



Correction du TP1 : Erreur due à la conversion en binaire

1. On a $x = 0.1_{10}$. Le nombre en binaire obtenu est :

$$y_2 = 0,00011\dots_2$$

2. La valeur décimale de y est obtenue par la fonction `function [y]=BinaireDecimal(x)` à partir de l'initialisation de x réalisée par la fonction `function [x]=Initx()`. La variable x est le vecteur des décimales de 0.1 écrit en binaire. Le programme principal qui vous est fourni renvoie deux valeurs de z : l'une sans format d'écriture, l'autre avec. Comparez les résultats obtenus pour vous convaincre de l'utilité de l'écriture avec format.

3. Une simple boucle suffit pour calculer les valeurs de `som` et `som1`, sans oublier une initialisation de la variable `som` (resp. `som1`) à 0. En effet certains compilateurs n'initialisant pas à zéro les variables lors de leur déclaration (qui n'existe pas dans Scilab), il est toujours préférable d'initialiser à zéro.

Les résultats donnent :

```
valeur de som : 9.99999999999998670000e-001  
valeur de som1 : 9.9999999999999890000e-001  
différence entre som et som1 : -1.22124532708767220000e-015
```

On observe une différence entre les deux valeurs qui correspond à :

$$\begin{aligned} som - som1 &= 10z - 10x \\ &= 10(z - x) \simeq -1.2 \cdot 10^{-15} \end{aligned}$$

Si on appelle f l'application qui convertit de décimal en binaire, et par suite sa réciproque f^{-1} l'application qui convertit de binaire en décimal, on devrait avoir :

$$z = (f^{-1} \circ f)(x) = x$$

En fait $z \neq x$ car la conversion de décimal en binaire est assortie d'une troncature de la valeur exacte $0,00011\dots_2$ en $0, \underbrace{000110011\dots001}_{\text{sur 52 bits}}$ donc en convertissant on a $m(y) < y$. Ensuite on applique f^{-1} qui est monotone croissante puisque f l'est aussi, et donc

$$z = f^{-1}[m(y)] < f^{-1}(y) = x$$

ce qui correspond bien au fait que l'on observe que $som - som1 = 10(z - x) < 0$. On peut même préciser qu'ici

$$z - x = -1.2 \cdot 10^{-16}$$