



# Correction des exercices du TD 1

## Exercice 1.1

Soit un système de représentation flottant avec base  $\beta$ , mantisse à  $p$  places, exposant  $E$  avec  $E_m \leq E \leq E_M$ .  
Calculer le nombre de valeurs normalisées qui peuvent être représentées par ce système.

Application :  $\beta = 10, p = 3, E_m = -15, E_M = 16$ .

Un nombre normalisé en virgule flottante, si  $\beta > 2$ , est un nombre dans lequel le chiffre qui précède la virgule est un 0 et le chiffre qui suit la virgule n'est pas un 0. Ce 0 est omis dans l'écriture de la mantisse et le nombre est stocké comme un entier<sup>(1)</sup>.

Un nombre type  $n$  codé en représentation normalisée s'exprime :

$$n = (-1)^s 0.a_1 a_2 \dots a_p \times \beta^E \text{ avec } E_m \leq E \leq E_M$$

On a

- nombre d'exposants disponibles :  $E_M - E_m + 1$ . En réalité, pour les nombres normalisés il faut ne pas tenir compte de l'exposant 00...0 (nombres sous-normalisés) et de l'exposant 11...1 (NaN). Donc exposants disponibles pour le codage :  $E_M - E_m - 1$ .
- nombre de nombres de la forme  $0.a_1 a_2 \dots a_p$  :  $(\beta - 1)\beta^{p-1}$  puisque chaque chiffre  $a_i$  évolue entre 0 et  $\beta - 1$  sauf si  $a_1$  qui ne peut être nul et évolue donc entre 1 et  $\beta - 1$
- nombre de signes possibles : 2

Il faut y ajouter 2 zéros (le positif et le négatif), soit au total :

$$2(\beta - 1)\beta^{p-1} (E_M - E_m - 1) + 2$$

Application :

$$\begin{aligned} 2(\beta - 1)\beta^{p-1} (E_M - E_m - 1) + 2 &= 2 \cdot 9 \cdot 10^2 (16 + 15 - 1) + 2 \\ &= 54000 + 2 = 54002 \end{aligned}$$

## Exercice 1.2

Soient trois réels  $x = 0.125 \times 10^6, z = 0.437 \times 10^{12}, w = 0.215 \times 10^{-10}$ . En utilisant le système de numération de l'exercice précédent pour le stockage de ces nombres, calculer :

1. La somme  $x + z$  et commenter le résultat
2. Le produit  $x \times z$  et commenter le résultat
3. La division  $w/x$  indiquant qu'il y a underflow

Solution :

1.  $x + z = 0.125 \times 10^6 + 0.437 \times 10^{12} = (0.000000125 + 0.437) 10^{12}$  (alignement)  
 $= 0.437000125 \times 10^{12} = 0.437 \times 10^{12}$  (standardisation avec  $m = 3$ ) =  $z$   
 Conclusion :  $x + z = z$  et pourtant  $x \neq 0$ !

<sup>1</sup>Rappelons que si  $\beta = 2$ , le nombre qui précède la virgule est un 1 qui ne sera pas stocké mais toujours pris en compte lors du décodage (bit caché), sauf si l'exposant est 0.

$$2. x \times z = 0.125 \times 10^6 \times 0.437 \times 10^{12} = 0.125 \times 0.437 \times 10^{18} = 0.054625 \times 10^{18} = 0.54625 \times 10^{17}$$

(normalisation) =  $0.546 \times 10^{17}$  (standardisation)

Conclusion : l'exposant est supérieur à l'exposant maximal utilisable  $E_M = 16$  donc le nombre  $x \times z$  est supérieur au plus grand nombre représentable ; il y a donc dépassement. Ceci se traduira par un message d'erreur affiché par le calculateur indiquant qu'il y a overflow.

$$3. w/z = (0.215 \times 10^{-10}) / (0.437 \times 10^{12}) = 0.215/0.437 \times 10^{-22} = 0.49199084668192219 \times 10^{-22} = 0.491 \times 10^{-22}$$

(standardisation)

Conclusion : l'exposant est inférieur à l'exposant minimal utilisable  $E_m$  et le quotient  $w/z$  est donc plus petit que le plus petit nombre positif représentable ( $1.100 \times 10^{-15}$ ) ; il y a donc dépassement. Ceci se traduira par un message d'erreur affiché par le calculateur indiquant qu'il y a underflow.

### Exercice 1.3

Soient trois réels  $x = 0.400 \times 10^0 = y, z = 0.100 \times 10^3$ . En utilisant le système de numération de l'exercice précédent pour le stockage de ces nombres, calculer les deux sommes  $(x + y) + z$  et  $x + (y + z)$ .

Solution :

$$(x+y)+z = 0.800 \times 10^0 + 0.100 \times 10^3 = 0.0008 \times 10^3 + 0.100 \times 10^3 = 0.001 \times 10^3 \text{ (standardisation)} + 0.100 \times 10^3 = 0.101 \times 10^3$$

$$y + z = 0.400 \times 10^0 + 0.100 \times 10^3 = 0.000400 \times 10^3 + 0.100 \times 10^3 = 0.100 \times 10^3 \text{ (standardisation) donc } x + (y + z) = 0.400 \times 10^0 + 0.100 \times 10^3 = 0.100 \times 10^3 = z$$

Conclusion : l'ordre dans lequel sont effectuées les opérations peut avoir une incidence sur le résultat final. Lorsqu'on additionne des nombres positifs, il faut commencer par les plus petits.

### Exercice 1.4

Soit le nombre  $387.62000_{10}$ .

- Calculer sa valeur en hexadécimal

Rappelons la correspondance entre chiffres hexadécimaux :

10	11	12	13	14	15
A	B	C	D	E	F

La partie entière est 387.

$$387_{10} = 24 \times 16 + 3 = (1 \times 16 + 8) \times 16 + 3 = 1 \times 16^2 + 8 \times 16^1 + 3 \times 16^0 = 183_{16}$$

La partie décimale est 0.62000.

$$0.62000 \times 16 = 9.92 \text{ dont la partie entière est } 9.$$

$$0.92 \times 16 = 14.72 \text{ dont la partie entière est } 14.$$

$$0.72 \times 16 = 11.52 \text{ dont la partie entière est } 11.$$

$$0.52 \times 16 = 8.32 \text{ dont la partie entière est } 8.$$

$$0.32 \times 16 = 5.12 \text{ dont la partie entière est } 5.$$

$$0.12 \times 16 = 1.92 \text{ dont la partie entière est } 1.$$

On s'arrête car on a atteint le nombre de chiffres décimaux fournis dans le nombre initial, plus un chiffre qui permet de connaître l'arrondi à effectuer.

On a donc  $0.62000 = \frac{9}{16} + \frac{14}{16^2} + \frac{11}{16^3} + \frac{8}{16^4} + \frac{5}{16^5} + \frac{0.12}{16^6}$  qui s'écrit en se limitant à 5 chiffres par arrondi :  $0,9EB85_{16}$ .

Donc  $387.62000_{10}$  se convertit en  $183,9EB85_{16}$ .

- Convertir la valeur hexadécimale en décimale.

Conversion de la partie entière :

$$183_{16} = 1 \times 16^2 + 8 \times 16^1 + 3 \times 16^0 = 387_{10}$$

Conversion de la partie décimale :

$$0,9EB85_{16} = \frac{9}{16} + \frac{14}{16^2} + \frac{11}{16^3} + \frac{8}{16^4} + \frac{5}{16^5} = 0,61999_{10} \text{ en se limitant aux 5 chiffres décimaux présents au départ (i.e. en gardant la même précision).}$$

Donc  $183,9EB85_{16}$  se convertit en  $387,61999_{10}$ .

- Calculer l'erreur absolue de représentation.

$$|\Delta x| = |m(x) - x| = |387.62000 - 387,61999| = 10^{-5}$$

4. Calculer l'erreur relative absolue de précision.

$$\eta(x) = \frac{|\Delta x|}{|x|} = \frac{10^{-5}}{387.62000} \simeq 2,58.10^{-8}$$

### Exercice 1.5

Considérons une machine décimale avec mantisse à 4 chiffres. Calculer l'erreur de représentation et l'erreur relative de représentation pour les nombres :

1.  $a = 9,023506$
2.  $b = 158,26$
3.  $c = 0,001588946$

### SOLUTION

On suppose que la machine transforme en notation normalisée décimale avec arrondi et non troncature.

1. Le nombre  $a$  est représenté en notation normalisée par  $0,9024.10^1$  donc  $\Delta a = 0,9024.10^1 - 9,023506 = -0,000494 = -4,94.10^{-4}$ .

$$\iota(a) = \frac{\Delta a}{m(a)} = \frac{-4.94 \times 10^{-4}}{0.9024 \times 10^1} = -5.4743 \times 10^{-5}$$

2. Le nombre  $b$  est représenté en notation normalisée par  $0,1583.10^3$  donc  $\Delta b = 0,1583.10^3 - 158,26 = 0,04 = 4.10^{-2}$

$$\iota(b) = \frac{\Delta b}{m(b)} = \frac{4 \times 10^{-2}}{0.1583 \times 10^3} = 2.5268 \times 10^{-4}$$

3. Le nombre  $c$  est représenté en notation normalisée par  $0,1589.10^{-2}$  donc  $\Delta c = 0.1589 \times 10^{-2} - 0.001588946 = 5.4 \times 10^{-8}$

$$\iota(c) = \frac{\Delta c}{m(c)} = \frac{5.4 \times 10^{-8}}{0.1589 \times 10^{-2}} = 3.3984 \times 10^{-5}$$

### Exercice 1.6

Soient les nombres  $a = 15,2750$ ,  $b = 358,937$  et  $c = 5233,618$ .

1. Convertir ces nombres en hexadécimal

Cas de  $a$ .

Partie entière :  $15_{10} = F_{16}$

Partie décimale :

$0,2750 \times 16 = 4,4$  dont la partie entière est 4

$0,4 \times 16 = 6,4$  dont la partie entière est 6

$0,4 \times 16 = 6,4$  dont la partie entière est 6...

Donc  $a = 15,2750_{10} = F,466..._{16}$ . Quand on convertit, on garde le même nombre de chiffres en hexadécimal qu'en décimal donc on a

$$15,2750_{10} = F,4666_{16}$$

Cas de  $b$ .

Partie entière :  $358 = 22 \times 16 + 6 = 1 \times 16^2 + 6 \times 16 + 6 = 166_{16}$

Partie décimale :

$0,937 \times 16 = 14,992$  dont la partie entière est 14 = E

$0,992 \times 16 = 15,872$  dont la partie entière est 15 = F

$0,872 \times 16 = 13,952$  dont la partie entière est 13 = D

Donc  $b = 358,937$  se convertit en  $166, EFD_{16}$

Cas de  $c$

Partie entière :  $5233 = 327 \times 16 + 1 = (20 \times 16 + 7) \times 16 + 1 = ((1 \times 16 + 4) \times 16 + 7) \times 16 + 1 = 1 \times 16^3 + 4 \times 16^2 + 7 \times 16 + 1 = 1471$

Partie décimale :

$0,618 \times 16 = 9,888$  dont la partie entière est 9

$0,888 \times 16 = 14,208$  dont la partie entière est 14 =  $E$

$0,208 \times 16 = 3,328$  dont la partie entière est 3

Donc  $c = 5233,618$  se convertit en  $1471,9E3_{16}$

2. Convertir ces nombres hexadécimaux en nombres décimaux avec exactitude de 8 (i.e. 8 chiffres significatifs).

Cas de  $a$ .

$F,4666_{16} = 15 + 4 \times 16^{-1} + 6 \times 16^{-2} + 6 \times 16^{-3} + 6 \times 16^{-4} = 15,274993_{10}$

Cas de  $b$ .

$166, EFD_{16} = 358 + 14 \times 16^{-1} + 15 \times 16^{-2} + 13 \times 16^{-3} = 358,93676_{10}$

Cas de  $c$ .

$1471,9E3_{16} = 5233 + 9 \times 16^{-1} + 14 \times 16^{-2} + 3 \times 16^{-3} = 5233,6179_{10}$

3. Calculer l'erreur relative de cette dernière conversion sous la forme  $x.xx \times 10^{-7}$

$\Delta a = m(a) - a = 15,274993 - 15,2750 = -7 \times 10^{-6}$

$\eta(a) = \frac{\Delta a}{a} = -\frac{7 \times 10^{-6}}{15,2750} \simeq -4,58 \times 10^{-7}$

$\Delta b = m(b) - b = 358,93676 - 358,937 = -2,4 \times 10^{-4}$

$\eta(b) = \frac{\Delta b}{b} = \frac{-2,4 \times 10^{-4}}{358,937} \simeq -6,69 \times 10^{-7}$

$\Delta c = m(c) - c = 5233,6179 - 5233,618 = -1 \times 10^{-4}$

$\eta(c) = \frac{\Delta c}{c} = \frac{-1 \times 10^{-4}}{5233,618} = -1,911 \times 10^{-8} \simeq -0,19 \times 10^{-7}$

### Exercice 1.7

Rappel des données :

-  $x = s.m.b^e$  avec  $\frac{1}{b} \leq m < 1$ , où :

- \*  $s$  est le signe
- \*  $m$  est la mantisse sans limitation de bits
- \*  $b$  est la base
- \*  $e$  est l'exposant, entier.

- la représentation de  $x$  en machine est  $m(x) = s.M.b^E$  avec  $m(x) \in M( )$ , où :

- \*  $M$  est la mantisse limitée à  $p$  digits
- \*  $E$  est l'exposant, limité à  $q$  digits.

Le codage en nombres flottants requiert ainsi  $N = p + q + 1$  digits.

On considère  $b = 2$ , on travaille en binaire.

Le problème consiste à calculer l'erreur de représentation pour différentes opérations arithmétiques.

1. Cas de l'affectation

L'erreur est donnée par

$$\begin{aligned} e &= x - m(x) \\ &= s.m.2^e - s.M.2^E \\ &= s.2^E(m.2^{e-E} - M) \end{aligned}$$

Il peut y avoir troncature de l'exposant donc on a toujours  $E \leq e$ , soit  $e - E \geq 0$  donc  $2^{e-E} \geq 1$ . Dans ce cas, l'exposant étant toujours supposé positif, on obtiendra un nombre d'exposant plus faible que

$x$ , l'erreur sera donc plus importante que celle sans troncature d'exposant, mais impossible à minorer. On parle dans ce cas de dépassement de capacité.

**On suppose désormais qu'il n'y a pas de troncature sur l'exposant.**

L'erreur qui se produit sur la mantisse est due à la troncature appliquée au  $(p+1)^{ième}$  digit, ou à l'arrondi effectué sur le  $p^{ième}$  digit, elle peut donc se formaliser comme

$$e_m = s.\alpha.2^E.2^{-p}$$

où : -  $\alpha \in [0, 1[$  s'il y a troncature

-  $\alpha \in [-0.5, 0.5[$  s'il y a arrondi.

En supposant qu'il n'y a pas d'approximation sur l'exposant et en utilisant la notation  $\Delta(x)$  pour l'erreur de représentation, on obtient :

$$m(x) = x - s.\Delta(x).2^{E-p}$$

## 2. Erreur de l'opération d'addition

Soient deux nombres  $x_1$  et  $x_2$  dont les représentations machine sont respectivement  $m(x_1)$  et  $m(x_2)$ . La somme des nombres en machine est calculée par :

$$\begin{aligned} m[m(x_1) + m(x_2)] &= [x_1 - s_1.\Delta(x_1).2^{E_1-p} + x_2 - s_2.\Delta(x_2).2^{E_2-p}] - s_s.\Delta(x_s).2^{E-p} \\ &= x_1 + x_2 - s_1.\Delta(x_1).2^{E_1-p} - s_2.\Delta(x_2).2^{E_2-p} - s_s.\Delta(x_s).2^{E-p} \end{aligned}$$

Remarque : L'erreur globale est l'accumulation de chacune des erreurs de représentation.

## 3. Erreur de l'opération de soustraction

Comme précédemment pour l'addition, on obtient pour la différence :

$$\begin{aligned} m[m(x_1) - m(x_2)] &= [x_1 - s_1.\Delta(x_1).2^{E_1-p} - x_2 + s_2.\Delta(x_2).2^{E_2-p}] - s_s.\Delta(x_s).2^{E-p} \\ &= x_1 - x_2 - s_1.\Delta(x_1).2^{E_1-p} + s_2.\Delta(x_2).2^{E_2-p} - s_s.\Delta(x_s).2^{E-p} \end{aligned}$$

Remarque : L'erreur se comporte comme pour la somme.

## 4. Erreur de l'opération de multiplication

En réutilisant les mêmes notations, on obtient pour  $x_1 \times x_2$  :

$$\begin{aligned} m(m(x_1).m(x_2)) &= (x_1 - s_1.\Delta(x_1).2^{E_1-p})(x_2 - s_2.\Delta(x_2).2^{E_2-p}) - s_m.\Delta(x_m).2^{E-p} \\ &= x_1x_2 - s_1.x_2.\Delta(x_1).2^{E_1-p} - s_2.x_1.\Delta(x_2).2^{E_2-p} \\ &\quad + s_1.\Delta(x_1).2^{E_1-p}s_2.\Delta(x_2).2^{E_2-p} - s_m.\Delta(x_m).2^{E-p} \end{aligned}$$

En négligeant le terme d'ordre 2 en  $\Delta(x_1).\Delta(x_2)$ , on obtient :

$$m(m(x_1).m(x_2)) = x_1x_2 - s_1.x_2.\Delta(x_1).2^{E_1-p} - s_2.x_1.\Delta(x_2).2^{E_2-p} - s_m.\Delta(x_m).2^{E-p}$$

## 5. Erreur de l'opération de division

Pour  $x_1/x_2$  il vient :

$$\begin{aligned} m(m(x_1)/m(x_2)) &= (x_1 - s_1.\Delta(x_1).2^{E_1-p}) / (x_2 - s_2.\Delta(x_2).2^{E_2-p}) - s_d.\Delta(x_d).2^{E-p} \\ &= x_1 / [x_2 - s_2.\Delta(x_2).2^{E_2-p}] - s_1.\Delta(x_1).2^{E_1-p} / [x_2 - s_2.\Delta(x_2).2^{E_2-p}] \\ &\quad - s_d.\Delta(x_d).2^{E-p} \end{aligned}$$

Utilisons les DL au voisinage de zéro : si on considère deux nombres  $x$  et  $\alpha$  tels que  $\alpha \ll x$ , on a

$$\begin{aligned} (x + \alpha)^{-1} &= \left[ x \left( 1 + \frac{\alpha}{x} \right) \right]^{-1} \\ &= x^{-1} (1 + \varepsilon)^{-1} \end{aligned}$$

où  $\varepsilon = \frac{\alpha}{x}$  est petit devant 1, et on sait que  $(1 + \varepsilon)^{-1} \simeq 1 - \varepsilon$ . On en déduit que

$$(x + \alpha)^{-1} \simeq x^{-1} \left( 1 - \frac{\alpha}{x} \right) = x^{-1} - \alpha x^{-2}$$

Appliquons ce résultat au calcul de  $x_1/[x_2 - s_2 \cdot \Delta(x_2) \cdot 2^{E_2-p}]$  :

$$\begin{aligned} x_1/[x_2 - s_2 \cdot \Delta(x_2) \cdot 2^{E_2-p}] &= x_1 \cdot [x_2^{-1} + s_2 \cdot \Delta(x_2) \cdot 2^{E_2-p} \cdot x_2^{-2}] \\ &\simeq x_1 \cdot x_2^{-1} + s_2 \cdot x_1 \cdot \Delta(x_2) \cdot 2^{E_2-p} \cdot x_2^{-2} \end{aligned}$$

De même pour  $s_1 \cdot \Delta(x_1) \cdot 2^{E_1-p}/[x_2 - s_2 \cdot \Delta(x_2) \cdot 2^{E_2-p}]$  :

$$[x_2 - s_2 \cdot \Delta(x_2) \cdot 2^{E_2-p}]^{-1} = x_2^{-1} + s_2 \cdot \Delta(x_2) \cdot 2^{E_2-p} x_2^{-2}$$

d'où

$$\begin{aligned} s_1 \cdot \Delta(x_1) \cdot 2^{E_1-p}/[x_2 - s_2 \cdot \Delta(x_2) \cdot 2^{E_2-p}] &= s_1 \cdot \Delta(x_1) \cdot 2^{E_1-p} \cdot x_2^{-1} + s_1 \cdot s_2 \cdot \Delta(x_1) \cdot \Delta(x_2) \cdot 2^{E_1-p} 2^{E_2-p} x_2^{-2} \\ &\simeq s_1 \cdot \Delta(x_1) \cdot 2^{E_1-p} \cdot x_2^{-1} \end{aligned}$$

en négligeant le terme d'ordre 2. Soit :

$$\begin{aligned} m(m(x_1)/m(x_2)) &= x_1 \cdot x_2^{-1} - s_1 \cdot \Delta(x_1) \cdot 2^{E_1-p} \cdot x_2^{-1} + s_2 \cdot x_1 \cdot \Delta(x_2) \cdot 2^{E_2-p} \cdot x_2^{-2} \\ &\quad - s_d \cdot \Delta(x_d) \cdot 2^{E-p} \end{aligned}$$

Remarque : Au cas où le réel  $x_2$  est petit et le réel  $x_1$  grand, la quantité  $s_2 \cdot x_1 \cdot \Delta(x_2) \cdot 2^{E_2-p} \cdot x_2^{-2}$  peut devenir importante et perturber la valeur obtenue. Il faut donc éviter d'effectuer de telles divisions.