

# Promenades aléatoires $\pm 1$

Gérard LETAC,

département Informatique de l'Institut Universitaire  
de Technologie de Clermont-Ferrand

Nous voudrions montrer ici, à travers quelques exemples, combien le modèle probabiliste d'une promenade aléatoire  $\pm 1$  est riche et comment il rend service dans des questions qui à première vue en paraissent fort éloignées.

Considérons un point P mobile sur la droite Z des entiers relatifs. A l'instant  $k$  (entier  $>0$ ), la position de P est repérée par l'entier  $S_k$  de Z. On suppose  $S_0 = 0$ . On jette une pièce de monnaie entre les instants  $k$  et  $k+1$ . Si c'est *face* on pose  $S_{k+1} = S_k + 1$ , sinon  $S_{k+1} = S_k - 1$ . En d'autres termes  $S_k = X_1 + \dots + X_k$ , où  $X_1, \dots, X_k$  sont des variables aléatoires indépendantes telles que  $\Pr(X_k = +1) = \Pr(X_k = -1) = \frac{1}{2}$ . Par exemple :

$k$ .....	1	2	3	4	5	6	7
Pièce .....	pile	pile	face	face	face	pile	face
$X_k$ .....	-1	-1	1	1	1	-1	1
$S_k$ .....	-1	-2	-1	0	1	0	1




FIG. 1.

### 1. Une réussite.

Dans un jeu de 52 cartes, Pierre tire une carte et, avant de la regarder, devine sa couleur : rouge ou noire. Il marque un point s'il a deviné juste. Il recommence avec le paquet de 51 cartes restantes, et ainsi de suite jusqu'à épuisement du paquet. Paul lui donne 1 franc par point marqué. Combien d'argent Pierre doit-il donner à Paul au début du jeu pour que celui-ci soit équitable? Si vous préférez, quelle est la moyenne  $E(N)$  — ou espérance mathématique — du nombre  $N$  de points marqués?

Contrairement à ce qu'on pourrait penser à première vue, 26 n'est pas  $E(N)$ ; c'est même le salaire minimum garanti de Pierre : qu'il lui suffise d'annoncer 52 fois rouge. Il y a mieux : Pierre peut annoncer rouge si c'est la couleur la mieux représentée dans le paquet (ou vice versa) et annoncer au hasard s'il y a égalité. (Il n'est pas difficile de vérifier que cette méthode maximise  $E(N)$ .)

Introduisons les variables aléatoires  $Y_1, Y_2, \dots, Y_{52}$  où  $Y_k = +1$  si la  $k^{\text{ème}}$  carte tirée est rouge et  $Y_k = -1$  sinon, et posons  $Z_k = Y_1 + \dots + Y_k$ ,  $Z_0 = 0$ . Le nombre de points obtenus est donc 26 plus le nombre de fois où Pierre a bien deviné quand il choisissait au hasard. Soit  $K$  le nombre de fois où il choisissait au hasard :

la moyenne du nombre de points est donc  $26 + \frac{1}{2} E(K)$ .

Il est clair que  $K$  est égal au nombre de zéros dans  $Z_0, Z_1, \dots, Z_{51}$ . Hélas les  $Y_k$  n'engendrent pas une promenade  $\pm 1$ , car  $Z_{52} = 0$  empêche l'indépendance. L'idée est pourtant de « plonger » le processus dans une promenade en utilisant les probabilités conditionnelles.

Considérons donc une « vraie » promenade  $(S_k)$   $k_{x=0}^{\infty} = 0$ . On pose :

$$T_0 = 0, \quad T_{n+1} = \inf \{k > T_n \text{ tels que } S_k = 0\}.$$

On voit que  $T_n$  est l'instant du  $n^{\text{ème}}$  retour à l'origine de la promenade. Dans l'exemple de la figure 1,  $T_1 = 4$  et  $T_2 = 6$ . Il est possible de montrer que  $T_n$  existe avec la probabilité 1. Si nous remarquons que  $P(S_n = 0) = 0$

si  $n$  est impair et que  $P(S_n = 0) = \frac{C_n^{n/2}}{2^n} \frac{1}{2^n}$  si  $n$  est pair (analyse combinatoire facile), on a l'identité suivante, obtenue grâce à la formule du binôme :

$$\begin{aligned} (1-t^2)^{-1/2} &= \sum_{n=0}^{\infty} t^n P(S_n = 0) &= \sum_{n=0}^{\infty} t^n P\left(\bigcup_{k=0}^n T_k = n\right) \\ &= \sum_{n=0}^{\infty} t^n \sum_{k=0}^n P(T_k = n) &= \sum_{k=0}^{\infty} \sum_{n=k}^{\infty} t^n P(T_k = n). \end{aligned}$$

Un peu d'intuition permet de penser que les longueurs des intervalles de temps séparant ces différents retours sont indépendants et de même loi que  $T_1$ . Ces intervalles étant  $I_1 = T_1$ ,  $I_n = T_n - T_{n-1}$ , on a donc  $T_n = I_1 + \dots + I_n$ .

Par conséquent : 
$$\sum_{n=k}^{\infty} t^n P(T_k = n) = \left[ \sum_{n=1}^{\infty} t^n P(T_1 = n) \right]^k.$$

D'où la jolie identité : 
$$\sum_{n=1}^{\infty} t^n P(T_1 = n) = 1 - \sqrt{1-t^2}.$$

Désignons par  $K_n$  le nombre de zéros de la suite  $S_0, S_1, \dots, S_{n-1}$ .

Si on revient au problème posé, il est clair que  $E(K_{52} | S_{52} = 0) = E(K)$ . Comme il est fréquent en mathématiques, on a intérêt à résoudre un problème plus général : le calcul de  $E(K_n | S_n = 0)$ .

Or : 
$$\begin{aligned} \sum_{n=0}^{\infty} t^n P(S_n = 0) \cdot E(K_n | S_n = 0) &= 1 + \sum_{n=1}^{\infty} t^n P(S_n = 0) \cdot \sum_{k=1}^{\infty} k P(K_n = k | S_n = 0) \\ &= 1 + \sum_{k=1}^{\infty} k \sum_{n=k}^{\infty} t^n P(K_n = k | S_n = 0). \end{aligned}$$

Le point essentiel est que  $P(K_n = k | S_n = 0) = P(T_k = n)$ .

Les expressions ci-dessus sont donc égales à

$$1 + \sum_{k=1}^{\infty} k (1 - \sqrt{1-t^2})^k = 1 + \frac{1}{1-t^2} - \frac{1}{\sqrt{1-t^2}}$$

Pour avoir  $E(K_{52} | S_{52} = 0)$ , il suffit d'examiner les coefficients de  $t^{52}$  et on obtient  $2^{52} / C_{52}^2 - 1$ , soit, si  $2n = 52$ , environ 8, 03. Donc  $E(N) \approx 30, 02$ .

Précisons qu'on peut perfectionner la technique pour montrer que la variance de  $N$  est 2,41.

## 2. Points au hasard sur un cercle.

Un problème qui intéresse le statisticien est le suivant : sur un cercle  $T$ , choisissons « au hasard »  $n$  points  $P_1, \dots, P_n$  (sous-entendu : uniformément et indépendamment); on fait passer par le centre  $O$  une droite  $D$  de sorte que le nombre  $N$  des  $P_i$  situés d'un même côté de la droite soit le plus grand possible. Il est clair que  $2N > n$ . Mais quelle est la loi de  $N$ ?

Autrement dit : calculer  $Pr(N = k)$ , si  $\frac{n}{2} < k < n$ .

Sur  $T$ , plaçons les points  $P'_1, \dots, P'_n$  définis par  $\overrightarrow{OP'_1} + \overrightarrow{OP'_i} = \vec{0}$ . Fixons une origine  $I$  et un sens de parcours sur  $T$  (fig. 2). Les  $2n$  points  $P_1, \dots, P_n, P'_1, \dots, P'_n$  sont donc classés par ce sens de parcours. On définit les variables aléatoires  $X_1, \dots, X_{2n}$  par  $X_k = +1$  si le  $k^{\text{ième}}$  point rencontré est un  $P$ ,  $X_k = -1$  si c'est un  $P'$ . Évidemment, par suite des hypothèses,  $X_1, \dots, X_n$  sont indépendants et tels que  $P(X_i = 1) = P(X_i = -1) = \frac{1}{2}$ . Et  $X_{i+n} + X_i = 0$  si  $i \in [1, n]$ . On pose  $S_k = X_1 + \dots + X_k$ .





FIG. 2.

P'énonce maintenant un lemme que le lecteur patient n'aura pas de difficulté à démontrer :

*Lemme.* Soient  $\varepsilon_1, \dots, \varepsilon_n$  des nombres égaux à  $\pm 1$  tels que

$$\varepsilon_{i+n} + \varepsilon_i = 0 \quad \text{si } i \in [1, n].$$

On pose

$$\varepsilon_i^+ = \max(0, \varepsilon_i), \quad f_k = \varepsilon_1 + \dots + \varepsilon_k \quad \text{et} \quad g_k = \varepsilon_1^+ + \dots + \varepsilon_k^+.$$

Alors

$$\max_{1 \leq k \leq 2n} f_k - \min_{1 \leq k \leq 2n} f_k = 2 \max_{1 \leq k \leq n} (g_{k+n} - g_k) - n.$$

Un peu de réflexion — et l'examen de la figure 2 — indique la signification du lemme : l'oscillation de  $S_k$  entre 1 et  $2n$  est égale à  $2N - n$ . Les techniques de promenades aléatoires  $\pm 1$ , trop longues pour être développées ici, permettent d'obtenir la loi de l'oscillation  $O_n = \max_{1 \leq k \leq 2n} S_k - \min_{1 \leq k \leq 2n} S_k$ .

Un cas est particulièrement simple, celui où  $N = n$ . Alors  $O_n = n$ , ce qui ne peut arriver que s'il existe  $i$ , entre 1 et  $n$ , tel que

$$X_1 = X_2 = \dots = X_i = -X_{i+1} = \dots = -X_n$$

comme le montrerait le dessin. La probabilité est facile à calculer : c'est  $\frac{n}{2^{n-1}}$ .

### 3. Comparaison de lois empiriques.

Soient  $Y_1, \dots, Y_n$  des variables aléatoires indépendantes et de même loi continue définie par  $F(x) = P(Y_i < x)$ .  $F(x)$  n'est pas nécessairement connue, et pour avoir une idée de cette loi, le statisticien forme la fonction aléatoire suivante, appelée « loi empirique ».

$$F_n(x) = \frac{1}{n} (\text{nombre de } i \in [1, n) \text{ tels que } Y_i < x),$$

dont on peut démontrer qu'elle converge vers  $F(x)$  si  $n \rightarrow \infty$ .




FIG. 3.

Soient ensuite  $Z_1, \dots, Z_n$  des variables aléatoires indépendantes et de même loi, dont on pense que la loi commune est  $F$ . Pour tester cette affirmation, rien de plus naturel que de regarder le maximum  $D_n$  des différences entre les lois empiriques.  $F_n(x)$  et  $G_n(x)$  des  $Y$  et  $Z$  :

$$D_n = \max_x [F_n(x) - G_n(x)].$$

Mais pour tester statistiquement l'hypothèse de l'identité des lois des  $Y$  et  $Z$  il est indispensable de connaître la loi de  $D_n$  dans le cas où cette hypothèse est vérifiée. Il est remarquable que dans ce cas non seulement la loi de  $D_n$  ne dépend pas de  $F$ , mais est reliée à de simples propriétés d'une promenade  $\pm 1$ .

Classons les  $2n$  nombres  $Y_1, \dots, Y_n, Z_1, \dots, Z_n$  par ordre croissant et définissons les variables aléatoires  $X_1, \dots, X_{2n}$  par  $X_k = +1$  si le  $k^{\text{ième}}$  nombre est un  $Y$  et par  $X_k = -1$  si c'est un  $Z$ .

Posons  $S_k = X_1 + \dots + X_k$ . On voit alors que les  $k$  premiers termes de la

suite croissante comprennent  $\frac{1}{2}(k+S_k)$  nombres Y et  $\frac{1}{2}(k-S_k)$  nombres Z ce qui entraîne l'existence d'un  $x$  tel que

$$F_n(x) - G_n(x) = \frac{S_n}{n}.$$

Les  $X_k$  ne sont pas indépendants puisque soumis à la restriction  $S_{2n} = 0$ . Cependant, on peut utiliser le même artifice que dans l'exemple 1, en plongeant les  $S_k$  dans une promenade  $\pm 1$  et en conditionnant par  $S_{2n} = 0$ . Supposons donc que les  $S_k$  forment une promenade  $\pm 1$ , on a alors

$$P\left(D_n > \frac{d}{n}\right) = P\left(\exists k \in \{0, \dots, n\} \text{ tel que } S_k > d; S_{2n} = 0\right).$$

Le calcul du membre de droite se fait en utilisant le célèbre « principe de symétrie » de Désiré André : dans un diagramme comme celui de la figure 1, il y a  $C_{2n}^d$  « chemins » équiprobables joignant les points  $(0, 0)$  et  $(2n, 0)$ .

Le problème est de compter le nombre de ces chemins qui touchent la droite  $y = d$ . La figure 4 montre qu'il y a correspondance bijective entre ces derniers et les chemins joignant les points  $(0, 2d)$  et  $(2n, 0)$ , cette correspondance étant réalisée en prenant le symétrique par rapport à  $y = d$  de la partie du chemin de  $(0, 0)$  à  $(2n, 0)$  située entre  $(0, 0)$  et le premier point de contact avec  $y = d$ .




FIG. 4.

La probabilité cherchée est donc

$$C_{2n-d}^d / C_{2n}^d = \frac{n!}{(n-d)!} \cdot \frac{n!}{(n+d)!}$$

### Bibliographie

- [1] LETAC (G.). — *Problèmes de Probabilité*, P.U.F., à paraître.
- [2] HODGES (J. L.). (1955). — A bivariate sign test. *Ann. Math. Statist.*, 26, 523-527.
- [3] GNEDENKO et KOROLJUK (1951).