

MATH & MEDIA :

Et si on votait en tirant au hasard, à ‘pile ou face’ ?

Notre attention a été attirée par un article de Libération du 10 décembre 200, relatif aux élections américaines, et en particulier à celles de l'état de Floride. On y faisait référence à une étude de Bernard PARIZOT, astrophysicien au CNRS et amateur de statistiques, où celui affirmait (au moment où l'écart entre Bush et Gore n'était que de 537 voix pour environ 6 millions de votants) un certain nombre de propositions a priori étonnantes., dont celle ci : « *Un simple tirage à pile ou face entre les deux candidats aurait sans doute donné un écart beaucoup plus important* ».

Nous avons voulu en savoir un peu plus, et avons consulté le site < www.cyberhumanisme.org > où B. PARIZOT avait rédigé ses conclusions.

Nous avons pu y lire ceci :

(...) les écarts de voix entre les deux principaux candidats sont beaucoup plus faibles que si on tirait les votes à pile ou face.

(...) là où l'approche mathématique devient intéressante, c'est qu'elle permet de calculer précisément l'ordre de grandeur des fluctuations statistiques en fonction du nombre de pièces lancées [il s'agit là du tirage à pile ou face] : les fluctuations statistiques sont de type gaussien, avec une largeur relative typique en racine de $1/N$, où N est le nombre de lancers.

(...) Prenons maintenant le cas du fameux Etat de la Floride, cause de tous les problèmes. Il y a paraît-il 6 millions d'électeurs. Par le simple fait du hasard, c'est-à-dire dans le cas où aucune opinion ne guiderait les votes, on devrait donc obtenir un écart de voix de l'ordre de racine carrée de 6 millions, c'est-à-dire environ 2500 voix

Cette dernière phrase pourrait être interprétée comme « L'espérance de l'écart est de l'ordre de 2 500 voix ». Même ainsi, elle est ambiguë : est-ce l'écart entre le nombre de voix observées et 3 000 000, ou l'écart entre le nombre de voix de chacun des deux candidats ? Par la suite, nous privilégions la première interprétation, sans être sûrs que ce soit la bonne...

Posons le problème de façon plus claire : on joue n fois à ‘pile ou face’ (avec une pièce équilibrée). L'espérance du nombre de ‘PILE’ est $n/2$. Appelons D la variable aléatoire correspondant à l'écart (en valeur absolue) entre le nombre de ‘PILE’ observé et $n/2$. **Il s'agit de calculer l'espérance $E(D)$.** Remarquons tout de suite que si on cherchait à déterminer l'espérance de l'écart entre le nombre de ‘PILE’ et de ‘Face’, on trouverait $2 \cdot E(D)$.

Le point de vue de l'analyste combinatoire

On fera l'hypothèse que n est pair, pour que $n/2$ soit entier. Le nombre de ‘PILE’, X , suit une loi binomiale $B(n ; 1/2)$. Posons $D = |X - n/2|$. Pour tout k (entier) compris entre 0 et $n/2$ on a :

$$p(D = k) = p(X = n/2 - k) + p(X = n/2 + k) = \frac{C_n^{n/2+k}}{2^n - 1} .$$

$$D'ou\ E(D) = \frac{1}{2^{n-1}} \sum_{k=1}^{n/2} k \cdot C_n^{n/2+k}$$

Et par un astucieux calcul (si l'on sait bien manier la combinatoire), on trouve finalement

$$\frac{n \cdot C_n^{n/2}}{2^{n+1}}$$

que E(D) =

L'inconvénient est qu'on ne sait pas calculer effectivement des combinaisons portant sur de si grandes valeurs (n'oublions pas que, dans notre exemple, n = 6 000 000). L'analyste va donc chercher la limite de cette expression lorsque n → ∞. Et cela en utilisant les intégrales

$$W_k = \int_0^{\pi/2} \sin^k(x) \cdot dx \qquad W_k = \frac{\pi}{2} \cdot \frac{C_n^{n/2}}{2^n}$$

les de Wallis, sachant que. On trouve donc,

$$\sqrt{\frac{n}{2\pi}}$$

in fine, que E(D) est de l'ordre de grandeur de lorsque n est 'infiniment grand'.

A propos des intégrales de Wallis, consultez l'excellent ouvrage de B. et A. PARZYSZ *Fonctions d'une variable* dans la collection TD chez Dunod. Le calcul ci-dessus a d'ailleurs été fait par Bernard PARZYSZ, que nous remercions.

Le point de vue du probabilitste-statisticien

Le statisticien, lui, sait que la loi binomiale B(n ; 1/2) de X (nombre de 'PILE') est approchée, dès que n est suffisamment grand, par une loi normale N(n/2 ; √n/2).

La fonction de répartition de D est définie par F_D(x) = p(n/2 - x < X < n/2 + x) = p(n/2 - x < X < n/2 + x) pour x ≥ 0.

Soit F_D(x) = F_X(n/2 + x) - F_X(n/2 - x). En dérivant, il vient :

f_D(x) = f_X(n/2 + x) - f_X(n/2 - x), où f_X est la densité de X, dont on disait qu'on l'avait assimilée à une loi normale.

$$\frac{2\sqrt{2}}{\sqrt{n\pi}} \cdot e^{-\frac{2x^2}{n}}$$

On trouve donc f_D(x) =

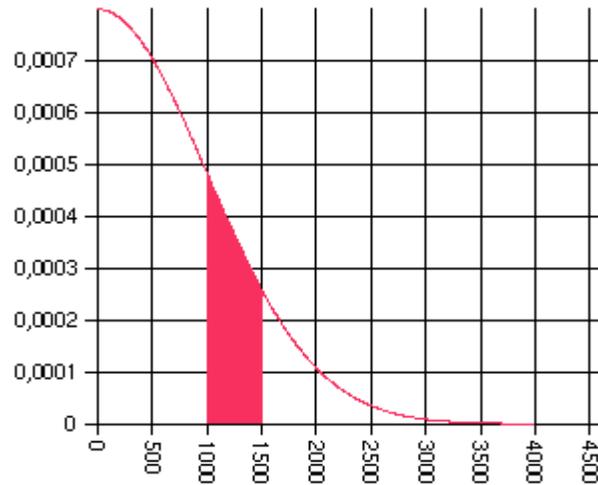
$$\int_0^\infty x \cdot f_D(x) \cdot dx = \frac{\sqrt{n}}{\sqrt{2\pi}} \cdot \left[e^{-\frac{2x^2}{n}} \right]_0^\infty$$

.D'ou\ E(D) =

$$\sqrt{\frac{n}{2\pi}}$$

Ce qui, in fine, redonne bien E(D) = . Merci à Daniel Vagost et Franck Gaüzère, du département S.T.I.D. de l'I.U.T. de Metz, d'avoir ment à bien ce calcul.

L'image ci-dessous est la densité de 2D (différence en valeur absolue entre le nombre de PILE et le nombre de FACE (pour $n = 1\,000\,000$)). Nous l'avons trouvée sur le site personnel de Michel Brissaud, qui a lui aussi traité ce problème de l'écart des voix (avec l'aide d'un tableur). Nous l'en remercions et nous vous conseillons de consulter sa page personnelle : <http://www.perso.wanadoo.fr/michel.brissaud>



Le point de vue du simulateur (!)

Le simulateur est l'auteur de ces lignes : il ne sait ni calculer des intégrales (fussent-elles de Wallis, de Futuna ou d'ailleurs), ni manier correctement la combinatoire. Il a donc réalisé un petit programme pour simuler 6 000 000 de tirages à 'pile ou face', et regardé l'écart (en valeur absolue) entre le nombre de 'PILE' et 3 000 000. Et il a répété 500 fois cette expérience aléatoire.

Voici l'algorithme :

```
nbvotants=6000000 ; nbA=0, écart=0, totalécart=0;
écartmax=0, écartmin=nbvotants; écartmoy=0;
entrer nbrepet; (équivalent d'un input)
for(j=0;j<nbrepet;j=j+1)
{ nbA=0; écart=0;
  for (i=0;i<nbvotants;i=i+1) if (random()<0.5) nbA=nbA+1;
  écart=abs(nbvotants/2-nbA); totalécart=totalécart+écart;
  if (écart>écartmax) écartmax=écart;
  if (écart<écartmin) écartmin=écart;
} (fin de la boucle for)
écartmoy=totalécart/nbrepet;
print("Sur "+nbrepet+" expériences, écart moyen =
"+écartmoy);
print("Maximum de l'écart : "+écartmax+" ; minimum de
l'écart : "+écartmin);
```

Le langage de cet algorithme est purement imaginaire, mais il s'inspire du C ou du Java. Au bout d'un certain temps (500 fois 6 000 000, ça fait quand même 3 milliards de tirages), le résultat s'affiche :

Sur 500 expériences, écart moyen = 958,2
Maximum de l'écart : 4066 ; minimum de l'écart : 9

Et on est satisfait, car cela correspond au résultat théorique !

Si on avait recherché, par simulation, la fréquence d'un écart supérieur à $\sqrt{n}/2$ (ce qui correspond aux dires de B. PARIZOT, voir ci-dessous), on aurait trouvé environ 1/3 : ce n'est pas un événement si rare que ça.

Mais... car il y a un mais !

Bernard PARIZOT a écrit « *Par le simple fait du hasard, c'est-à-dire dans le cas où aucune opinion ne guiderait les votes, on devrait donc obtenir un écart de voix de l'ordre de racine carrée de 6 millions, c'est-à-dire environ 2500 voix* ».

Ce qui ne correspond ni à ce qu'on a calculé, ni à ce qu'on a simulé.

On a certainement mal interprété son texte : il parlait certainement de l'écart entre les deux candidats, et non de l'écart entre le nombre de voix de l'un des deux et 3 000 000. Il faut donc doubler tous les résultats trouvés auparavant.

Mais cela ne donne toujours qu'une espérance de $\sqrt{\frac{2n}{\pi}}$, soit environ 1 954 voix.

L'explication tient peut-être dans cette phrase : « *les fluctuations statistiques sont de type gaussien, avec une largeur relative typique en racine de $1/N$* ». Ce qui correspond à la « plage de normalité » dont il est question dans le programme de seconde à propos des fluctuations d'échantillonnage : quand on joue à 'pile ou face', on a en effet 95% de chances d'observer, dans l'échantillon tiré, que la proportion de 'PILE' est dans l'intervalle

$$\left[\frac{1}{2} - \frac{1}{\sqrt{n}} ; \frac{1}{2} + \frac{1}{\sqrt{n}} \right]$$

L'auteur pose inconsciemment le problème de la vulgarisation scientifique, qui oblige parfois à une trop grande simplification du propos pour qu'il puisse être compris par tous. Mais le cœur du message est présent : l'écart est dans l'ordre de grandeur de \sqrt{n} ...

Jacques VERDIER

P.S. Dans un message électronique du 27/01/01, Michel BRISSAUD m'écrivait ceci : « *En conclusion, c'est très compliqué, et je continue à penser qu'une approche correcte de la fluctuation d'échantillonnage est impossible en classe de seconde : il faut rester à un niveau très élémentaire.* »