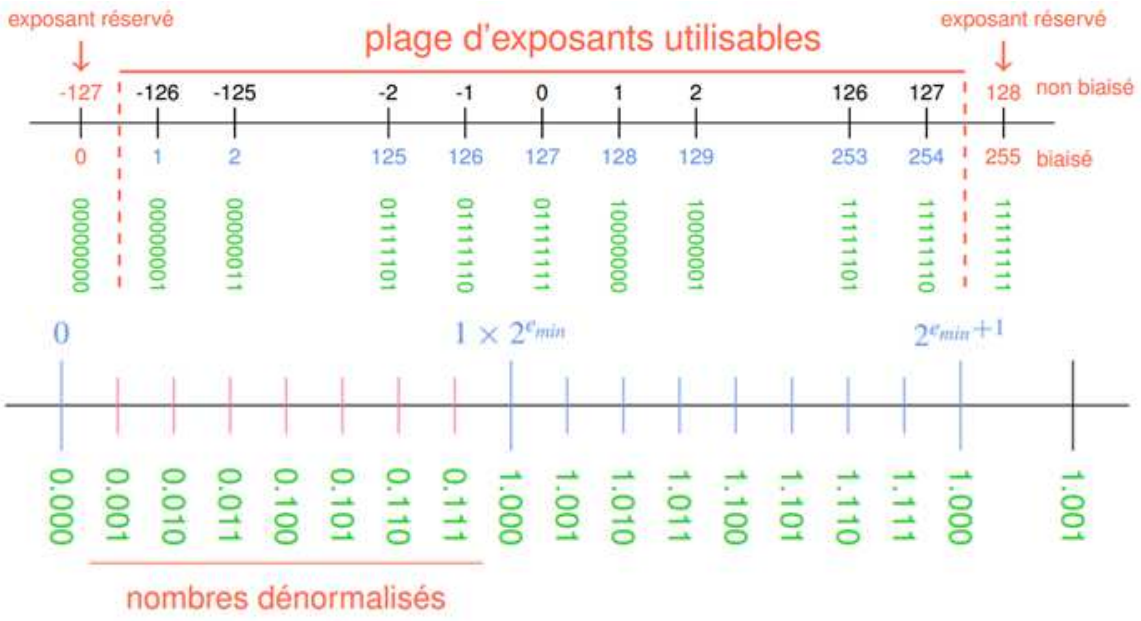

3.3.4.2 Tableau récapitulatif

	IEEE 754 simple précision	IEEE 754 double précision
Exposant	-126 à 127	-1022 à 1023
Mantisse	1 à presque 2 ($2 - 2^{-23}$)	1 à presque 2 ($2 - 2^{-52}$)
Plus petit nombre normalisé	2^{-126}	2^{-1022}
Plus grand nombre normalisé	Presque 2^{128}	Presque 2^{1024}
Plus petit nombre dénormalisé	2^{-149} ($0,000\ldots1 \times 2^{-126}$)	2^{-1074} ($0,000\ldots1 \times 2^{-1022}$)
Intervalle utile	Approximativement 10^{-38} à 10^{38}	Approximativement 10^{-308} à 10^{308}

4 Les caractères

4.1 Les caractères alphanumériques

Le nombre de caractères à coder est grands. On estime qu'actuellement, il y a plus de 245000 caractères assignés, 93 écritures différentes.

Les caractères alphanumériques comprennent les caractères alphabétiques (de A à Z en alphabet latin), ainsi que les caractères numériques comprenant les chiffres 0 à 9 mais aussi les signes − ou +.

Il y a aussi bien d'autres caractères : ponctuation, touches clavier (espace, entrée, ...), ...

4.2 Le code ASCII

Le code ASCII (American Standard Code for Information Interchange) a été standardisé en 1963.

Il utilise un octet pour encoder 128 caractères : 33 caractères de contrôle, 94 caractères imprimables (lettres, chiffres, ...), l'espace. Le $8^{\text{ème}}$ bit reste à 0.

Beaucoup de pages de codes étendent l'ASCII en utilisant le $8^{\text{ème}}$ bit pour définir des caractères numérotés de 128 à 255. La norme ISO/CEI 8859 fournit des extensions pour diverses langues.

Par exemple, l'ISO 8859-1, aussi appelée Latin-1, étend l'ASCII avec les caractères accentués utiles aux langues originaires d'Europe occidentale comme le français ou l'allemand. C'est le cas de ce cours, codé Latin-1.

Hex	Dec	Char		Hex	Dec	Char	Hex	Dec	Char	Hex	Dec	Char
0x00	0	NULL	null	0x20	32	Space	0x40	64	@	0x60	96	`
0x01	1	SOH	Start of heading	0x21	33	!	0x41	65	A	0x61	97	a
0x02	2	STX	Start of text	0x22	34	"	0x42	66	B	0x62	98	b
0x03	3	ETX	End of text	0x23	35	#	0x43	67	C	0x63	99	c
0x04	4	EOT	End of transmission	0x24	36	$	0x44	68	D	0x64	100	d
0x05	5	ENQ	Enquiry	0x25	37	%	0x45	69	E	0x65	101	e
0x06	6	ACK	Acknowledge	0x26	38	&	0x46	70	F	0x66	102	f
0x07	7	BELL	Bell	0x27	39	'	0x47	71	G	0x67	103	g
0x08	8	BS	Backspace	0x28	40	(	0x48	72	H	0x68	104	h
0x09	9	TAB	Horizontal tab	0x29	41	)	0x49	73	I	0x69	105	i
0x0A	10	LF	New line	0x2A	42	*	0x4A	74	J	0x6A	106	j
0x0B	11	VT	Vertical tab	0x2B	43	+	0x4B	75	K	0x6B	107	k
0x0C	12	FF	Form Feed	0x2C	44	,	0x4C	76	L	0x6C	108	l
0x0D	13	CR	Carriage return	0x2D	45	-	0x4D	77	M	0x6D	109	m
0x0E	14	SO	Shift out	0x2E	46	.	0x4E	78	N	0x6E	110	n
0x0F	15	SI	Shift in	0x2F	47	/	0x4F	79	O	0x6F	111	o
0x10	16	DLE	Data link escape	0x30	48	0	0x50	80	P	0x70	112	p
0x11	17	DC1	Device control 1	0x31	49	1	0x51	81	Q	0x71	113	q
0x12	18	DC2	Device control 2	0x32	50	2	0x52	82	R	0x72	114	r
0x13	19	DC3	Device control 3	0x33	51	3	0x53	83	S	0x73	115	s
0x14	20	DC4	Device control 4	0x34	52	4	0x54	84	T	0x74	116	t
0x15	21	NAK	Negative ack	0x35	53	5	0x55	85	U	0x75	117	u
0x16	22	SYN	Synchronous idle	0x36	54	6	0x56	86	V	0x76	118	v
0x17	23	ETB	End transmission block	0x37	55	7	0x57	87	W	0x77	119	w
0x18	24	CAN	Cancel	0x38	56	8	0x58	88	X	0x78	120	x
0x19	25	EM	End of medium	0x39	57	9	0x59	89	Y	0x79	121	y
0x1A	26	SUB	Substitute	0x3A	58	:	0x5A	90	Z	0x7A	122	z
0x1B	27	FSC	Escape	0x3B	59	;	0x5B	91	[	0x7B	123	{
0x1C	28	FS	File separator	0x3C	60	<	0x5C	92	\	0x7C	124	|
0x1D	29	GS	Group separator	0x3D	61	=	0x5D	93	]	0x7D	125	}
0x1E	30	RS	Record separator	0x3E	62	>	0x5E	94	^	0x7E	126	~
0x1F	31	US	Unit separator	0x3F	63	?	0x5F	95	_	0x7F	127	DEL

Le code ASCII ne permet d'encoder que l'alphabet latin, sans accents.

4.3 L'Unicode

La première norme date de 1991, la dernière (6.1) de 2012.

Unicode (Universal Character Set Transformation Format) code les caractères sous forme de séquences de 1 à 4 **codets** d'un octet chacun. La norme Unicode définit entre autres un ensemble (ou répertoire) de caractères. Chaque caractère est repéré dans cet ensemble par un index entier aussi appelé **point de code**. Par exemple le caractère €(euro) est le $8365^{\text{ème}}$ caractère du répertoire Unicode, son index, ou point de code, est donc 8364 (on commence à compter à partir de 0).

Le répertoire Unicode peut contenir plus d'un million de caractères, ce qui est bien trop grand pour être codé par un seul octet. La norme Unicode définit donc des méthodes standardisées pour coder et stocker cet index sous forme de séquence d'octets : UTF-8 est l'une d'entre elles, avec UTF-16, UTF-32 et leurs différentes variantes.

La principale caractéristique d'UTF-8 est qu'elle est rétro-compatible avec la norme ASCII, c'est-à-dire que tout caractère ASCII se code en UTF-8 sous forme d'un unique octet, identique au code ASCII. Par exemple *A* (A majuscule) a pour code ASCII 65 et se code en UTF-8 par l'octet 65. Chaque caractère dont le point de code est supérieur à 127 (caractère non ASCII) se code sur 2 à 4 octets. Le caractère € (euro) se code par exemple sur 3 octets : 226, 130, et 172.

Type	Caractère	Point de code (Hex)	Valeur scalaire		Codage UTF-8	
			Base 10	binaire	binaire	Base 16
Contrôles	[NUL]	U+0000	0	*0000000*	**0***0000000*	00
	[US]	U+001F	0	*00*11111	**0***00*11111	1F
Texte	[SP]	U+0020	32	*0*100000	**0***0*100000	20
	A	U+0041	65	1000001	**0**1000001	41
	~	U+007E	126	1111110	**0**1111110	7E
Contrôles	[DEL]	U+007F	127	1111111	**0**1111111	7F
	[PAD]	U+0080	128	*000*10 000000	**110***000*10 **10**000000	C2 80
	[APC]	U+009F	159	*000*10 011111	**110***000*10 **10**011111	C2 9F
Texte	[NBSP]	U+00A0	160	*000*10 100000	**110***000*10 **10**100000	C2 A0
	é	U+00E9	233	*000*10 101001	**110***000*10 **10**101001	C3 A9
	??	U+07FF	2047	11111 111111	**110**11111 **10**111111	DF BF
	?!	U+0800	2048	*0000* 100000 000000	**1110***0000* **10**100000 **10**000000	E0 A0 80
	€	U+20AC	8364	*00*10 000010 101100	**1110***00*10 **10**000010 **10**101100	E2 82 AC
	▒	U+D7FF	55295	1101 011111 111111	**1110**1101 **10**111111 **10**111111	ED 9F BF

Plus d'information sur le codage d'un caractère à l'adresse suivante, en remplaçant xxxx par le code U-xxxx :

http://www.fileformat.info/info/unicode/char/xxxx/index.htm

On y trouve également les commandes ou raccourcis pour obtenir les caractères dans différents environnement :

- Microsoft *Windows*® : Alt+xxxx
- **Python** : u"\ uxxxx