

Étude du biais et de la variance de l'arithmétique stochastique

EL-Mehdi EL ARAR

el-mehdi.el-arar@uvsq.fr

Laboratoire D'Informatique Parallélisme Réseaux Algorithmes
Distribués (LI – PARAD)



Interflop, 06 Octobre 2021

Plan

- Introduction.
- Étude du biais de l'arithmétique stochastique sur la méthode d'intégration des rectangles.
- Étude de la variance d'un mode d'arrondi stochastique.

Introduction

- Estimation de l'erreur.
- Étude de la distribution en sortie.
 - ▶ Moment du premier ordre : Comparaison de deux modes d'arrondi stochastiques.
 - ▶ Moment du deuxième ordre : Produit scalaire, système linéaire.

Notations et terminologie

Définition 1.1.

Soient $\mathcal{F} \subset \mathbb{R}$ l'ensemble des représentants et $x \in \mathbb{R}$. On définit :

- $fl[x] = x(1 + \delta)$, où δ est l'erreur relative vérifie $|\delta| < u = \frac{1}{2}\beta^{1-p}$.
- L'arrondi vers le haut $\lceil x \rceil$ et l'arrondi vers le bas $\lfloor x \rfloor$ par :

$$\lceil x \rceil = \min\{y \in \mathcal{F} : y \geq x\}, \quad \lfloor x \rfloor = \max\{y \in \mathcal{F} : y \leq x\}.$$

- $\varepsilon(x) = \beta^{e-p} = \lceil x \rceil - \lfloor x \rfloor$ où β est la base, e est l'exposant de x et p est la précision machine.
- $\theta(x) = \frac{x - \lfloor x \rfloor}{\lceil x \rceil - \lfloor x \rfloor}$ est la fraction arrondie de $\varepsilon(x)$.

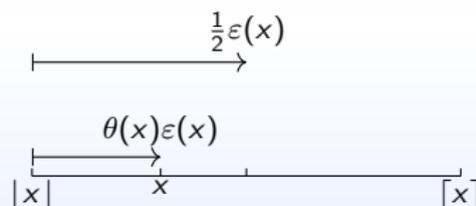


FIGURE – $\theta(x)$ est la fraction arrondie de $\varepsilon(x)$.

Définition 1.2.

On définit les deux modes d'arrondi stochastiques :

$$\begin{aligned} \mathit{random_nearness} : fl(x) &= \begin{cases} \lceil x \rceil & \text{avec probabilité } \theta(x), \\ \lfloor x \rfloor & \text{avec probabilité } 1 - \theta(x). \end{cases} \\ \mathit{random_up_or_down} : fl(x) &= \begin{cases} \lceil x \rceil & \text{avec probabilité } 1/2, \\ \lfloor x \rfloor & \text{avec probabilité } 1/2. \end{cases} \end{aligned}$$

D. S. Parker. *Monte Carlo Arithmetic : exploiting randomness in floating-point arithmetic*. University of California (Los Angeles). Computer Science Department, 1997.

Propriété 1.1.

Soit $x \in \mathbb{R}$ et $x \notin \mathcal{F}$. On note X la variable aléatoire de la distribution du résultat obtenu en arrondissant x par l'un des deux modes d'arrondi, i.e.,

$$X = \mathbf{random_round}(x) = \mathbf{round}(x + \beta^{e_x - p} \xi),$$

Le mode **random_nearness** est réalisé pour ξ suivant une loi uniforme sur $(-\frac{1}{2}; \frac{1}{2})$. Ce mode est sans biais, et on a :

$$E[X] = \theta(x)\lceil x \rceil + (1 - \theta(x))\lfloor x \rfloor = x.$$

Le mode **random_up_or_down** est réalisé pour ξ suivant une loi uniforme sur $(-\theta(x); 1 - \theta(x))$. Ce mode est biaisé, et on a :

$$E[X] = x + \varepsilon(x)\left(\frac{1}{2} - \theta(x)\right).$$

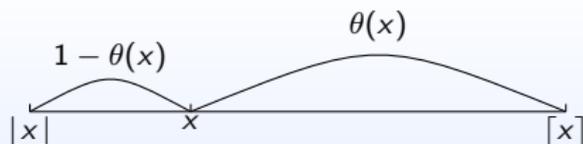


FIGURE – Random_nearness.



FIGURE – Random_up_or_down.

Intégration de la fonction constante

On s'intéresse au calcul de $\int_0^1 1 dx = 1$ par la méthode des rectangles.

```
float dx = 1/N;  
float s = 0.0;  
for (int i=0; i < N; i++) {  
    s += dx*1;  
}  
return s;
```

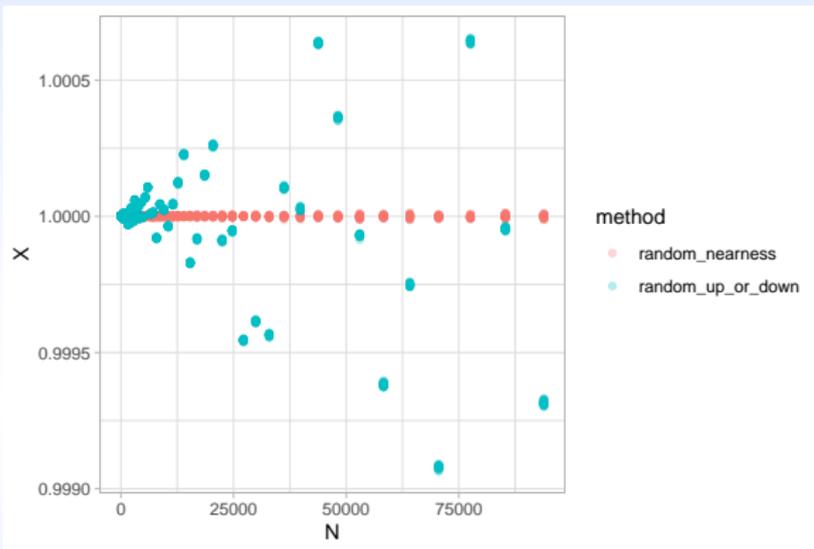


FIGURE – 30 échantillons d'arrondi stochastique de $\int_0^1 1 dx$.

Lemme 2.1.

La distribution X est obtenu en addition N fois le pas dx . On note S_k la variable aléatoire de la somme partielle à l'étape $0 \leq k \leq N - 1$ et s_k la somme partielle exacte (la valeur mathématique). Avec $S_{N-1} = X$. On a :

$$E[S_k - s_k] = \varepsilon(s_k) \left(\frac{1}{2} - \theta(s_k) \right),$$

et

$$|E[S_k - s_k]| < \frac{1}{2} \varepsilon(s_k).$$

Lemme 2.1.

La distribution X est obtenu en addition N fois le pas dx . On note S_k la variable aléatoire de la somme partielle à l'étape $0 \leq k \leq N - 1$ et s_k la somme partielle exacte (la valeur mathématique). Avec $S_{N-1} = X$. On a :

$$E[S_k - s_k] = \varepsilon(s_k) \left(\frac{1}{2} - \theta(s_k) \right),$$

et

$$|E[S_k - s_k]| < \frac{1}{2} \varepsilon(s_k).$$

Remarque 2.1.

- $\varepsilon(s_k)$ est constant entre deux puissances consécutives de la base, en particulier pour la base deux, à chaque changement de puissance de deux, il est doublé.

Lemme 2.1.

La distribution X est obtenu en addition N fois le pas dx . On note S_k la variable aléatoire de la somme partielle à l'étape $0 \leq k \leq N - 1$ et s_k la somme partielle exacte (la valeur mathématique). Avec $S_{N-1} = X$. On a :

$$E[S_k - s_k] = \varepsilon(s_k) \left(\frac{1}{2} - \theta(s_k) \right),$$

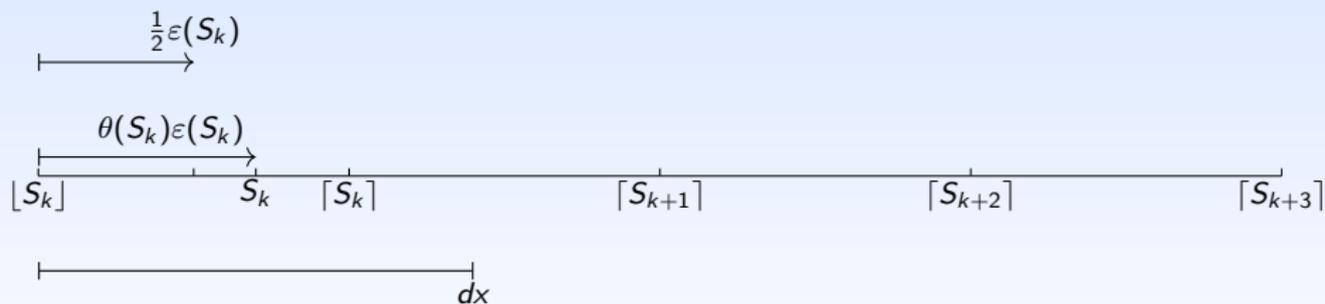
et

$$|E[S_k - s_k]| < \frac{1}{2} \varepsilon(s_k).$$

Remarque 2.1.

- $\varepsilon(s_k)$ est constant entre deux puissances consécutives de la base, en particulier pour la base deux, à chaque changement de puissance de deux, il est doublé.
- Sauf la première valeur, $\theta(s_k)$ est constante entre deux puissances consécutives de la base.

Le schéma suivant explique la remarque précédente :



Le schéma suivant explique la remarque précédente :

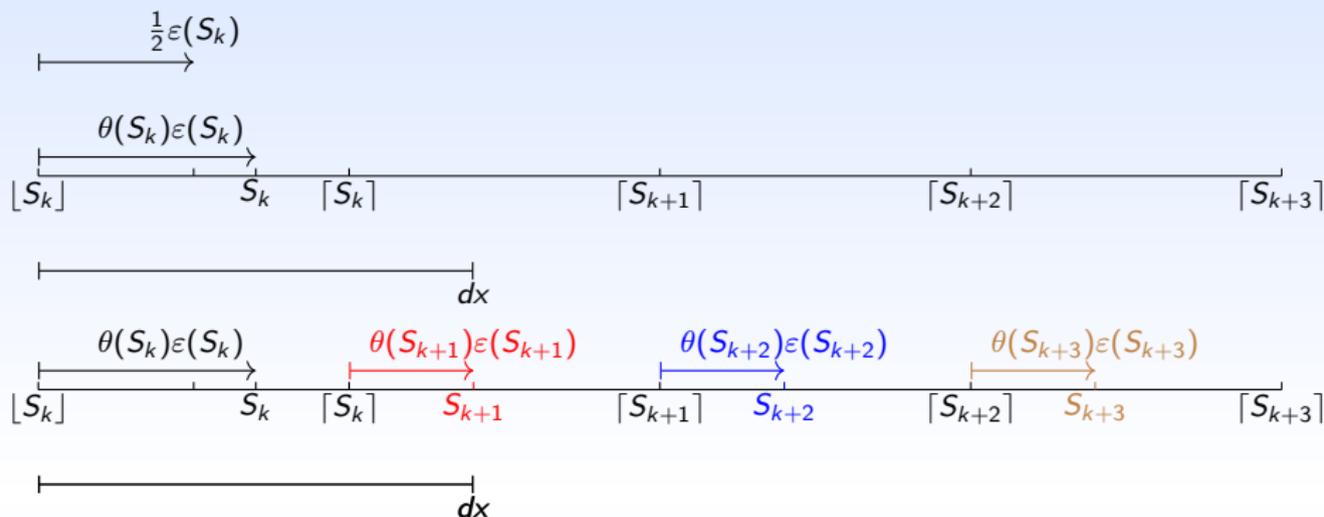


FIGURE – θ est constante entre deux puissance de deux successives.

Le schéma suivant explique la remarque précédente :

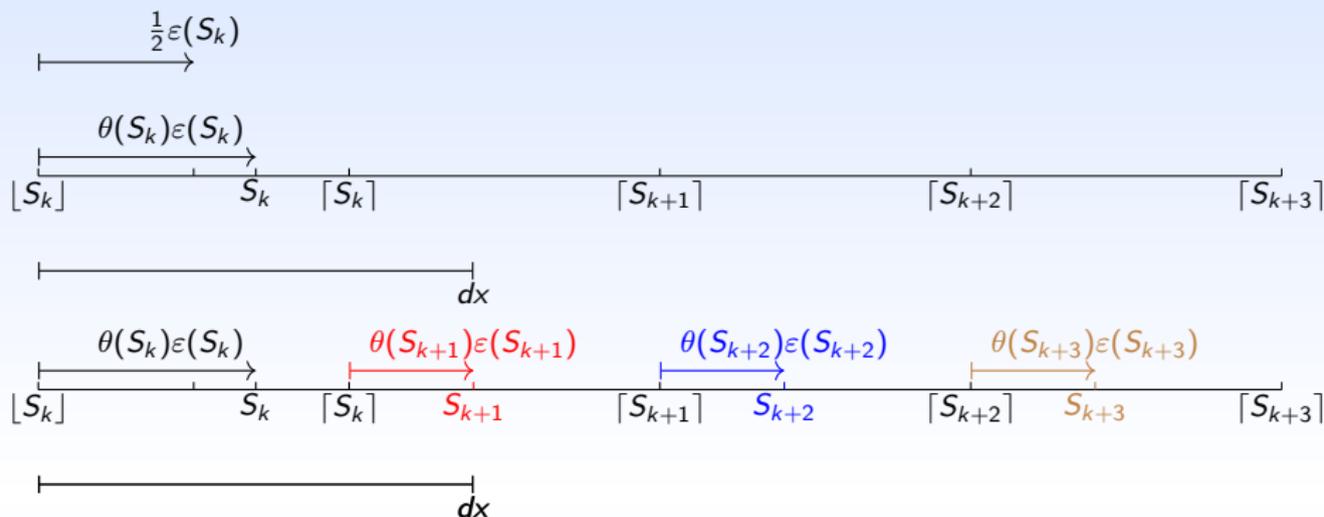


FIGURE – θ est constante entre deux puissance de deux successives.

Conclusion

- L'origine du biais.
- Le mode **nearness** se comporte mieux.

Étude de la variance

- M. P. Connolly, N. J. Higham and Théo Mary. Stochastic rounding and its probabilistic backward error analysis.
- Mean independant.

Définition 3.1.

On dit qu'une variable aléatoire Y est "mean independent" par rapport à une variable aléatoire X si et seulement si : pour tout x tel que la probabilité que $X = x$ est non nulle on a $E(Y/X = x) = E(Y)$ et on écrit $E(Y/X) = E(Y)$.

Des variables aléatoires $\delta_1, \delta_2, \dots$ sont "mean independent" si $E(\delta_k/\delta_1, \dots, \delta_{k-1}) = E(\delta_k)$ pour tout k .

Propriété 3.1.

Soit $\delta_1, \delta_2, \dots$, dans cet ordre obtenu dans un calcul itératif par le mode **nearness**,

- Les δ_k sont des variables aléatoires centrées.
- Pour tout k on a $E(\delta_k/\delta_1, \dots, \delta_{k-1}) = E(\delta_k) = 0$.

Théorème 3.1.

Soient $y = a^\top b$, avec $a, b \in \mathbb{R}^n$, Y la variable aléatoire de la distribution du résultat obtenu en arrondissant y par le mode *nearness*. Alors

$$V(Y) \leq y^2 (K^2(1+u)^n - 1) = y^2((K^2 - 1) + nuK^2) + O(u^2),$$

avec K est le conditionnement de $y = \sum_{i=1}^n a_i b_i$.

Idée de la preuve

Utiliser le résultat obtenu par N. J. Higham,

$$Y = \sum_{i=1}^n a_i b_i \prod_{k=1}^n (1 + \delta_{k,i}).$$

Théorème 3.2.

On considère le système linéaire suivant $Ax = b$, avec $b \in \mathbb{R}^n$ et $A \in \mathbb{R}^{n \times n}$ est une matrice inversible triangulaire inférieure. Le système est résolu par substitution avec le mode **nearness**, la solution X satisfait pour tout $i = 1 : n$

$$V(X_i) \leq x_i^2 \left[(1 + u)^{i+1} \left(K_i^2 + V\left(\frac{\sum_{j=1}^{i-1} |a_{ij}| X_j}{a_{ii} X_i}\right) \right) - 1 \right],$$

avec K_i est le conditionnement de $a_{ii} x_i = b_i - \sum_{j=1}^{i-1} a_{ij} x_j$.

Nombre de chiffres significatifs

Théorème 3.3.

Soit $y = a^\top b$, avec $a, b \in \mathbb{R}^n$, en appliquant le mode *nearness* on a

$$\mathbb{P}\left(\frac{|Y - y|}{|y|} \leq 2^{-\alpha_\theta}\right) \geq \theta,$$

avec $0 < \theta < 1$ et $\alpha_\theta = -\log_2\left(K \exp\left(u\sqrt{2n \ln \frac{2}{1-\theta}}\right) - 1\right)$ est le nombre des chiffres significatifs de $\frac{|Y-y|}{|y|}$ avec probabilité θ .

Idée de la preuve

- Les martingales.
- Inégalité de Azuma-Hoeffding

n =1000, verificarlo precision = 24bits, mode = rr

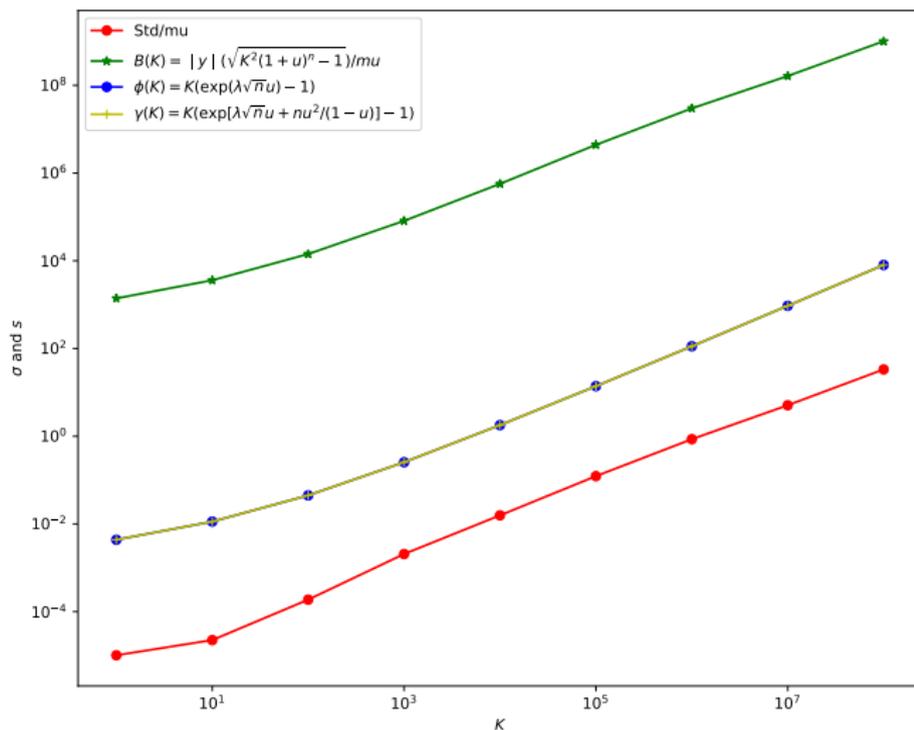


FIGURE – Le nombre de chiffres significatifs pour le produit scalaire avec 29 exécutions et $\lambda = 1.6651$.

Conclusion

Étapes réalisées

- Étude du biais.
- Borne de la variance.
- Borne probabiliste.

Conclusion

Étapes réalisées

- Étude du biais.
- Borne de la variance.
- Borne probabiliste.

Étape suivante

- Les effets des opérations élémentaires sur l'espérance et la variance.