

Estimations des grands écarts

Arnaud GIRAND

17 juin 2012

Référence :

– [Les01], p. 16–20

Prérequis :

– formule de Stirling.

Proposition 1

Soit $p \in (0, 1)$.

On considère une suite $(X_n)_{n \geq 1}$ de variables aléatoires i.i.d de loi $\mathcal{B}(p)$ et on pose :

$$\forall n \geq 1, S_n := \sum_{i=1}^n X_i \sim \mathcal{B}(n, p)$$

Pour $\varepsilon \in (0, 1 - p)$ on définit également :

$$h_+(\varepsilon) := (p + \varepsilon) \ln \left(\frac{p + \varepsilon}{p} \right) + (1 - p - \varepsilon) \ln \left(\frac{1 - p - \varepsilon}{1 - p} \right)$$

Alors :

(i) $h_+(\varepsilon) > 0$;

(ii)

$$\forall n \geq 1, \quad \mathbb{P} \left(\frac{S_n}{n} \geq p + \varepsilon \right) \leq e^{-nh_+(\varepsilon)}$$

(iii) cette inégalité est optimale, i.e :

$$\frac{1}{n} \ln \left(\mathbb{P} \left(\frac{S_n}{n} \geq p + \varepsilon \right) \right) \xrightarrow{n \rightarrow \infty} -h_+(\varepsilon)$$

DÉMONSTRATION :

(i) et (ii) Soit $t > 0$. Alors :

$$\begin{aligned} \mathbb{P} \left(\frac{S_n}{n} \geq p + \varepsilon \right) &= \mathbb{P} \left(e^{t(S_n - np - n\varepsilon)} \geq 1 \right) \\ &\leq \mathbb{E}(e^{t(S_n - np - n\varepsilon)}) \text{ par inégalité de Markov} \\ &= e^{-nt(p + \varepsilon)} \mathbb{E}(e^{tS_n}) \\ &= e^{-nt(p + \varepsilon)} \sum_{k=0}^{\infty} e^{tk} \mathbb{P}(S_n = k) \text{ par lemme de transfert} \\ &= e^{-nt(p + \varepsilon)} \sum_{k=0}^n e^{tk} C_n^k p^k (1 - p)^{n-k} \\ &= e^{-nt(p + \varepsilon)} \sum_{k=0}^n e^{tk} C_n^k p^k (1 - p)^{n-k} \\ &= e^{-nt(p + \varepsilon)} (1 - p + pe^t)^n \\ &= e^{-n(t(p + \varepsilon) - \ln(1 - p + pe^t))} \end{aligned}$$

Posons :

$$h := \sup_{t > 0} (t(p + \varepsilon) - \ln(1 - p + pe^t))$$

On a alors :

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

On considère à présent la fonction $g : (t \in \mathbb{R}_+^*) \mapsto t(p + \varepsilon) - \ln(1 - p + pe^t)$. Comme $g(0) = 0$, $h = \sup(g) \leq 0$. De plus $\forall t > 0$, $g'(t) = p + \varepsilon - \frac{pe^t}{1 - p + pe^t}$ et donc $g'(0) = \varepsilon > 0$, ce qui implique que g est strictement croissante au voisinage de 0 et donc que $h > 0$. Enfin si on pose $t_0 := \ln\left(\frac{(p + \varepsilon)(1 - p)}{p(1 - p - \varepsilon)}\right)$ alors une rapide étude de fonction montre que $h = g(t_0) = h_+\varepsilon$, d'où les points (i) et (ii).

(iii) Par (ii) on a :

$$\frac{1}{n} \ln\left(\mathbb{P}\left(\frac{S_n}{n} \geq p + \varepsilon\right)\right) \leq -h_+(\varepsilon) \quad (1)$$

Nous allons donc tenter de minorer cette quantité. Pour $n \geq 1$ on pose $k_n := \lceil n(p + \varepsilon) \rceil$ et on remarque que $\mathbb{P}\left(\frac{S_n}{n} \geq p + \varepsilon\right) = \mathbb{P}(S_n \geq n(p + \varepsilon)) \geq \mathbb{P}(S_n = k_n) = C_n^{k_n} p^{k_n} (1 - p)^{n - k_n}$. En appliquant la formule de Stirling à chacune¹ des factorielles présentes dans $C_n^{k_n}$ on trouve alors :

$$\mathbb{P}(S_n = k_n) \sim \frac{1}{\sqrt{2\pi}} \sqrt{\frac{n}{k_n(n - k_n)}} \left(\frac{np}{k_n}\right)^{k_n} \left(\frac{n(1 - p)}{n - k_n}\right)^{n - k_n} \quad (2)$$

Or $k_n = n(p + \varepsilon) + o(n)$ et $n - k_n = n(1 - p - \varepsilon) + o(n)$, donc $\mathbb{P}(S_n = k_n) \xrightarrow{n \rightarrow \infty} 0$, on peut passer au logarithme dans l'équivalent (2), d'où :

$$\frac{1}{n} \ln(\mathbb{P}(S_n = k_n)) \sim \frac{-1}{2n} \ln(2\pi) + \frac{1}{2n} \ln\left(\frac{n}{k_n(n - k_n)}\right) + \frac{1}{n} \ln\left(\left(\frac{np}{k_n}\right)^{k_n}\right) + \frac{1}{n} \ln\left(\left(\frac{n(1 - p)}{n - k_n}\right)^{n - k_n}\right)$$

On sait que $\frac{n}{k_n(n - k_n)} \xrightarrow{n \rightarrow \infty} 0$. Remarquons ensuite que :

$$\begin{aligned} \forall n \geq 1, \ln\left(\left(\frac{np}{k_n}\right)^{k_n}\right) &= k_n \ln\left(\frac{np}{k_n}\right) = n(p + \varepsilon) \ln\left(\frac{np}{k_n}\right) + (k_n - n(p + \varepsilon)) \ln\left(\frac{np}{k_n}\right) \\ &= n(p + \varepsilon) \ln\left(\frac{p}{p + \varepsilon}\right) + n(p + \varepsilon) \ln\left(\frac{n(p + \varepsilon)}{k_n}\right) + (k_n - n(p + \varepsilon)) \ln\left(\frac{np}{k_n}\right) \end{aligned}$$

Ainsi, comme $(k_n - n(p + \varepsilon))_n$ est bornée (par 1) on obtient :

$$\frac{1}{n} \ln\left(\left(\frac{np}{k_n}\right)^{k_n}\right) \xrightarrow{n \rightarrow \infty} (p + \varepsilon) \ln\left(\frac{p}{p + \varepsilon}\right)$$

De même :

$$\frac{1}{n} \ln\left(\left(\frac{n(1 - p)}{n - k_n}\right)^{n - k_n}\right) \xrightarrow{n \rightarrow \infty} (1 - p - \varepsilon) \ln\left(\frac{1 - p}{1 - p - \varepsilon}\right)$$

Et donc in fine :

$$\frac{1}{n} \mathbb{P}(S_n = k_n) \xrightarrow{n \rightarrow \infty} -h_+(\varepsilon)$$

Ce qui implique, comme $\mathbb{P}\left(\frac{S_n}{n} \geq p + \varepsilon\right) \geq \mathbb{P}(S_n = k_n)$ que :

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \ln\left(\mathbb{P}\left(\frac{S_n}{n} \geq p + \varepsilon\right)\right) \geq -h_+(\varepsilon) \quad (3)$$

Or par (1) :

$$\limsup_{n \rightarrow \infty} \frac{1}{n} \ln\left(\mathbb{P}\left(\frac{S_n}{n} \geq p + \varepsilon\right)\right) \leq -h_+(\varepsilon) \quad (4)$$

Et donc, en combinant (3) et (4) :

$$\frac{1}{n} \ln\left(\mathbb{P}\left(\frac{S_n}{n} \geq p + \varepsilon\right)\right) \xrightarrow{n \rightarrow \infty} -h_+(\varepsilon)$$

1. J'aimerais que ce soit une mauvaise blague. J'aimerais tellement.

Détails supplémentaires :

– Rappelons la très divertissante *formule de Stirling* :

$$n! \sim_{n \rightarrow \infty} \left(\frac{n}{e}\right)^n \sqrt{2\pi n}$$

– Soient u et v deux suites de \mathbb{R}_+^* convergeant vers une limite $\ell \neq 1$ telles que $u_n \sim v_n$. Montrons que $\ln(u_n) \sim \ln(v_n)$. Remarquons que comme $\lim_n v_n \neq 1$, il existe $N \geq 0$ tel que $\forall n \geq N, v_n \neq 1$. On peut alors écrire :

$$\forall n \geq N, \frac{\ln(u_n)}{\ln(v_n)} - 1 = \frac{\ln(u_n) - \ln(v_n)}{\ln(v_n)} = \frac{\ln\left(\frac{u_n}{v_n}\right)}{\ln(v_n)} \xrightarrow[n \rightarrow \infty]{} 0$$

D'où le résultat.

Références

[Les01] Emmanuel Lesigne. *Pile ou face*. Ellipses, 2001.