

POLYTECH **INFORMATIQUE**

3ÈME ANNÉE

Alexandra Bac

NUMERICAL METHODS

METHODS


COURS 1


INTRODUCTION, NOMBRES ET MACHINES

MÉTHODES NUMÉRIQUES



Calculer avec un ordinateur





MÉTHODES NUMÉRIQUES

Calculer avec un ordinateur

Représenter les données
(entiers, réels ...)

Réaliser les calculs

Opérations machine

Algorithmes numériques

Erreurs de représentation

Erreurs de calcul


Arrondi

Convergence

$\pi, \sqrt{2} \dots$

0.1 \rightarrow cannot be rep. exactly on a computer ...

ANALYSE NUMÉRIQUE



REPRÉSENTATION DES ENTIERS

PROBLÈME DE LA REPRÉSENTATION

Représentation en base b ($b \in \mathbb{N}, b > 0$)

$$n = \sum_{i=1}^N c_i \cdot b^i \quad \text{avec } c_i < b$$

Représenté par



(c_0, \dots, c_N)

$b = 2$

$$n = \sum_{i=1}^N c_i \cdot b^i \quad \text{avec } c_i \in \{0,1\}$$

bits

Représenté par



(c_0, \dots, c_N)

N bits

PROBLÈME DE LA REPRÉSENTATION

Représentation en base b ($b \in \mathbb{N}, b > 0$)

$$n = \sum_{i=1}^N c_i \cdot b^i \quad \text{avec } c_i < b$$

Représenté par

(c_0, \dots, c_N)

$b = 2$

$$n = \sum_{i=1}^N c_i \cdot b^i \quad \text{avec } c_i \in \{0,1\}$$

bits

Représenté par

(c_0, \dots, c_N)

N bits

Ordinateur \rightarrow objets finis

integer \rightsquigarrow 32 bits / 4 bytes

Entiers négatifs ?

PROBLÈME DE LA REPRÉSENTATION

$$n = \sum_{i=1}^N c_i \cdot b^i \quad \text{avec } c_i \in \{0,1\}$$

ENTIERS POSITIFS

$$N \leftrightarrow 0 \leq n \leq 2^N - 1$$

- ▶ N=8 (unsigned char)
 $2^8 - 1 = 255$
- ▶ N=16 (unsigned short)
 $2^{16} - 1 = 65535$
- ▶ N=32 (unsigned int)
 $2^{32} - 1 = 4.294.967.295$
- ▶ N=64 (unsigned long int)
 $2^{64} - 1 = 1,844 \cdot 10^{19}$


ENTIERS RELATIFS

1 bit utilisé pour coder le signe

$$N \leftrightarrow -2^{N-1} \leq n \leq 2^{N-1} - 1$$

- ▶ N=8 (char)
 $-128 \leq n \leq 127$
- ▶ N=16 (short)
 $-32768 \leq n \leq 32767$
- ▶ N=32 (int)
 $-2.147.483.648 \leq n \leq 2.147.483.647$
- ▶ N=64 (long int)
 $-9,2 \cdot 10^{18} \leq n \leq 9,2 \cdot 10^{18}$

m \longrightarrow representation over N bits ?



$m \in$ range
given
on prev.
slide

$$m = (c_0 \dots c_N)$$

300 \longrightarrow cannot be
represented
with
 $N = 8$

\searrow
can be represented
with $N = 16$

PROBLÈME DE LA REPRÉSENTATION DES ENTIERS RELATIFS

$$n = \sum_{i=1}^N c_i \cdot b^i \quad \text{avec } c_i \in \{0,1\}$$

Codage du signe

CODAGE NAÏF PAR UN BIT

$$c_{N-1}c_{N-2}\dots c_1c_0 \rightarrow n = (-1)^{c_{N-1}} \left(\sum_{i=0}^{n-2} c_i \cdot 2^i \right)$$

Bit de signe

-11 sur 8 bits :

1 | 0 | 0 | 0 | 1 | 0 | 1 | 1

COMPLEMENT A UN

Le plus utilisé actuellement

$$c_{N-1}c_{N-2}\dots c_1c_0 \rightarrow n = -c_{N-1} \cdot 2^{N-1} + \sum_{i=0}^{n-2} c_i \cdot 2^i$$

-11 sur 8 bits :

$$-11 = -128 + 117$$

1 | 1 | 1 | 1 | 0 | 1 | 0 | 1

PROBLÈME DE LA REPRÉSENTATION DES ENTIERS RELATIFS

$$n = \sum_{i=1}^N c_i \cdot b^i \quad \text{avec } c_i \in \{0,1\}$$

Codage du signe

CODAGE NAÏF PAR UN BIT

- ▶ 0 a deux représentations
00000000 / 10000000
- ▶ Addition → cas à traiter
-11 + (-5)
-11 + 5

COMPLEMENT A UN

Le plus utilisé actuellement

- ▶ 0 a une seule représentation
00000000
- ▶ L'**addition reste valable**

$$\begin{array}{r} -11 : 11110101 \\ -5 : 11111011 \\ + \hline 11110000 \end{array} \longrightarrow 112 \text{ (déc)}$$

Résultat : -128 + 112 = -16 (déc)

PROBLÈME DE LA REPRÉSENTATION DES ENTIERS RELATIFS

$$n = \sum_{i=1}^N c_i \cdot b^i \quad \text{avec } c_i \in \{0,1\}$$

Codage du signe

CODAGE NAÏF PAR UN BIT

- ▶ 0 a deux représentations
00000000 / 10000000
- ▶ Addition → cas à traiter
-11 + (-5)
-11 + 5

COMPLEMENT A UN

Le plus utilisé actuellement

- ▶ 0 a une seule représentation
00000000
- ▶ L'**addition reste valable**

$$\begin{array}{r} -11 : 11110101 \\ 5 : 00000101 \\ + \hline 11111010 \end{array} \longrightarrow 122 \text{ (déc)}$$

Résultat : -128 + 122 = -6 (déc)

REPRÉSENTATION DES FLOTTANTS ...

Mériterait un cours entier ... cf TD ...

**UN MOT SUR LES
ERREURS**

EVALUATION DE L'ERREUR COMMISE

Erreur commise entre x et x' ?

$x = 1,2957$
 $x' = 1,2956$ \curvearrowright $|x - x'| = 10^{-4}$

$x = 0,0017$
 $x' = 0,0016$ \curvearrowright $|x - x'| = 10^{-4}$

$x = 0,0007$
 $x' = 0,0006$ \curvearrowright $|x - x'| = 10^{-4}$

Même erreur ?

EVALUATION DE L'ERREUR COMMISE

Erreur commise entre x et x' ?

$x = 1,2957$
 $x = 1,2956$ \curvearrowright $|x - x'| = 10^{-4}$

$7 \cdot 10^{-3} \%$

$x = 0,0017$
 $x = 0,0016$ \curvearrowright $|x - x'| = 10^{-4}$

Même erreur ?

5,9 %

$x = 0,0007$
 $x = 0,0006$ \curvearrowright $|x - x'| = 10^{-4}$

14,3 %

EVALUATION DE L'ERREUR COMMISE

Erreur commise entre x et x' ?

ERREUR ABSOLUE

$$|x - x'|$$

- ▶ Naturel sur les petits nombres
 $|x| < 1$
- ▶ Peut être inatteignable sur de grands nombres

ERREUR RELATIVE

$$\frac{|x - x'|}{|x|}$$

- ▶ Naturel sur les grands nombres
 $|x| \gg 1$
- ▶ L'erreur dépend de l'ordre de grandeur de x

Compute solution x^*



conjugating alg.



$u_N \approx$
STOP

x^* up to a given precision

$$\|u_n - u_{n-1}\| < \epsilon \quad / \quad \frac{\|u_n - u_{n-1}\|}{\|u_n\|} < \epsilon$$

error \rightarrow absolute
 \rightarrow relative



$A \times B$ — algebra

alg. prod

$\{$

$*$


$$(A \times B)_{ij} = \sum_k A_{ik} \times B_{kj}$$

Alg.


$A^m = \underbrace{A \times \dots \times A}_{m \text{ times}}$

$\sim \wedge$

$A^3 = A \times A \times A$



\neq



$A * B$

algorithmic

$C_{ij} = a_{ik} \times b_{kj}$

RAND

uniform

\sim

$[0, 1]$

normal

\rightarrow

-probability

