

Université Paris 7 - Denis Diderot

Licence Sciences et Applications

**Mentions : Mathématiques, Informatique
et MASS**

**IF1 - Introduction à l'informatique et la
programmation**

2006-2007

Amphi - 2-ème partie

Jean-Marie Rifflet

Systèmes de numération : quelques dates :

- **5000 av. J.-C. : système de numération parlé sexagésimal (base 60) des Sumériens**
- **3200 av. J.-C. : chiffres sumériens**
- **3000 av. J.-C. : numération hiéroglyphique égyptienne. Système additionnel**
- **1900-1600 av. J.-C. : premier système de numération positionnel des babyloniens (base 60, pas de zéro)**
- **fin du XIV^e siècle av. J.-C. : apparition des chiffres chinois**

- **III^e siècle av. J.-C. :**

- ◇ **invention du zéro par les Babyloniens (pas vu comme un nombre, mais comme absence d'une certaine unité)**
- ◇ **apparition des chiffres brahmi (indiens), précurseurs de nos chiffres (dits arabes) (il existait par ailleurs des symboles pour 10, 20, . . . , 100, 200, . . .**

1	2	3	4	5	6	7	8	9
—	=	≡	+	h	୩	୭	୮	୯
Brahmi numerals around 1st century A.D.								

- **IV^e siècle de notre ère : naissance de la numération décimale indienne de position (ajout aux 9 chiffres d'un signe en forme de petit cercle comme chiffre zéro)**
- **458 : apparition "officielle" du nombre zéro en Inde**

- fin du VIII^e siècle : numération décimale positionnelle et zéro dans la culture islamique dans la partie occidentale

0	1	2	3	٤	٥	6	7	٨	9
0	1	2	3	4	5	6	7	8	9

ou en Égypte et actuellement

•	1	2	3	4	0	6	7	8	9
0	1	2	3	4	5	6	7	8	9

- IX^e siècle : introduction du zéro en Europe

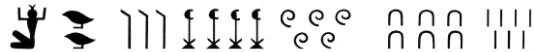
- X^e siècle : introduction des chiffres arabes en Europe
- ◇ XII^e au XV^e siècle : stabilisation des chiffres arabes
- 1489-1650 : introduction de symboles tels que +, -, =, <, >, x et de la notation à virgule
- 1700 : promotion du systeme binaire par Leibniz : base 2 dans laquelle le chiffre **1** représente Dieu et le chiffre **0** le vide
- 1795 : adoption du systeme métrique en France

Systèmes de numération additionnels :

- système égyptien: une valeur est attribuée à un pictogramme et on obtient une valeur en sommant les valeurs des pictogrammes. Ainsi à partir de



on obtient la représentation suivante de 1234567 :



- système romain :

système romain	I	V	X	L	C	D	M
valeur décimal	1	5	10	50	100	500	1000

- Un certain nombre de règles sont utilisées pour l'écriture des nombres:
- ◇ lorsqu'un symbole est placé à la droite d'un symbole plus fort que lui, sa valeur s'ajoute
CCLXXI correspond à 271

- ◇ on ne place jamais 4 symboles identiques à la suite.
9 s'écrit IX et non VIII
- ◇ lorsqu'un symbole est placé à la gauche d'un symbole plus fort que lui on retranche sa valeur.
CCXLIII correspond à 243
- Le plus grand nombre exprimable est MMMCMXCIX, c'est-à-dire 3999
- Système particulièrement inadapté au calcul : calculer par exemple CCXLVII + CDLXXVIII sans passer par l'écriture décimale.

Systèmes de numération positionnels :

Le principe est d'attribuer à un chiffre d'une suite, un poids en fonction de la position qu'il occupe dans la suite. Si on utilise n chiffres (on parle de la base n), un chiffre c dans une suite "a comme valeur" c^i si sa position est i dans la suite représentant le nombre et la valeur représentée est la somme des valeurs associées aux différents chiffres en fonction de leur poids.

Dans la base b , $c_n c_{n-1} \dots c_1 c_0$ représente

$$\sum_{i=0}^n c_i \times b^i$$

En base 10 classique: dans le nombre 35089,

- ◇ 3 a comme poids 4 (d'où la valeur 30000 associée)
- ◇ 5 est de poids 3 (5000),
- ◇ 0 est de poids 2 (0),
- ◇ 8 est de poids 1 (80),
- ◇ 9 est de poids 0 (9 puisque $10^0 = 1$)

Donc le nombre représenté est: $30000 + 5000 + 80 + 9$.

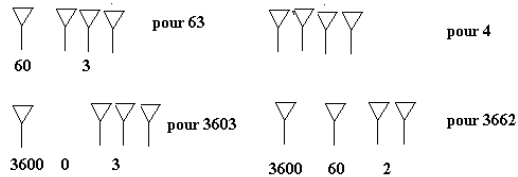
Il en est ainsi pour toutes les bases

Remarques

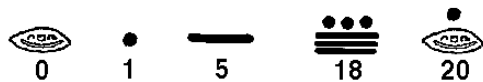
Dans toute base b

- le nombre b s'écrit 10
- un nombre divisible par b^n se termine par n chiffres 0

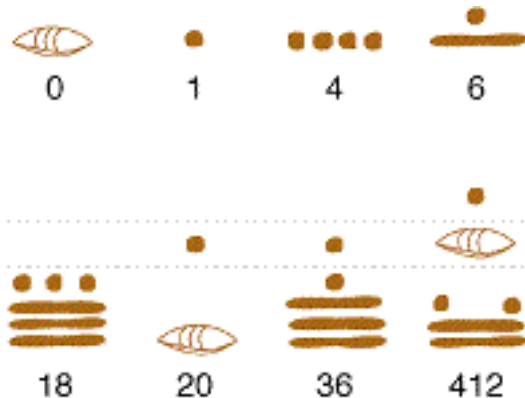
- **système sexagésimal des Babyloniens (base 60)**



- **système des mayas en base 20 (système vicédécimal) au moyen de trois symboles (représentant une unité, cinq unités et le zéro):**



d'où la représentation de quelques nombres:



Les informations dans les machines

On distingue deux types de calculateurs:

- **analogiques**: les données manipulées sont représentées par des phénomènes physiques (intensité, tension) proportionnelles aux données. Les circuits composant le calculateur sont tels que la valeur physique de sortie représente le résultat de l'opération réalisée sur les valeurs associées aux entrées. On travaille donc ici sur des domaines continus

Par exemple, la dynamo d'une bicyclette fournit plus ou moins de courant aux lampes selon qu'on pédale vite ou pas (le même phénomène s'observe avec les éoliennes).

- **digitaux ou numériques** : ils manipulent essentiellement des nombres.

Les mécanismes électriques, magnétiques ou électroniques les composant possèdent deux états stables (typiquement deux tensions +5V et 0), représentés conventionnellement soit par **0**, soit par **1** (ou **Vrai/Faux**).

Il est donc nécessaire de discrétiser/numériser les phénomènes ou grandeurs considérés. Une donnée manipulée par une telle machine sera donc représentée par une certaine combinaison de composants binaires. Par suite, une telle représentation d'une grandeur ne se fera qu'avec une précision finie.

Structures élémentaires

- le **bit** (*binary digit*) : élément d'information binaire
- l'**octet** (*byte*) : un groupe constitué (généralement) de 8 bits
- le **mot** (*word*) : ensemble d'octets regroupés logiquement (mots de 2, 4, 8 ou 16 octets).

La **mémoire centrale** d'un ordinateur contient donc un ensemble de bits (on peut généralement **adresser** des octets ou des mots) Une même séquence de bits peut évidemment être interprétée (selon le contexte et sa longueur) de différentes manières:

- une instruction
- un caractère
- un nombre entier
- un nombre réel (ou plutôt décimal)
- une donnée codant du son, de l'image, de la vidéo

Le codage des caractères

- Le **code ASCII** (*American Standard Code for Information Interchange*): standard adopté en 1960 comme codage des caractères sur un octet (7 bits utilisés)

Représentation des caractères sur un octet (ASCII)

32	espaces	56	8	80	P	104	h
33	!	57	9	81	Q	105	i
34	"	58	:	82	R	106	j
35	#	59	;	83	S	107	k
36	\$	60	<	84	T	108	l
37	%	61	=	85	U	109	m
38	&	62	>	86	V	110	n
39	'	63	?	87	W	111	o
40	(64	@	88	X	112	p
41)	65	A	89	Y	113	q
42	*	66	B	90	Z	114	r
43	+	67	C	91		115	s
44	,	68	D	92	\	116	t
45	-	69	E	93]	117	u
46	.	70	F	94	^	118	v
47	/	71	G	95	_	119	w
48	0	72	H	96	-	120	x
49	1	73	I	97	a	121	y
50	2	74	J	98	b	122	z
51	3	75	K	99	c	123	{
52	4	76	L	100	d	124	
53	5	77	M	101	e	125	}
54	6	78	N	102	f	126	~
55	7	79	O	103	g	127	

Différents codes étendus à 8 bits existent tels que le code ASCII étendu ANSI (*American National Standards Institute*):

	0	1	2	3	4	5	6	7	8	9	A	B	C	D	E	F
8	□	□	,	f	~	~	~	†	‡	^	‰	Š	<	œ	□	□
9	□	\	/	“	”	•	-	-	™	š	>	œ	□	□	Ÿ	
A		i	o	£	¥	!	\$	“	”	©	ª	«	¬	-	®	—
B	°	±	²	³	´	µ	¶	·	¸	¹	º	»	¼	½	¾	¿
C	à	á	â	ã	ä	å	æ	ç	è	é	ê	ë	ì	í	î	ï
D	ð	ñ	ò	ó	ô	õ	ö	×	ø	ù	ú	û	ü	ý	þ	ÿ
E	à	á	â	ã	ä	å	æ	ç	è	é	ê	ë	ì	í	î	ï
F	ð	ñ	ò	ó	ô	õ	ö	÷	ø	ù	ú	û	ü	ý	þ	ÿ

Il en existe d'autres pour PC ou pour Mac (tous deux différents)

- Le **code EBCDIC**: développé par IBM pour coder les caractères sur un octet, il n'est pas sorti du monde IBM
- **Unicode**: mis au point en 1991, il code les caractères sur 2 octets (16 bits). Il permet de prendre en compte tous les alphabets existants (arabe, cyrillique, grec, hébreu, latin, . . .) et est compatible avec le code ASCII. Il est indépendant de tout système et de tout langage (codage des caractères sous JAVA)

Le codage des nombres entiers

- les nombres sont évidemment codés sous forme binaire. Sur une machine à mots de n bits, il est possible de coder 2^n nombres entiers. Afin de pouvoir coder à la fois des nombres positifs et des nombres négatifs, un bit est réservé pour le signe (bit de gauche à 0 pour les positifs et à 1 pour les négatifs)
- par exemple, la suite de 16 bits **0001101010111001** représente le nombre **6841** écrit sous forme décimal (base 10):
 - ◇ les chiffres 1 correspondent aux poids 0,3,4,5,7,9, 11 et 12
 - ◇ les puissances de 2 correspondantes ont comme valeur décimale: 1,8,16,32,128,512,2048 et 4096
 - ◇ la valeur décimale du nombre est donc: $1+8+16+32+128+512+2048+4096$

- les nombres négatifs sont représentés en **complément à 2**: sur une machine à n bits, le nombre α est représenté par $2^n - \alpha$
Ainsi, le nombre **-6841** est représenté sur 16 bits par $2^{16} - 6841$, c'est-à-dire comme $65536 - 6841 = 58695$, c'est-à-dire **1110010101000111**
- sur une machine de n bits, le plus grand entier représentable est $2^{n-1} - 1$ et le plus petit -2^{n-1} .
Ainsi sur **16 bits** l'intervalle est **[-32768:32767]** et sur **32 bits**, c'est **[-2147483648:2147483647]**
- les calculs se font modulo n (n est le nombre de bits utilisés)
- les calculs se font modulo n (n est le nombre de bits utilisés)

Représentation de l'opposé d'un nombre

Pour déterminer la représentation de $-n$,

- rechercher dans la représentation de n à partir de la droite le premier 1
- basculer tous les chiffres à sa gauche (les 1 deviennent des 0 et les 0 des 1)

Sur l'exemple:

0001101010111001
1110010101000111

Autre exemple:

0110010101001100
1001101010110100

- On peut également inverser tous les bits puis ajouter 1

Les base 8 et 16

L'écriture de nombres en base 2 est fastidieuse et peu compacte.

Il est courant et pratique d'utiliser :

- la base 8
 - ◇ représentation octale permettant de regrouper des séquences de 3 bits en un seul caractère (en commençant par la droite)
 - ◇ chiffres de la base sont 0,1,2,3,4,5,6 et 7
 - ◇ correspondance avec la base 2 :

<i>octal</i>	0	1	2	3	4	5	6	7
<i>binaire</i>	000	001	010	011	100	101	110	111

- ◇ Exemple : le nombre de 16 bits

0001101010111001

se traduit en 015271,

ce qui est la représentation octale du nombre décimal 6841

- la base 16 qui donne une écriture plus compacte.
 - ◇ regroupement de séquences de 4 bits en un seul caractère (en commençant par la droite)
 - ◇ chiffres: 0,1,2,3,4,5,6,7,8,9,A,B,C,D,E et F
 - ◇ correspondance avec la base 2 :

<i>hexa</i>	0	1	2	3	4	5	6	7
<i>bin</i>	0000	0001	0010	0011	0100	0101	0110	0111
<i>hexa</i>	8	9	A	B	C	D	E	F
<i>bin</i>	1000	1001	1010	1011	1100	1101	1110	1111

- ◇ Exemple : le nombre de 16 bits 0001101010111001 se traduit en 1AB9, ce qui est la représentation hexadécimale du nombre décimal 6841

Sens de lecture des octets

Dans tout ce que nous avons fait, nous avons supposé que l'octet de poids fort était à gauche, et donc que les nombres se lisaient comme nous en avons l'habitude.

Ce n'est pas toujours le cas !

On distingue:

- la représentation "par le grand bout" (*big endian*) dans laquelle l'octet de poids fort est stocké avant l'octet de poids faible (chez Motorola par exemple). C'est la manière usuelle de lire les nombres
- la représentation "par le petit bout" (*little endian*) dans laquelle l'octet de poids faible est stocké avant l'octet de poids fort (c'est le cas chez Intel)

Arithmétique en base 2

- les opérations sur les entiers s'appuient sur des tables d'addition et de multiplication:

<u>addition :</u>	+	0	1
	0	0	1
	1	1	10

<u>multiplication :</u>	*	0	1
	0	0	0
	1	0	1

*	0	1
0	0	0
1	0	1

- additions

- ◇ deux nombres positifs "petits"

$$\begin{array}{r}
 \text{---}11111111\text{---}1 \quad \text{retenues} \\
 + 0001101010111001 \quad 6841 \\
 0000011101010001 \quad 1873 \\
 \text{-----} \\
 0010001000001010
 \end{array}$$

On a en fait réaliser : $6841 + 1873 = 8714$

- ◇ somme "trop grande"

$$\begin{array}{r}
 1111\text{---}1\text{---} \\
 0001101010111001 \quad 6841 \\
 + 0110110011000000 \quad 27840 \\
 \text{-----} \\
 1000011101111001
 \end{array}$$

On a en fait réaliser une opération qui sur 16 bits a un résultat négatif, qui est l'opposé de **0111100010000111** (30855), et donc sur 16 bits,

$$\underline{6841 + 27840 = -30885}$$

◇ positif + négatif avec résultat positif

Ici on calcule **(-6841) + 27840**

11-11--11-----	<i>retenues</i>
1110010101000111	-6841
+ 0110110011000000	27840

10101001000000111	

sur 16 bits, un 17-ème chiffre apparaît, on l'oublie purement et simplement. Les 16 bits de poids faible **0101001000000111** correspondent au résultat **20999**

◇ positif + négatif avec résultat négatif

--1--1-----	<i>retenues</i>
0001101010111001	6841
+ 1001001101000000	-27840

1010110111111001	

Le résultat est le complément de

0101001000000111
c'est-à-dire **-20999**

- multiplications

- ◇ un exemple simple : calcul de $29*11$ en ne gardant que les chiffres significatifs:

```

  11101
  * 1011
  -----
  11101
+ 11101.
+ 11101...
  -----
 100111111

```

100111111 est la représentation de $29*11=319$

- ◇ deux nombres positifs plus compliqués
On imagine que si les nombres sont suffisamment grands, le résultat ne pourra pas tenir sur le nombre de bits disponibles.
C'est ce qui se passe par exemple avec $6841*315$ sur une machine 16 bits:

```

 1101010111001
 * 100111011
 -----
 1101010111001
 1101010111001.
 1101010111001...
 1101010111001....
 1101010111001.....
 1101010111001.....
 -----
1000001110000110100011

```

Les 16 chiffres de poids faible

1110000110100011

correspondent au complément à 2 de

0001111001011101

doit le nombre écrit 7773 en base dix

Le résultat obtenu est donc -7773

Sur une machine 32 bits, on obtient effectivement 1000001110000110100011, c'est-à-dire 2154915 ($6841*315$).

Les nombres non entiers

- les nombres rationnels (fractions):
 - ◇ apparus avec la notion de partage (les quantités $1/2$, $1/3$, $1/5$, ...) que les Egyptiens savaient additionner
 - ◇ les Grecs ont considéré les rapports de grandeurs entières et faisaient les 4 opérations (éléments d'Euclide, 3-ème siècle avant J.C)
- nombres irrationnels
 - ◇ découverte par les Grecs de la non-rationalité de $\sqrt{2}$ (qualifié d'irrationnel ou non énonçable)
 - ◇ vers l'an 1000, Arabes et Persans considéraient comme nombre tout rapport de longueur, d'où l'idée de nombres irrationnels.
Irrationalité de π (Lambert, 1761)
- les nombres décimaux: une partie entière et une partie décimale

Représentation des nombre réels

- virgule fixe comme sur les caisses enregistreuses. Par exemple:
 $r_1 = \underline{7467,56}$ ou $r_2 = \underline{-00000,842}$
- fractionnaire comme couple d'entiers
- virgule flottante
 - ◇ éventuellement un signe + ou -
 - ◇ une *mantisse* m (en virgule fixe)
 - ◇ un *exposant* e
 - ◇ une *base* b

soit donc: $\underline{\pm m \times b^e}$

Par exemple quelques-unes des écritures pour r_1 et r_2 sont:

 - $\underline{74,6756 \times 10^2}$
 - $\underline{746756000000 \times 10^{-8}}$
 - $\underline{8,42 \times 10^{-5}}$

Existence d'une *infinité* de représentations d'un nombre sous cette forme, d'où le choix d'une représentation normalisée:

dans la base b , la mantisse m est prise dans l'intervalle $[1 : b[$ (avec une représentation particulière pour zéro)

pour r_1 : $7,46756 \times 10^1$

pour r_2 : $8,42 \times 10^{-2}$

Changement de base en virgule fixe

On se limitera ici au passage de la représentation en virgule fixe de la base *dix* à la base *deux*.

- les chiffres de la partie entière d'un nombre écrit en notation positionnelle en base b correspondent successivement, de droite à gauche avant la virgule aux puissances positives de la base (chiffre des unités correspondant à la puissance 0 de la base, chiffre des "*basaines*" multiples de b^1 , puis les multiples de b^2 , . . .)
- les chiffres de la partie décimale (c'est-à-dire à la droite de la virgule) d'un nombre écrit en notation positionnelle en base b correspondent successivement, de gauche à droite après la virgule, aux puissances négatives de la base (les "*basèmes*" fractions de b^{-1} , puis celles de b^{-2} , . . .).

Passage de la base dix à la base deux

- la partie entière se calcule par divisions successives par 2 (il s'agit d'un nombre entier)
- la partie décimale se calcule par multiplications successives par 2 de la partie décimale et on garde à chaque étape le chiffre qui sort avant la virgule. La suite de ces chiffres 0 ou 1 donne la partie décimale en base deux.
- soit le nombre qui s'écrit 0,3 en base dix. Sa transformation en base deux par la méthode décrite donne:

$$0,3 \times 2 = \underline{0}.6$$

$$0,6 \times 2 = \underline{1}.2$$

$$0,2 \times 2 = \underline{0}.4$$

$$0,4 \times 2 = \underline{0}.8$$

$$0,8 \times 2 = \underline{1}.6$$

$$0,6 \times 2 = \underline{1}.2$$

...

On voit apparaître une période infinie 1001 pour la représentation du nombre qui est donc

$$\underline{0,010011001100110011001\dots}$$

Ainsi, un nombre finiment représenté en base dix ne l'est pas nécessairement en base deux.

Le fait que la représentation soit infinie correspond au fait que 0,3 ne s'exprime pas comme une somme de puissances négatives du nombre deux.

Comme on peut l'imaginer, cela est source de nombreuses difficultés et résultats surprenants aux conséquences parfois catastrophiques si on n'y prend pas garde.

Voir les exemples un peu plus loin.

Représentation dans un ordinateur

- la base b est bien évidemment 2
- représentation normalisée (norme IEEE754)
 - ◇ nombres codés sur 32 bits en simple précision et 64 bits en double précision
 - ◇ nombre de bits des composants de la représentation:

	signe	exposant	mantisse	excès exposant
simple précision	1 bit	8 bits	23 bits	127
double précision	1 bit	11 bits	52 bits	1023

- ◇ nombre positif si bit de signe = 0
- ◇ mantisse dans l'intervalle $[1,0 : 10,0[$ (on parle ici en base deux !)
Le seul chiffre (binaire) à gauche de la virgule est un 1 et n'est donc pas représenté
- ◇ dans la partie exposant, ce qui est stocké, c'est la valeur vraie de l'exposant (qui désigne évidemment une puissance de deux) augmentée de la valeur donnée dans le tableau.

Ainsi, en simple précision

- la valeur décimale 234 désigne un exposant vrai égal à 107 ($234-127$)
- la valeur décimale 34 désigne un exposant vrai égal à -93 ($34-127$)
- les valeurs 0 (tous les bits à 0) et 255 (tous les bits à 1) sont réservées et ne représentent pas les valeurs vrais d'exposant -127 et +128.

Intervalles des valeurs

- la plus grande valeur correspond à un exposant de valeur maximale (127) et tous les bits de la mantisse à 1, c'est-à-dire $\frac{(2 - 2^{-23})^{127}}{(2 - 2^{-52})^{1023}}$ en simple précision et $\frac{(2 - 2^{-23})^{127}}{(2 - 2^{-52})^{1023}}$ en double
- la plus petite valeur correspond à la même configuration avec un bit de signe égal à 1, donc $\frac{-(2 - 2^{-23})^{127}}{(2 - 2^{-52})^{1023}}$ en simple précision et $\frac{-(2 - 2^{-23})^{127}}{(2 - 2^{-52})^{1023}}$ en double

Représentation des entiers sous forme flottante

Exemple: l'entier 2093787663_{10} :

- sa représentation binaire comme entier est

01111100110011001010101000001111

(on a distingué les paquets de 8 bits successifs pour faciliter la lecture)

- sa forme normalisée comme nombre réel en base deux (sans se préoccuper de sa mémorisation effective) est:

1.111100110011001010101000001111

avec un exposant égal à 30_{10} , c'est-à-dire 11110_2 ;

- dans sa représentation sur 32 bits:
 - ◇ le nombre étant positif, le bit de signe est 0
 - ◇ on ajoute à l'exposant l'excès 127_{10} , c'est-à-dire 1111111_2 , ce qui donne la valeur 10011101

- ◇ la mémorisation de ce nombre en mémoire ne permet de conserver que 23 bits (24 en fait puisque le premier 1 est *gratuit* et n'est pas enregistré), ce qui donne les 23 bits:

11110011001100101010100

- ◇ finalement la représentation du nombre est obtenue par la mise bout à bout des 3 suites de bits précédentes, ce qui donne (on a distingué les paquets de 4 bits successifs pour faciliter le passage ultérieur à une expression symbolique en hexadécimal):

01001110111110011001100101010100

Cette suite de 32 bits vue comme la représentation d'un nombre entier s'exprime sous forme hexadécimale sous la forme suivante

4EF99954

◇ **vérification expérimentale**

Le programme C suivant :

```
main( ) {
    int n = 2093787663;
    union {
        float f;
        int n; } val;
    val.f = 2093787663;
    printf(" n = %d\n val.f = %f\n
           val.f = %e, val.n = %p\n",
           n, val.f, val.f, val.n);
}
```

confirme ces résultats :

```
n = 2093787663
val.f = 2093787648.000000 // approchée
val.f = 2.093788e+09
val.n = 4ef99954 // hexadécimal
```

En Java, on écrirait par exemple :

```
class EntierReel {
    public static void main(String [ ] a){
        int n = 2093787663;
        float f = 2093787663;
        Deug.println("n = " + n +
                    "      f = " + f);
    }
}
```

dont l'exécution donne :

```
n = 2093787663      f = 2.09378765E9
```

Représentation des nombres décimaux

Si on reprend le nombre 0,3, sa forme normalisée en base deux est infinie et a la forme suivante où tous les nombres sont exprimés en base deux:

$$\underline{10^{-10} \times 1,0011001100110011001\dots}$$

Il sera donc représenté en machine avec

- le bit de signe 0
- les 8 bits de la partie exposant

$$\underline{1111111 + (-10) = 01111101}$$

- 23 bits extraits du développement infini de la partie après la virgule:

normalement 00110011001100110011001

mais en fait 00110011001100110011010

(arrondi à cause du 1 qui suit)

- la représentation complète sur 32 bits est:

00111110100110011001100110011010

sous forme hexadécimale :

3E99999A

ce que confirme les résultats du programme C suivant:

```
main( ) {
    union {
        float f;
        int n; } val;
    val.f = 0.3;
    printf(" val.f = %f\n val.f = %e\n
           val.n = %p\n", val.f,
           val.f, val.n);
}
```

à savoir :

val.f = 0.300000

val.f = 3.000000e-01

val.n = 3e99999a

Problèmes numériques

Exemple introductif

Considérons par exemple la séquence de code Java suivante:

```
if ((0.3 - 0.2) == (0.2 - 0.1))
    Deug.println("oui");
else
    Deug.println("non");
```

Son exécution affiche **non**

L'explication du résultat est dans la représentation des 3 nombres impliqués:

Forme décimale	Forme hexadécimale	représentation binaire sur 32 bits
<u>0.3</u>	<u>3E99999A</u>	<u>00111110 10011001 10011001 10011010</u>
<u>0.2</u>	<u>3E4CCCCD</u>	<u>00111110 01001100 11001100 11001101</u>
<u>0.1</u>	<u>3DCCCCCD</u>	<u>00111101 11001100 11001100 11001101</u>

La représentation de 0.3 - 0.2 est

3dccccce

alors que celle de 0.2 - 0.1 est

3dcccccd

L'exemple précédent met en lumière les problèmes d'imprécision introduite par la nécessité de représenter finement des valeurs représentées infiniment.

Autres exemples :

- dans l'exemple suivant écrit avec une boucle simple en Java:

```
class Ajouter {
    public static void main(String [ ] a){
        double somme = 0;
        while (somme != 20)
            somme = somme + 0.1;
        Deug.println("Après la boucle");
    }
}
```

l'exécution donne lieu à une boucle infinie (le programme ne se termine pas!): la valeur de la variable n'est jamais (exactement) 20.

- le test de nullité d'une variable de type float ou double comme dans la séquence C ou Java suivante:

```
if (val == 0)
    .....
```

"n'a pas de sens"

Un tel test doit être remplacé par "quelque chose" (ici en Java) de la forme

```
if (Math.abs(val) < eps)
    .....
```

Disons simplement que la valeur epsilon dépend tout à la fois de la machine, et de l'application.

- addition de nombres d'ordres de grandeur très différents

Pour additionner deux nombres, il faut ajuster leurs exposants. Cet ajustement se fait sur le plus grand des deux en alignant la mantisse et en effectuant la somme. Si les ordres de grandeur sont trop éloignés, le plus petit des deux nombres sera ignoré.

Le programme

```
class SommeReels {
    public static void main(String [ ] a){
        float reel1, reel2, somme;
        reel1 = (float) 1.2E3;
        reel2 = (float) 1.3E-2;
        somme = reel1 + reel2;
        Deug.println(somme);
        reel1 = (float) 1.2E4;
        reel2 = (float) 1.3E-4;
        somme = reel1 + reel2;
        Deug.println(somme);
    }
}
```

produit les affichages suivants:

1200.013 vision de $1200 + 0,013$

12000.0 vision de $12000 + 0,00013$

La première opération se fait sous la forme:

$$\underline{(1,2 \times 10^3) + (0,000013 \times 10^3)}$$

et la seconde sous la forme

$$\underline{(1,2 \times 10^4) + (0,0000000013 \times 10^4)}$$

On conçoit aisément que la limitation du nombre de chiffres entraîne la perte des informations relatives au second nombre (tout cela devant être codé en binaire).

Des calculs au format double améliore les choses sur ces données.

On obtient alors l'affichage

1200.013

12000.00013

Quelques définitions utiles

Les valeurs suivantes correspondent à des situations où un calcul conduit à une valeur non représentable, c'est-à-dire de valeur absolue trop grande (*overflow*) ou une perte de précision (*underflow*) approximée par zéro:

- negative overflow: nombres inférieurs à $\underline{-(2 - 2^{-23})^{127}}$ (en simple précision)
- positive overflow: nombres positifs supérieurs à $\underline{(2 - 2^{-23})^{127}}$ (en simple précision)

Valeurs spéciales

- le zéro: il est représenté par la valeur nulle des champs exposants et mantisse (il existe donc +0 et un -0)
- infini positif: tous les bits du champ exposant à 1 et bits du champ mantisse à 0, bit de signe 0
- infini négatif: tous les bits du champ exposant à 1 et bits du champ mantisse à 0, bit de signe 1
- faux nombres: tous les bits du champ exposant à 1 et champ mantisse non nul
- forme dénormalisée: champ exposant nul et mantisse non nulle, sans premier bit 1 implicite