

Arithmétique sur ordinateur

Calculer juste ou juste calculer ?

F. Langrognnet



PLAN

- 1 Calculer avec un ordinateur, est-ce une bonne idée ?
- 2 Qui est le responsable ?
- 3 Que faire ?
- 4 Références, conclusion

PLAN

1 Calculer avec un ordinateur, est-ce une bonne idée ?

- Des nombres plus dangereux que d'autres
- Des erreurs parfois importantes
- Codes équivalents ?
- Même code => même résultat ?

2 Qui est le responsable ?

3 Que faire ?

4 Références, conclusion

PLAN

1 Calculer avec un ordinateur, est-ce une bonne idée ?

- Des nombres plus dangereux que d'autres
- Des erreurs parfois importantes
- Codes équivalents ?
- Même code => même résultat ?

2 Qui est le responsable ?

3 Que faire ?

4 Références, conclusion

Un calcul simple

vraiment simple...

$$\text{Calcul de } \sum_{i=1}^n x$$

Avec $n = 1000$ et

- $x = 0.5$
- $x = 0.25$
- $x = 0.1$
- $x = 0.7$

Un calcul simple

Un peu de C++

```
int main(){
    float x;
    cout<<"Entrez la valeur de x"<<endl;
    cin>>x;
    float res = 0.0;
    for (int i=0;i<1000;i++){
        res+=x;
    }
    cout<<"Somme des x (1000 fois) : "<<setprecision(10)<<res<<endl;
    return 0;
}
```

Un calcul simple

Calculons

$$\sum_{i=1}^{1000} 0.5 = 500$$

$$\sum_{i=1}^{1000} 0.25 = 250$$

$$\sum_{i=1}^{1000} 0.1 = 99.999046$$

$$\sum_{i=1}^{1000} 0.7 = 700.006958$$

Un calcul simple

Calculons

$$\sum_{i=1}^{1000} 0.5 = 500$$

$$\sum_{i=1}^{1000} 0.25 = 250$$

$$\sum_{i=1}^{1000} 0.1 = 99.999046$$

$$\sum_{i=1}^{1000} 0.7 = 700.006958$$

Un calcul simple

Calculons

$$\sum_{i=1}^{1000} 0.5 = 500$$

$$\sum_{i=1}^{1000} 0.25 = 250$$

$$\sum_{i=1}^{1000} 0.1 = 99.999046$$

$$\sum_{i=1}^{1000} 0.7 = 700.006958$$

Un calcul simple

Calculons

$$\sum_{i=1}^{1000} 0.5 = 500$$

$$\sum_{i=1}^{1000} 0.25 = 250$$

$$\sum_{i=1}^{1000} 0.1 = 99.999046$$

$$\sum_{i=1}^{1000} 0.7 = 700.006958$$

Et avec Matlab ?

Ce calcul avec Matlab

```
x = single(0.1);  
res = 0.0;  
for i=1:1000  
    res = res+x;  
end;
```

- **res = 99.9990**
- **Pas mieux** (même erreur)

Remarque

Tous les calculs (C++ et Matlab) ont été faits en **simple précision**

un calcul simple

Et avec des **double precision** ?

On remplace les **float** par des **double** et ...

$$\sum_{i=1}^{1000} 0.1 = 99.9999999999985931253$$

On repousse simplement le problème !

un calcul simple

Et avec des **double precision** ?

On remplace les **float** par des **double** et ...

$$\sum_{i=1}^{1000} 0.1 = 99.9999999999985931253$$

On repousse simplement le problème !

Question 1

- Pourquoi les résultats avec $x = 0.5$ et $x = 0.25$ sont-ils justes et ceux avec $x = 0.7$ et $x = 0.1$ faux ?
- 0.7 et 0.1 sont-ils plus **dangereux** que 0.5 et 0.25 ?



Question 2

Est-ce vraiment grave ?



Exemple concret d'une erreur numérique

- Guerre du Golfe de 1991 : un anti-missile US Patriot dont le programme tournait depuis 100 heures a raté l'interception d'un missile Irakien Scud - **28 morts**
- Explication :
 - ▶ l'anti missile Patriot incrémentait un compteur toutes les 0.1 secondes
 - ▶ 0.1 approché avec erreur 0.0000000953 (codé sur 24 bits)
 - ▶ au bout de 100 heures, erreur cumulée 0.34s
 - ▶ dans ce laps de temps le Scud parcourt 500 mètres.



PLAN

1 Calculer avec un ordinateur, est-ce une bonne idée ?

- Des nombres plus dangereux que d'autres
- **Des erreurs parfois importantes**
- Codes équivalents ?
- Même code => même résultat ?

2 Qui est le responsable ?

3 Que faire ?


4 Références, conclusion

Suite de Muller

Soit la suite de Muller définie par :

$$\begin{cases} u_0 = 2 \\ u_1 = -4 \\ u_{n+1} = 111 - \frac{1130}{u_n} + \frac{3000}{u_n \cdot u_{n-1}} \end{cases}$$

- u_n converge vers **6**
- Sur n'importe quel système à précision finie on observera une convergence apparente, très rapide, vers **100**



Fonction de Rump

Fonction de Rump

$f(a, b) = (333 + \frac{3}{4})b^6 + a^2(11a^2b^2 - b^6 - 121b^4 - 2) + \frac{11}{2}b^8 + \frac{a}{2b}$ avec
 $a = 77617.0$ et $b = 33096.0$

Résultats

- Simple précision (32 bits) : $\approx -2,34 \cdot 10^{29}$
- Double précision (64 bits) : $\approx -1,1 \cdot 10^{21}$
- Avec d'autres parenthésages, sur des architectures différentes
 - ▶ Simple précision : $\approx 7,09 \cdot 10^{29}$ ou encore $\approx +1,17$
 - ▶ Double précision : $\approx +1,17$ (souvent)

Quelle est la bonne valeur ?

$\approx -0.82739605994682136814116509547981629$

Fonction de Rump

Fonction de Rump

$f(a, b) = (333 + \frac{3}{4})b^6 + a^2(11a^2b^2 - b^6 - 121b^4 - 2) + \frac{11}{2}b^8 + \frac{a}{2b}$ avec
 $a = 77617.0$ et $b = 33096.0$

Résultats

- Simple précision (32 bits) : $\approx -2, 34.10^{29}$
- Double précision (64 bits) : $\approx -1, 1.10^{21}$
- Avec d'autres parenthésages, sur des architectures différentes
 - ▶ Simple précision : $\approx 7, 09.10^{29}$ ou encore $\approx +1, 17$
 - ▶ Double précision : $\approx +1, 17$ (souvent)

Quelle est la bonne valeur ?

$\approx -0.82739605994682136814116509547981629$

Fonction de Rump

Fonction de Rump

$f(a, b) = (333 + \frac{3}{4})b^6 + a^2(11a^2b^2 - b^6 - 121b^4 - 2) + \frac{11}{2}b^8 + \frac{a}{2b}$ avec
 $a = 77617.0$ et $b = 33096.0$

Résultats

- Simple précision (32 bits) : $\approx -2, 34.10^{29}$
- Double précision (64 bits) : $\approx -1, 1.10^{21}$
- Avec d'autres parenthésages, sur des architectures différentes
 - ▶ Simple précision : $\approx 7, 09.10^{29}$ ou encore $\approx +1, 17$
 - ▶ Double précision : $\approx +1, 17$ (souvent)

Quelle est la bonne valeur ?

$\approx -0.82739605994682136814116509547981629$

Fonction de Rump

Fonction de Rump

$$f(a, b) = (333 + \frac{3}{4})b^6 + a^2(11a^2b^2 - b^6 - 121b^4 - 2) + \frac{11}{2}b^8 + \frac{a}{2b} \text{ avec } a = 77617.0 \text{ et } b = 33096.0$$

Résultats

- Simple précision (32 bits) : $\approx -2, 34.10^{29}$
- Double précision (64 bits) : $\approx -1, 1.10^{21}$
- Avec d'autres parenthésages, sur des architectures différentes
 - ▶ Simple précision : $\approx 7, 09.10^{29}$ ou encore $\approx +1, 17$
 - ▶ Double précision : $\approx +1, 17$ (souvent)

Quelle est la bonne valeur ?

$\approx -0.82739605994682136814116509547981629$

Fonction de Rump

Fonction de Rump

$$f(a, b) = (333 + \frac{3}{4})b^6 + a^2(11a^2b^2 - b^6 - 121b^4 - 2) + \frac{11}{2}b^8 + \frac{a}{2b} \text{ avec } a = 77617.0 \text{ et } b = 33096.0$$

Résultats

- Simple précision (32 bits) : $\approx -2, 34.10^{29}$
- Double précision (64 bits) : $\approx -1, 1.10^{21}$
- Avec d'autres parenthésages, sur des architectures différentes
 - ▶ Simple précision : $\approx 7, 09.10^{29}$ ou encore $\approx +1, 17$
 - ▶ Double précision : $\approx +1, 17$ (souvent)

Quelle est la bonne valeur ?

$\approx -0.82739605994682136814116509547981629$

PLAN

1 Calculer avec un ordinateur, est-ce une bonne idée ?

- Des nombres plus dangereux que d'autres
- Des erreurs parfois importantes
- Codes équivalents ?
- Même code => même résultat ?

2 Qui est le responsable ?

3 Que faire ?

4 Références, conclusion

Codes vraiment équivalents ?

$$f(x) = x^2 + \frac{1}{10} \sin(x)$$

$$f(x) = x * x + 0.1 \sin(x)$$

$$g(n) = \sum_{i=1}^n \frac{1}{i}$$

$$g(n) = \sum_{i=n}^1 \frac{1}{i}$$

donnent elles toujours les mêmes résultats ?

NON !!!

2 codes mathématiquement équivalents peuvent mener à des résultats différents

PLAN

1 Calculer avec un ordinateur, est-ce une bonne idée ?

- Des nombres plus dangereux que d'autres
- Des erreurs parfois importantes
- Codes équivalents ?
- Même code => même résultat ?

2 Qui est le responsable ?

3 Que faire ?

4 Références, conclusion

Même code => même résultat ? (1)

Ordre des opérations

```
int main() {  
    double x, a, b, c, d;  
    x = a + b + c + d;  
    return 0;  
}
```

Ordre des opérations

- Est-il toujours le même ?
- Est-il indépendant du langage ?
- Est-il indépendant des options du compilateur ?



NON !!!

Le même code peut être exécuté de manières différentes
(mathématiquement équivalentes)

Même code => même résultat ? (2)

L'ordre des opérations a-t-il une importance ?



$$(a + b) + c \stackrel{?}{=} a + (b + c)$$

NON !!!

L'ordre des opérations a une importance
Les résultats peuvent être différents

Question 3

Simulation numérique




Le climat sera t-il le même si on change de calculateur, de compilateur ?

Question 4

Faut-il jeter son ordinateur à la poubelle ...



... et utiliser la règle à calculs ?



PLAN

1 Calculer avec un ordinateur, est-ce une bonne idée ?

2 Qui est le responsable ?

- Qui est en charge des calculs ?
- Que dit la norme ?
- Les limites de la norme et ses conséquences ?

3 Que faire ?

4 Références, conclusion

PLAN

- 1 Calculer avec un ordinateur, est-ce une bonne idée ?
- 2 Qui est le responsable ?
 - Qui est en charge des calculs ?
 - Que dit la norme ?
 - Les limites de la norme et ses conséquences ?
- 3 Que faire ?
- 4 Références, conclusion

Qui est en charge des calculs ?

Le traitement de la précision des calculs se situe sur
l'ensemble de l'environnement logiciel et matériel

- **Processeur**

- ▶ réalise des opérations de calcul (Floating Point Unit)
- ▶ gère les exceptions
- ▶ possède ses propres registres (pour stocker des flottants)

- **Système d'exploitation**

- ▶ transmet les exceptions
- ▶ calcule les opérations (/fonctions) non gérées par le processeur
- ▶ gère le statut du calcul flottant : précision, mode d'arrondi

- **Langage de programmation**

- **Compilateur**

- **Développeur**

Langage de programmation

Les langages de programmation n'ont pas toujours les mêmes règles. Certains imposent un ordre (C++ sauf avec certaines options...), d'autres non (Fortran)



Exemple


$$x = a + b + c + d$$

- Dans quel ordre seront effectués les calculs ?
- Quel est l'impact sur le résultat ?

Compilateur

Le Compilateur

- possède des centaines d'options
- certaines options permettent de préserver la sémantique du langage
- mais ne sont pas toujours (/rarement ?) activées par défaut
- **Marketing** : les valeurs par défaut doivent optimiser la vitesse (...et pas la précision)



Développeur

- Est censé maîtrisé tout ce qui précède
- Et ... est tenu pour **responsable** de tout problème sur le logiciel, y compris la perte de précision



PLAN

- 1 Calculer avec un ordinateur, est-ce une bonne idée ?
- 2 Qui est le responsable ?
 - Qui est en charge des calculs ?
 - Que dit la norme ?
 - Les limites de la norme et ses conséquences ?
- 3 Que faire ?
- 4 Références, conclusion

Avant la norme...

Le chaos !



La norme en 3 lignes

La version de 1985 définit

- La **représentation** des réels
Simple et double précision
- 4 **modes** d'arrondi
- La notion d'arrondi **correct**




Représentation des réels

Représentation des réels

Mantisse, exposant, signe

Un nombre réel est représenté par un triplet :

- le signe (1 bit)
Négatif si bit=1, positif sinon
- l'exposant *decalé* (e bits)
Nombre entier compris entre 0 et $2^e - 1$
- la mantisse (m bits)
Représente un nombre réel compris entre 0 et 1



Norme IEEE-754 - nombre de bits

Type	Signe	Exposant	Mantisse
float (simple précision)	1	8	23
double (double précision)	1	11	52

Modes d'arrondi


Arrondis

Toutes les opérations (y compris l'affectation) fournissent des valeurs arrondies vers une valeur représentable en machine


Il existe 4 modes d'arrondi dans la norme IEEE 754 :

- vers moins $+\infty$ (RU)
- vers plus $-\infty$ (RD)
- vers 0 (RZ)
- Au plus proche (RN)

Modes d'arrondi



Modes d'arrondi



Arrondis corrects

Arrondis corrects

Arrondis corrects

Idée : éviter la propagation des erreurs d'arrondis à chaque opération

Soit

- x et y 2 nombres exactement représentables en machine
- \odot une opération
- \diamond le mode d'arrondi

La norme IEEE 754 exige que le resultat d'une operation $x \odot y$ soit égal à $\diamond(x \odot_{exact} y)$

Le résultat doit être le même que si on effectuait le calcul en précision infinie puis on arrondissait ce résultat.

PLAN

- 1 Calculer avec un ordinateur, est-ce une bonne idée ?
- 2 Qui est le responsable ?
 - Qui est en charge des calculs ?
 - Que dit la norme ?
 - Les limites de la norme et ses conséquences ?
- 3 Que faire ?
- 4 Références, conclusion

Absorption

Absorption

Lors d'une addition de 2 nombres ayant des **ordres de grandeur très différents**, on peut **perdre toute l'information** du plus petit.

Exemple

$$10^6 + 0.01171875 = 10^6 !$$

L'addition respecte bien l'arrondi correct

- 10^6 est le meilleur représentant pour 1000000,01171875
- Le nombre flottant suivant est 1000000,0625

Cancellation

Cancellation

Lors d'une soustraction de 2 nombres **proches**, on introduit **des chiffres faux** (/inconnus)

Exemple

$$9.500000953674316 - 9.5 = 9.53674316 \mathbf{40625} \cdot 10^{-7} !$$

La soustraction respecte bien l'arrondi correct

Cancellation et absorption



- Lors d'une **cancellation**, on introduit arbitrairement des 0 dans la mantisse (car on ne dispose pas de plus de précision sur les opérandes)
- Si les opérandes sont issus d'un calcul précédent ils ont pu subir une perte de précision (en cas d'**absorption** par exemple)

Cette perte de précision va alors être ré-intégrée et amplifiée.

Dans ce cas, les bits arbitrairement introduits (des 0) ne sont pas les bons.

Exemple

$$(10^6 + 0.01171875) - 10^6 = 0$$

Addition et multiplication

- La **commutativité est respectée** pour l'addition et la multiplication
 - ▶ $a + b = b + a$
 - ▶ $a * b = b * a$
- L'**associativité n'est pas respectée** (en général) ni pour l'addition, ni pour la multiplication
 - ▶ $(a + b) + c \stackrel{?}{=} a + (b + c)$
 - ▶ $(a * b) * c \stackrel{?}{=} a * (b * c)$
- La **distributivité n'est pas respectée** (en général) entre la multiplication et l'addition
 - ▶ $a(b + c) \stackrel{?}{=} ab + ac$

Arrondis corrects


... oui mais pas toujours

- La norme IEEE 754 n'impose l'**arrondi correct** que pour les opérations :
 $+$, $-$, $*$, $/$, $\sqrt{\quad}$
- Pour toutes les autres opérations, la norme **conseille** l'arrondi correct.

Pour ces fonctions, on ne peut donc jamais être sûr que le résultat d'une opération fournit le **meilleur** résultat dans \mathbb{F} .

L'**arrondi correct** n'est pas garanti pour une opération mathématique (autre que $+$, $-$, $*$, $/$, $\sqrt{\quad}$)

Arrondis corrects / non corrects



- Pour \sqrt{x} , l'arrondi correct est assuré
Le résultat est connu (/assuré) (au mode d'arrondi près)
- Pour $\exp(x)$, l'arrondi correct n'est pas assuré
On ne peut pas connaître la valeur retournée

PLAN

1 Calculer avec un ordinateur, est-ce une bonne idée ?

2 Qui est le responsable ?

3 **Que faire ?**

- Quelques conseils de bon sens
- Peut-on améliorer ou mesurer la précision ?

4 Références, conclusion

PLAN

- 1 Calculer avec un ordinateur, est-ce une bonne idée ?
- 2 Qui est le responsable ?
- 3 Que faire ?
 - Quelques conseils de bon sens
 - Peut-on améliorer ou mesurer la précision ?
- 4 Références, conclusion

Comparaisons

Comparaisons

La **comparaison** entre 2 réels doit être considérée avec la plus **grande prudence** !

- Ne jamais tester **if $x == y$...** surtout si x et y sont le résultat d'un calcul précédent
- Attention aux tests d'arrêt **if $|x_n - x_{n-1}| < \epsilon$...** ou même **if $\frac{|x_n - x_{n-1}|}{|x_n|} < \epsilon$...**
- Attention aux algorithmes dépendant de la comparaison entre 2 réels
Ex : **if $(x < y)$ <Traitement1> else <Traitement2>**



Savoir ordonner les opérations

... ou comment minimiser les effets de l'absorption

Impact de l'ordre des opérations

Somme des inverses de i

- De 1 à N :
$$\sum_{i=1}^n \frac{1}{i} \quad (1)$$

- ou de N à 1 :
$$\sum_{i=n}^1 \frac{1}{i} \quad (2)$$

Impact de l'ordre des opérations

Somme des inverses de i (de 1 à N)

En simple précision, on obtient :

N	10^5	10^6	10^7	10^8
valeur exacte	12.09015	14.39273	16.69531	18.99790
$1 \rightarrow N$	12.09085	14.35736	15.40368	15.40368
$N \rightarrow 1$	12.09015	14.39265	16.68603	18.80792

- $\sum_{i=1}^n \frac{1}{i}$: Pour n grand, on finira par additionner des réels d'ordres de grandeur très différents : **absorptions**
- $\sum_{i=n}^1 \frac{1}{i}$: Les ordres de grandeur dans les additions seront semblables

PLAN

- 1 Calculer avec un ordinateur, est-ce une bonne idée ?
- 2 Qui est le responsable ?
- 3 Que faire ?
 - Quelques conseils de bon sens
 - Peut-on améliorer ou mesurer la précision ?
- 4 Références, conclusion

Peut-on améliorer la précision ?

Bibliothèques de calcul utiles

- **Flottants codés sur plus de bits**
GMP (GNU Multiple Precision Arithmetic Library)
- **Arrondi correct pour toutes les fonctions mathématiques**
CRlibm (Correctly Rounded Mathematical LIBrary)
- **Précision arbitraire **et** arrondis corrects pour toutes les fonctions**
MPFR

Peut-on mesurer la précision ?

Arithmétique stochastique

Principe

- En changeant le mode d'arrondi à chaque opération, on **propage différemment** les erreurs d'arrondi
- En lançant plusieurs fois les calculs, on obtient des **résultats différents**
- L'étude **statistique** de ces résultats (représentant un échantillon d'une loi de probabilité) donne des **informations** sur la précision

Bibliothèque Cadna

La bibliothèque **Cadna** intègre l'arithmétique stochastique

- Donne le **nombre de chiffres significatifs**
- Indique les lignes de code où apparaissent des **pertes de précision** (cancellations, absorptions, branchements instables, ...)

Arithmétique par intervalle

Formule générale



$$X \diamond Y = \text{Hull}\{x \diamond y; x \in X, y \in Y\}$$

Opérations courantes

$$[\underline{x}, \bar{x}] + [\underline{y}, \bar{y}] = [\underline{x} + \underline{y}, \bar{x} + \bar{y}]$$

$$[\underline{x}, \bar{x}] - [\underline{y}, \bar{y}] = [\underline{x} - \bar{y}, \bar{x} - \underline{y}]$$

...



MPFI (bibliothèque d'arithmétique par intervalles multi-précision)

PLAN


- 1 Calculer avec un ordinateur, est-ce une bonne idée ?
- 2 Qui est le responsable ?
- 3 Que faire ?
- 4 **Références, conclusion**

Ma page personnelle

<https://lmb.univ-fcomte.fr/Florent-Langrognat>


- Un **cours** pour comprendre la représentation des nombres réels, l'arithmétique flottante, par intervalle et stochastique)
- Un **article** dans HPC magazine
- Une **école** "précision et reproductibilité en calcul numérique" (<http://calcul.math.cnrs.fr/spip.php?article220>)

Un livre



Conclusion

Calculer juste ou juste calculer ?



Les risques sont réels...
.. mieux vaut les connaître.