

# Estimation des grands écarts

Références : [Les01] p.16-20 ([Ouv07] et [Gou08]).

**Théorème 0.1** Soit  $p \in ]0, 1[$ . Soit  $(X_n)_{n \in \mathbb{N}^*}$  une suite de variables aléatoires indépendantes de même loi de Bernoulli de paramètre  $p$ . Soit la variable aléatoire  $S_n = \sum_{i=1}^n X_i \sim \mathcal{B}(n, p)$ . On pose pour  $\epsilon \in ]0, 1 - p[$ ,

$$h_+(\epsilon) = (p + \epsilon) \log \left( \frac{p + \epsilon}{p} \right) + (1 - p - \epsilon) \log \left( \frac{1 - p - \epsilon}{1 - p} \right)$$

Alors :

1.  $h_+(\epsilon) > 0$  ;
2. pour tout  $n \geq 1$ ,

$$\mathbb{P} \left( \frac{S_n}{n} \geq p + \epsilon \right) \leq e^{-nh_+(\epsilon)}$$

3. et cette inégalité est optimale, ie

$$\lim_{n \rightarrow +\infty} \frac{1}{n} \log \mathbb{P} \left( \frac{S_n}{n} \geq p + \epsilon \right) = -h_+(\epsilon)$$

## Démonstration

**Étape 1** Montrons le (1) et le (2).

Soit  $t > 0$  fixé. Déterminons la probabilité suivante :

$$\begin{aligned} \mathbb{P} \left( \frac{S_n}{n} \geq p + \epsilon \right) &= \mathbb{P}(S_n \geq n(p + \epsilon)) \\ &= \mathbb{P}(S_n - n(p + \epsilon) \geq 0) \\ &= \mathbb{P}(t(S_n - np - n\epsilon) \geq 0) \\ &= \mathbb{P}(e^{t(S_n - np - n\epsilon)} \geq 1) \end{aligned}$$

par bijectivité de l'exponentielle. Ainsi d'après l'inégalité de Markov, on a :

$$\begin{aligned} \mathbb{P} \left( \frac{S_n}{n} \geq p + \epsilon \right) &\leq \mathbb{E}(e^{t(S_n - np - n\epsilon)}) \\ &= e^{-nt(p+\epsilon)} \mathbb{E}(e^{tS_n}) \\ &= e^{-nt(p+\epsilon)} \sum_{k=1}^n e^{tk} \mathbb{P}(S_n = k) \quad \text{d'après le lemme de transfert ;} \\ &= e^{-nt(p+\epsilon)} \sum_{k=1}^n e^{tk} C_n^k p^k (1-p)^{n-k} \end{aligned}$$

La formule du binôme de Newton nous donne alors :

$$\begin{aligned} \mathbb{P} \left( \frac{S_n}{n} \geq p + \epsilon \right) &\leq e^{-nt(p+\epsilon)} (1 - p + pe^t)^n \\ &= e^{-nt(p+\epsilon) - n \log(1 - p + pe^t)} \end{aligned}$$

Cela étant vrai  $\forall t > 0$ , on obtient finalement :

$$\mathbb{P}\left(\frac{S_n}{n} \geq p + \epsilon\right) \leq e^{-nh}$$

où  $h = \sup_{t>0} \{t(p + \epsilon) - \log(1 - p + pe^t)\}$ .

Étudions alors la fonction :

$$\begin{aligned} g : \mathbb{R}_+^* &\longrightarrow \mathbb{R} \\ t &\longmapsto t(p + \epsilon) - \log(1 - p + pe^t) \end{aligned}$$

On remarque que  $g(0) = 0$  et que  $g$  est dérivable, de dérivée :

$$g'(t) = p + \epsilon - \frac{pe^t}{1 - p + pe^t}$$

d'où  $g'(0) = \epsilon > 0$ , ce qui prouve que la borne supérieure de  $g$  est strictement positive.

Cherchons le point où la dérivée s'annule :

$$\begin{aligned} g'(t) = 0 &\Leftrightarrow p + \epsilon - \frac{pe^t}{1 - p + pe^t} = 0 \\ &\Leftrightarrow p + \epsilon = \frac{pe^t}{1 - p + pe^t} \\ &\Leftrightarrow (p + \epsilon)(1 - p + pe^t) = pe^t \\ &\Leftrightarrow (p + \epsilon)(1 - p) = pe^t(1 - p - \epsilon) \\ &\Leftrightarrow e^t = \frac{(p + \epsilon)(1 - p)}{p(1 - p - \epsilon)} \\ &\Leftrightarrow t = \log\left(\frac{(p + \epsilon)(1 - p)}{p(1 - p - \epsilon)}\right) \end{aligned}$$

On effectue la tableau de variation de  $g$  et on se rend compte que  $g$  est maximale en  $t = \log\left(\frac{(p + \epsilon)(1 - p)}{p(1 - p - \epsilon)}\right)$ , donc :

$$\begin{aligned} h &= \sup_{t>0} \{t(p + \epsilon) - \log(1 - p + pe^t)\} \\ &= \log\left(\frac{(p + \epsilon)(1 - p)}{p(1 - p - \epsilon)}\right) (p + \epsilon) - \log\left(1 - p + p\frac{(p + \epsilon)(1 - p)}{p(1 - p - \epsilon)}\right) \\ &= (p + \epsilon) \log\left(\frac{p + \epsilon}{p}\right) + (p + \epsilon) \log\left(\frac{1 - p}{1 - p - \epsilon}\right) - \log\left(1 - p + \frac{(p + \epsilon)(1 - p)}{1 - p - \epsilon}\right) \\ &= (p + \epsilon) \log\left(\frac{p + \epsilon}{p}\right) + (p + \epsilon) \log\left(\frac{1 - p}{1 - p - \epsilon}\right) - \log\left(\frac{(1 - p)(1 - p - \epsilon) + (p + \epsilon)(1 - p)}{1 - p - \epsilon}\right) \\ &= (p + \epsilon) \log\left(\frac{p + \epsilon}{p}\right) + (p + \epsilon) \log\left(\frac{1 - p}{1 - p - \epsilon}\right) - \log\left(\frac{1 - p}{1 - p - \epsilon}\right) \\ &= (p + \epsilon) \log\left(\frac{p + \epsilon}{p}\right) + (1 - p - \epsilon) \log\left(\frac{1 - p - \epsilon}{1 - p}\right) \\ &= h_+(\epsilon) \end{aligned}$$

**Étape 2** Montrons l'assertion (3). L'estimation des grands écarts obtenue dans l'étape 1 s'écrit :

$$\mathbb{P}\left(\frac{S_n}{n} \geq p + \epsilon\right) \leq e^{-nh_+(\epsilon)}$$

Nous cherchons alors une minoration. On pose  $k_n = \lceil n(p + \epsilon) \rceil$  le nombre entier immédiatement supérieur à  $n(p + \epsilon)$ . On a alors :

$$\mathbb{P}(S_n \geq n(p + \epsilon)) \geq \mathbb{P}(S_n = k_n)$$

et nous allons maintenant montrer que :

$$\lim_{n \rightarrow +\infty} \frac{1}{n} \log \mathbb{P}(S_n = k_n) = -h_+(\epsilon)$$

car cela assurera que :

$$\liminf_{n \rightarrow +\infty} \frac{1}{n} \log \mathbb{P}(S_n \geq n(p + \epsilon)) \geq -h_+(\epsilon)$$

On a :

$$\mathbb{P}(S_n = k_n) = \frac{n!}{k_n!(n - k_n)!} p^{k_n} (1 - p)^{n - k_n}$$

Ainsi en appliquant la formule de Stirling aux trois suites de factorielles, on obtient :

$$\begin{aligned} \mathbb{P}(S_n = k_n) &\sim \sqrt{2\pi n} \left(\frac{n}{e}\right)^n \frac{1}{\sqrt{2\pi k_n}} \left(\frac{e}{k_n}\right)^{k_n} \frac{1}{\sqrt{2\pi(n - k_n)}} \left(\frac{e}{n - k_n}\right)^{n - k_n} p^{k_n} (1 - p)^{n - k_n} \\ &\sim \sqrt{\frac{2\pi n}{(2\pi k_n)(2\pi(n - k_n))}} \left(\frac{n}{e}\right)^n \left(\frac{ep}{k_n}\right)^{k_n} \left(\frac{e(1 - p)}{n - k_n}\right)^{n - k_n} \\ &\sim \sqrt{\frac{2\pi n}{4\pi^2 k_n(n - k_n)}} \left(\frac{n}{e}\right)^{k_n} \left(\frac{n}{e}\right)^{n - k_n} \left(\frac{ep}{k_n}\right)^{k_n} \left(\frac{e(1 - p)}{n - k_n}\right)^{n - k_n} \\ &\sim \sqrt{\frac{n}{2\pi k_n(n - k_n)}} \left(\frac{nep}{ek_n}\right)^{k_n} \left(\frac{ne(1 - p)}{en - kn}\right)^{n - k_n} \\ &\sim \frac{1}{\sqrt{2\pi}} \sqrt{\frac{n}{k_n(n - k_n)}} \left(\frac{np}{k_n}\right)^{k_n} \left(\frac{n(1 - p)}{n - k_n}\right)^{n - k_n} \end{aligned}$$

Comme  $k_n$  et  $n - k_n$  divergent vers l'infini et  $\mathbb{P}(S_n = k_n) \rightarrow 0$  alors on peut passer au logarithme dans l'équivalence précédente, ie :

$$\begin{aligned} \log \mathbb{P}(S_n = k_n) &\sim \log \left( \frac{1}{\sqrt{2\pi}} \sqrt{\frac{n}{k_n(n - k_n)}} \left(\frac{np}{k_n}\right)^{k_n} \left(\frac{n(1 - p)}{n - k_n}\right)^{n - k_n} \right) \\ &\sim \log \left( \frac{1}{\sqrt{2\pi}} \right) + \log \left( \sqrt{\frac{n}{k_n(n - k_n)}} \right) + k_n \log \left( \frac{np}{k_n} \right) + (n - k_n) \log \left( \frac{n(1 - p)}{n - k_n} \right) \\ &\sim -\frac{1}{2} \log(2\pi) + \frac{1}{2} \log \left( \frac{n}{k_n(n - k_n)} \right) + k_n \log \left( \frac{np}{k_n} \right) + (n - k_n) \log \left( \frac{n(1 - p)}{n - k_n} \right) \end{aligned}$$

Or par définition  $k_n = \lceil n(p + \epsilon) \rceil$ , donc  $k_n = n(p + \epsilon) + o(n)$  et  $n - k_n = n(1 - p - \epsilon) + o(n)$ , donc :

$$\frac{n}{k_n(n - k_n)} = \frac{n}{n(p + \epsilon)n(1 - p - \epsilon) + o(n)} = \frac{1}{(p + \epsilon)n(1 - p - \epsilon) + o(n)} \rightarrow 0$$

Donc

$$\lim_{n \rightarrow +\infty} \frac{1}{2n} \log \left( \frac{n}{k_n(n - k_n)} \right) \rightarrow 0$$

Maintenant :

$$\begin{aligned} k_n \log \left( \frac{np}{k_n} \right) &= n(p + \epsilon) \log \left( \frac{p}{p + \epsilon} \frac{n(p + \epsilon)}{k_n} \right) + (k_n - n(p + \epsilon)) \log \left( \frac{np}{k_n} \right) \\ &= n(p + \epsilon) \log \left( \frac{p}{p + \epsilon} \right) + n(p + \epsilon) \log \left( \frac{n(p + \epsilon)}{k_n} \right) + (k_n - n(p + \epsilon)) \log \left( \frac{np}{k_n} \right) \end{aligned}$$

Ainsi en utilisant le fait que  $k_n - n(p + \epsilon)$  reste borné (par 1), on en déduit que :

$$\lim_{n \rightarrow +\infty} \frac{1}{n} k_n \log \left( \frac{np}{k_n} \right) = (p + \epsilon) \log \frac{p}{p + \epsilon}$$

De la même façon, on montre que :

$$\lim_{n \rightarrow +\infty} \frac{1}{n} (n - k_n) \log \left( \frac{n(1 - p)}{n - k_n} \right) = (1 - p - \epsilon) \log \frac{1 - p}{1 - p - \epsilon}$$

Donc on en déduit que :

$$\frac{1}{n} \log(\mathbb{P}(S_n = k_n)) \longrightarrow -h_+(\epsilon)$$

Donc puisque  $\mathbb{P}(S_n \geq n(p + \epsilon)) \geq \mathbb{P}(S_n = k_n)$ , alors

$$\liminf_{n \rightarrow +\infty} \frac{1}{n} \log(\mathbb{P}(S_n \geq n(p + \epsilon))) \geq -h_+(\epsilon)$$

Or d'après le point (2) démontré dans l'étape 1, on a :

$$\limsup_{n \rightarrow +\infty} \frac{1}{n} \log(\mathbb{P}(S_n \geq n(p + \epsilon))) \leq -h_+(\epsilon)$$

D'où l'égalité voulue.

### Lemmes utilisés

**Lemme 0.1 (Inégalité de Markov)** Soit  $X \in \mathcal{L}^1(\Omega, \mathcal{A}, \mathbb{P})$  positive, alors pour tout  $\epsilon > 0$  :

$$\mathbb{P}(X \geq \epsilon) \leq \frac{\mathbb{E}(X)}{\epsilon}$$

A fortiori, on a aussi :

$$\mathbb{P}(X > \epsilon) \leq \frac{\mathbb{E}(X)}{\epsilon}$$

**Démonstration** Si  $X \in \mathcal{L}^1(\Omega, \mathcal{A}, \mathbb{P})$  est positive, soit  $D = \{X \geq \epsilon\}$ . On a alors les minoration suivantes :

$$\begin{aligned} \mathbb{E}(X) &= \int_{\Omega} X d\mathbb{P} \\ &\geq \int_D X d\mathbb{P} \\ &\geq \epsilon \mathbb{P}(D) \end{aligned}$$

D'où le résultat. La deuxième inégalité résulte de l'inclusion  $(X > \epsilon) \subset (X \geq \epsilon)$ .

**Lemme 0.2 (Formule de Stirling)** On considère la suite  $(u_n)_{n \in \mathbb{N}^*}$  définie par  $\forall n \in \mathbb{N}^*$  :

$$u_n = \frac{n^n e^{-n} \sqrt{n}}{n!}$$

Déterminons la nature de la série de terme général  $v_n = \log\left(\frac{u_{n+1}}{u_n}\right)$  et déduisons-en l'existence d'un entier  $k > 0$  tel que, quand  $n \rightarrow +\infty$  :

$$n! \sim k \sqrt{n} n^n e^{-n}$$

et déterminons cette constante à l'aide de la formule de Wallis.

**Démonstration** Estimons  $v_n$  lorsque  $n \rightarrow +\infty$  :

$$\begin{aligned} v_n &= \log\left(\left(\frac{n+1}{n}\right)^{n+\frac{1}{2}} e^{-1}\right) \\ &= -1 + \left(n + \frac{1}{2}\right) \log\left(1 + \frac{1}{n}\right) \\ &= -1 + \left(n + \frac{1}{2}\right) \left(\frac{1}{n} - \frac{1}{2n^2} + \mathcal{O}\left(\frac{1}{n^3}\right)\right) \\ &= \mathcal{O}\left(\frac{1}{n^2}\right) \end{aligned}$$

Cette expression nous montre la convergence de la série  $\sum v_n$ . Comme, on a  $v_1 + \dots + v_n = \log u_{n+1} - \log u_1$  pour  $n \geq 1$ , alors la suite  $(\log(u_n))_{n \in \mathbb{N}^*}$  converge. En notant  $\lambda$  sa limite, on voit que  $(u_n)$  converge vers  $k = e^\lambda > 0$ , d'où l'équivalent.

Il nous reste à déterminer la constante  $k$ . Nous allons pour ce faire utiliser la formule de Wallis, qui est :

$$\lim_{p \rightarrow +\infty} \frac{1}{p} \left( \frac{(2p)(2p-2)\dots 2}{(2p-1)(2p-3)\dots 1} \right)^2 = \pi$$

Par ailleurs, en utilisant l'équivalent, on a lorsque  $p \rightarrow +\infty$  :

$$\frac{1}{p} \left( \frac{(2p)(2p-2)\dots 2}{(2p-1)(2p-3)\dots 1} \right)^2 = \frac{1}{p} \left( \frac{2^{2p}(p!)^2}{(2p)!} \right)^2 \sim \frac{2^{4p}}{p} \frac{k^4 p^{4p+2} e^{-4p}}{k^2 (2p)^{4p+1} e^{-4p}} = \frac{k^2}{2}$$

donc  $\pi = \frac{k^2}{2}$ , ie  $k = \sqrt{2\pi}$ . D'où le résultat.

## Références

- [Gou08] Xavier Gourdon. *Analyse*. Ellipses, 2008.
- [Les01] Emmanuel Lesigne. *Pile ou face*. Ellipses, 2001.
- [Ouv07] Jean-Yves Ouvrard. *Probabilités 1*. Cassini, 2007.