



THE GERMAN TANK PROBLEM



Devoir Maison n°7

German Tank Problem
Solution

On considère dans tout le problème un n -échantillon (X_1, \dots, X_n) de la loi $\mathcal{U}([1, N])$ et on commence par poser

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i.$$

(1) On commence par rappeler que l'espérance et la variance de chaque variable de l'échantillon vaut

$$E(X_i) = \frac{N+1}{2}, \quad V(X_i) = \frac{N^2-1}{12}$$

ainsi, par linéarité de l'espérance

$$E(\bar{X}_n) = \frac{E(X_1) + \dots + E(X_n)}{n} = E(X_1) = \frac{N+1}{2}$$

ce qui n'est bien évidemment pas égal à N . Mais, en posant

$$T_n = 2\bar{X}_n - 1 = \frac{2}{n} (X_1 + \dots + X_n) - 1,$$

la linéarité de l'espérance garantit que $E(T_n) = N$ et T_n est, lui, un estimateur sans biais de N .

(2) Le risque quadratique est égal à la variance lorsque l'estimateur est sans biais. Ainsi,

$$\begin{aligned} r(T_n) &= V(T_n) = V\left(\frac{2}{n}(X_1 + \dots + X_n) - 1\right) \\ &= \frac{4}{n^2} V(X_1 + \dots + X_n) \\ &= \frac{4}{n^2} (V(X_1) + \dots + V(X_n)) \quad \text{par indépendance des } X_i \\ &= \frac{N^2-1}{3n} \end{aligned}$$

En particulier, on a bien $r(T_n) \rightarrow 0$ lorsque $n \rightarrow +\infty$, ce qui permet d'affirmer que T_n est un estimateur convergent d'après un résultat du cours (qui lui-même découle de l'inégalité de Bienayme-Tchebychev).

(3) **Application numérique & SciLab.**

(a) Il suffit d'utiliser la commande `mean()` qui renvoie la moyenne des composantes d'une liste ou d'un vecteur.

```
function y=T(X)
    y=2*mean(X)-1
endfunction
```

(b) On observe

$X = [8, 322, 15, 135, 69]$

La fonction précédente renvoie, pour cet échantillon, une estimation $N \simeq T_5 = 219$. Or on sait qu'il y a au moins 322 tanks. Cet estimateur ne semble pas très pertinent avec un petit échantillon...

(c) Cette fois on demande à ce que l'échantillon X soit simulé à l'intérieur de la fonction au sein de laquelle on utilise notre fonction T précédente.

```
function y=T_moy(N,n)
    Y=zeros(1,n)
    for k=1:n
        X=grand(1, 1000, 'uin', 1, N)
        Y(k)=T(X)
    end
    y=mean(Y)
endfunction
```

Regardons ce que renvoie donc cette fonction pour $N = 1000$ avec $n = 20$ puis $n = 100$.

```
--> T_moy(1000, 20)
ans =

    997.81770

--> T_moy(1000, 100)
ans =

    998.20482
```

L'espérance théorique étant $N = 1000$, ce n'est pas si mal.

(4) C'est une question classique. On rappelle que, pour chaque $i \in \llbracket 1; n \rrbracket$, on a, pour $k \in \mathbb{N}$,

$$P(X_i \leq k) = \begin{cases} 0, & \text{si } k = 0 \\ \frac{k}{N}, & \text{si } 1 \leq k \leq N \\ 1, & \text{si } k > N \end{cases}$$

Étant clair que $P(M_n \leq k) = 0$ si $k = 0$ et $P(M_n \leq k) = 1$ si $k > N$, on calcule pour $1 \leq k \leq N$.

$$\begin{aligned} P(M_n \leq k) &= P(\max(X_1, \dots, X_n) \leq k) \\ &= P([X_1 \leq k] \cap [X_2 \leq k] \cap \dots \cap [X_n \leq k]) \\ &= P(X_1 \leq k) \times P(X_2 \leq k) \times \dots \times P(X_n \leq k) && \text{par indépendance des } X_i \\ &= \left(\frac{k}{N}\right)^n \end{aligned}$$

(5) Soit Y un v.a à valeurs dans $\llbracket 1; N \rrbracket$. La variable étant finie, elle admet une espérance qu'on va calculer en utilisant l'égalité ultra-classique suivante

$$[Y = k] \cup [Y > k] = [Y > k - 1]$$

et donc, par incompatibilité,

$$P(Y = k) = P(Y > k - 1) - P(Y > k).$$

Il suit que

$$\begin{aligned}
 E(Y) &= \sum_{k=1}^N kP(Y = k) = \sum_{k=1}^N k(P(Y > k-1) - P(Y > k)) \\
 &= \sum_{k=1}^N kP(Y > k-1) - \sum_{k=1}^N kP(Y > k) \\
 &= \sum_{k=0}^{N-1} (k+1)P(Y > k) - \sum_{k=1}^N kP(Y > k) \\
 &= \sum_{k=0}^{N-1} kP(Y > k) + \sum_{k=0}^{N-1} P(Y > k) - \sum_{k=1}^N kP(Y > k) \\
 &= \sum_{k=0}^{N-1} P(Y > k) - NP(Y > N) \\
 &= \sum_{k=0}^{N-1} P(Y > k)
 \end{aligned}$$

car $(Y > N) = 0$ vu que $Y(\Omega) = \llbracket 1; N \rrbracket$. C'est bien la formule demandée.

- (6) Vu que $M_n(\Omega) = \llbracket 1; N \rrbracket$, on peut lui appliquer le résultat précédent pour le calcul de son espérance:

$$\begin{aligned}
 E(M_n) &= \sum_{k=0}^{N-1} P(M_n > k) = \sum_{k=0}^{N-1} (1 - P(M_n \leq k)) \\
 &= \sum_{k=0}^{N-1} 1 - \sum_{k=0}^{N-1} \left(\frac{k}{N}\right)^n \\
 &= N - \sum_{k=0}^{N-1} \left(\frac{k}{N}\right)^n,
 \end{aligned}$$

comme attendu.

- (7) Soit $k \in \llbracket 0; N-1 \rrbracket$. La fonction $t \mapsto t^n$ est croissante sur $[k/N; (k+1)/N]$ et donc, pour tout $t \in [k/N; (k+1)/N]$, on a

$$t^n \geq \left(\frac{k}{N}\right)^n \geq 0$$

puis, par croissance de l'intégrale

$$\int_{k/N}^{(k+1)/N} t^n dt \geq \int_{k/N}^{(k+1)/N} \left(\frac{k}{N}\right)^n dt = \frac{1}{N} \times \left(\frac{k}{N}\right)^n.$$

On a bien

$$0 \leq \left(\frac{k}{N}\right)^n \leq N \int_{k/N}^{(k+1)/N} t^n dt.$$

- (8) On somme, pour k de 0 à $N-1$, et on a

$$0 \leq \sum_{k=0}^{N-1} \left(\frac{k}{N}\right)^n \leq \sum_{k=0}^{N-1} N \int_{k/N}^{(k+1)/N} t^n dt = N \int_0^1 t^n dt = \frac{N}{n+1}.$$

En appliquant le résultat de la Question (6), on a bien

$$N - \frac{N}{n+1} \leq E(M_n) \leq N.$$

Le théorème des gendarmes donne alors

$$\lim_{n \rightarrow +\infty} E(M_n) = N$$

ce qui est bien la définition d'un estimateur de N asymptotiquement sans biais.

On introduit

$$\tilde{M}_n = M_n + (m_n - 1), \quad \text{où} \quad m_n = \min(X_1, \dots, X_n).$$

(9) On commence par écrire, pour $k \in \llbracket 0, N-1 \rrbracket$, que

$$\begin{aligned} P(m_n > k) &= P(\min(X_1, \dots, X_n) > k) \\ &= P([X_1 > k] \cap \dots \cap [X_n > k]) \\ &= P(X_1 > k) \times \dots \times P(X_n > k) && \text{par indépendance des } X_i \\ &= \left(\frac{N-k}{N}\right)^n \end{aligned}$$

et donc

$$E(m_n) = \sum_{k=0}^{N-1} P(m_n > k) = \sum_{k=0}^{N-1} \left(\frac{N-k}{N}\right)^n = \sum_{j=1}^N \left(\frac{j}{N}\right)^n.$$

(10) Par linéarité de l'espérance,

$$E(\tilde{M}_n) = E(M_n) + E(m_n) - 1 = N - \sum_{k=0}^{N-1} \left(\frac{k}{N}\right)^n + \sum_{j=1}^N \left(\frac{j}{N}\right)^n - 1 = N,$$

et \tilde{M}_n est bien un estimateur sans biais de N .

(11) Avec

$\mathbf{X} = [14, 44, 50, 101, 117, 127, 134, 139, 165, 188, 192, 201, 204, 215, 234, 243, 244, 253, 269, 269, 282, 287, 288, 322, 345]$

La commande $\max(\mathbf{X}) + \min(\mathbf{X}) - 1$ renvoie une estimation $N \sim \tilde{M}_{25} = 358$, ce qui est déjà plus grand que la valeur maximale de l'échantillon et n'a donc pas le défaut précédent.

(12) **Comparaison.**

La fonction proposée renvoie les moyennes de chacun des trois estimateurs T_n , M_n et \tilde{M}_n , sur 1000 échantillons de taille n de la loi $\mathcal{U}[\llbracket 1; N \rrbracket]$.

On prend ensuite $N = 1000$.

On regarde comment évolue chaque estimateur en fonction de n .

Pour cela on représente graphiquement cette évolution en fonction de n en prenant des valeurs de n entre 10 et 200 avec un pas de 10 (donc $n = 10, 20, 30, \dots, 100, 110, \dots, 200$).

Les losanges correspondent à l'estimateur T_n , les + à l'estimateur M_n et les \times à \tilde{M}_n . Il est clair que ce sont les \times qui ont des valeurs au plus proche de $N = 1000$ et on peut penser raisonnablement que \tilde{M}_n est le meilleur des trois estimateurs.