

# Sur l'approximation de la loi binomiale par la loi normale.

Auteur : **Christian Maillard**

840 B, avenue des Serrets - 04100 Manosque  
(trueil@wanadoo.fr)

## Introduction

Nous citons dans cette introduction une note de Paul-Louis HENNEQUIN parue dans le bulletin vert n°436 de Novembre-Décembre 2001 (p.732-733), suite à l'article de Louis-Marie BONNEVAL intitulé "Intervalles : de confiance ?" et référencé ci-dessous.

Nous invitons vivement le lecteur à prendre connaissance de ce texte de L. M. Bonneval, avant de poursuivre la lecture du présent article.

Dans le bulletin vert n°427 (mars-avril 2000), pages 141-170, Louis-Marie BONNEVAL s'intéresse à l'intervalle de confiance pour l'estimation de la probabilité  $p$  inconnue d'un événement aléatoire à partir de la réalisation de  $n$  expériences indépendantes dans lesquelles l'événement est apparu avec une fréquence  $f$ .

Il propose les deux conjectures suivantes :

1)- Pour tout naturel  $n > 0$ , et pour tout réel  $p$  de  $[0,1]$  :

$$P \left\{ \left| f - p \right| \leq \frac{1}{\sqrt{n}} \right\} > 0.9$$

résultat facile à mémoriser pour un élève débutant en statistique inférentielle.

2)- Pour tout naturel  $n > 20$ , et pour tout réel  $p$  de  $[0,1]$  :

$$P \left\{ \left| f - p \right| \leq \frac{1}{\sqrt{n}} \right\} > 0.93$$

et suggère de travailler sur le niveau 0.93.

Daniel SAADA (Saada@club-internet.fr) nous a adressé le 17 Février 2001 une étude relative au cas particulier  $p = 0.5$  et  $n = 4k^2$ ,  $k$  naturel. Il obtient alors :

$$P \left\{ \left| f - p \right| \leq \frac{1}{\sqrt{n}} \right\} > 0.915$$

Par ailleurs, il montre, toujours dans le cas particulier  $p = 0.5$  que, pour  $n > 5$  :

$$P \left\{ \left| f - p \right| \leq \frac{1}{\sqrt{n}} \right\} > 0.929$$

De son côté, Christian MAILLARD nous a adressé le 6 Août 2001 la démonstration des inégalités ci-dessous qui incluent les conjectures de L. M. Bonneval :

Pour tout  $p$  réel de  $[0,1]$  et pour tout naturel  $n$  supérieur à 552,

$$P \left\{ \left| f - p \right| \leq \frac{1}{\sqrt{n}} \right\} > 0.95$$

Pour tout  $p$  réel de  $[0,1]$  et pour tout naturel  $n$  supérieur à 56,

$$P \left\{ \left| f - p \right| \leq \frac{1}{\sqrt{n}} \right\} > 0.94$$

Pour tout  $p$  réel de  $[0,1]$  et pour tout naturel  $n$  supérieur à 20,

$$P \left\{ \left| \mathcal{F} - p \right| \leq \frac{1}{\sqrt{n}} \right\} > 0.93$$

Et enfin pour tout  $p$  réel de  $[0,1]$  et pour tout naturel  $n$  non nul,

$$P \left\{ \left| \mathcal{F} - p \right| \leq \frac{1}{\sqrt{n}} \right\} > 0.9$$

Cette démonstration s'accompagne d'une analyse très précise de l'approximation de la loi binomiale par la loi de Laplace-Gauss.

*La démonstration de la conjecture Bonneval s'appuie sur le principe (mais s'appuie seulement) du calcul de l'erreur commise en remplaçant la loi binomiale par la loi normale.*

*La partie qui suit donne un calcul général de l'erreur entre les deux lois (une majoration de l'erreur, bien entendu).*

*Pour aboutir ensuite à la conjecture Bonneval, il faudra choisir  $b = \frac{1}{\sqrt{pq}}$  mais aussi faire un calcul spécifique de l'erreur dans ce cas précis (qui ne sera pas développé ici).*

### Calcul de l'erreur sur $\text{Prob}(|\xi_n^*| \leq b)$ où $b$ est un réel positif quelconque

$\mathcal{S}_n$  suit une loi binomiale de paramètres  $n$  et  $p$ , et on pose  $\xi_n^* = \frac{\mathcal{S}_n - np}{\sqrt{npq}}$

Il est impossible de développer complètement les calculs menant à cet encadrement de l'erreur.

Je voudrais indiquer l'idée de départ et donner les résultats que j'ai trouvés.

**Préalable** : Les conditions sur  $n$  et  $p$  seront les suivantes :  $npq \geq \max\left(10 b^2 ; \frac{b^2}{25} ; 116 ; \frac{4}{b^2}\right)$

$$A = P(|\xi_n^*| \leq b) = \sum_{np-b\sqrt{npq} \leq k \leq np+b\sqrt{npq}} C_n^k p^k q^{n-k} = \sum_{np-b\sqrt{npq} \leq k \leq np+b\sqrt{npq}} \frac{n!}{k!(n-k)!} p^k q^{n-k}$$

On utilise alors l'encadrement suivant de  $n!$  (c.f. par exemple "Méthodes Stochastiques" de ZieZold-KriKenberg)

$$n^{n+0.5} e^{-n} e^{\frac{1}{12n+1}} \sqrt{2\pi} \leq n! \leq n^{n+0.5} e^{-n} e^{\frac{1}{12n}} \sqrt{2\pi}$$

Dans ce cas :

$$A \geq \frac{e^{\frac{1}{12n+1}}}{\sqrt{2\pi npq}} \sum_{np-b\sqrt{npq} \leq k \leq np+b\sqrt{npq}} \left(\frac{np}{k}\right)^{k+0.5} \left(\frac{q}{1-\frac{k}{n}}\right)^{n-k+0.5} e^{-\frac{1}{12k} - \frac{1}{12(n-k)}}$$

qui donne, après une étude de la dernière exponentielle :

$$A \geq \frac{\alpha_n}{\sqrt{2\pi npq}} \sum_{np-b\sqrt{npq} \leq k \leq np+b\sqrt{npq}} \left(\frac{np}{k}\right)^{k+0.5} \left(\frac{q}{1-\frac{k}{n}}\right)^{n-k+0.5}$$

$$\text{avec } \alpha_n = \exp\left(\frac{1}{12n+1} - \frac{1}{12n(pq - (q-p)b\sqrt{\frac{pq}{n} - \frac{b^2 pq}{n}})}\right)$$

Cette écriture n'étant valable que si  $np - b\sqrt{npq} > 0$  (1) et  $np + b\sqrt{npq} < n$  (2).

Les conditions (1) et (2) sont vérifiées.

Je vais utiliser la méthode du point médian. On a :

$$\sum_{np-b\sqrt{npq} \leq k \leq np+b\sqrt{npq}} \left(\frac{np}{k}\right)^{k+0.5} \left(\frac{q}{1-\frac{k}{n}}\right)^{n-k+0.5} = n \sum_{np-b\sqrt{npq} \leq k \leq np+b\sqrt{npq}} \frac{1}{n} f\left(\frac{k}{n}\right)$$

$$\text{avec } f(t) = \left(\frac{p}{t}\right)^{nt+0.5} \left(\frac{q}{1-t}\right)^{n-nt+0.5}$$

On a alors  $\left| \int_{\frac{k-0.5}{n}}^{\frac{k+0.5}{n}} f(t) dt - \frac{1}{n} f\left(\frac{k}{n}\right) \right| \leq \frac{K}{24n^3}$  où  $K$  est un majorant de  $|f''(t)|$  et  $p-b\sqrt{\frac{pq}{n}} \leq p+b\sqrt{\frac{pq}{n}}$ .  $K$  dépend de  $n, p$  et  $b$ .

On fait alors varier  $k$  et pour cela je suis amené à distinguer deux cas : le cas où  $np-b\sqrt{npq}$  est un entier, et le cas où c'en est pas un.

Je pose alors  $\alpha = p - \frac{[np+b\sqrt{npq}]+0.5}{n}$  et  $\beta = p - \frac{[np-b\sqrt{npq}]+0.5}{n}$  si  $np-b\sqrt{npq}$  n'est pas entier, sinon  $\beta = b\sqrt{\frac{pq}{n}} + \frac{0.5}{n}$ .

Dans les deux cas, il est facile de voir que  $-b\sqrt{\frac{pq}{n}} - \frac{0.5}{n} \leq \alpha \leq -b\sqrt{\frac{pq}{n}} + \frac{0.5}{n}$  et  $b\sqrt{\frac{pq}{n}} - \frac{0.5}{n} \leq \beta \leq b\sqrt{\frac{pq}{n}} + \frac{0.5}{n}$ .

On obtient alors  $A \geq \alpha_n \sqrt{\frac{n}{2\pi}} \int_{\alpha}^{\beta} e^{K(p,v)} dv - \frac{\alpha_n K\mu}{24n^2}$  avec  $e^{K(p,v)} = \left(\frac{p}{p-v}\right)^{np-nv} \left(\frac{q}{q+v}\right)^{nq+nv} \frac{1}{\sqrt{(p-v)(q+v)}}$  et  $\mu = \frac{2b\sqrt{npq}+1}{\sqrt{2\pi npq}}$ .

On développe  $K(p,v)$  sous la forme :  $K(p,v) = -\frac{1}{2} \ln pq - \frac{nv^2}{2pq} + X$  où  $X$  dépend de  $n, v, p, q$ .

Alors  $A \geq \alpha_n \sqrt{\frac{n}{2\pi}} \int_{\alpha}^{\beta} e^{K(p,v)} dv - \frac{\alpha_n K\mu}{24n^2} \geq \alpha_n \sqrt{\frac{n}{2\pi pq}} \int_{\alpha}^{\beta} e^{-\frac{nv^2}{2pq}} e^X dv - \frac{K\mu}{24n^2}$  (car  $\alpha_n$  est inférieur à 1), et on obtient de même une majoration similaire  $A \leq \sqrt{\frac{n}{2\pi pq}} \int_{\alpha}^{\beta} e^{-\frac{nv^2}{2pq}} e^X dv + \frac{K\mu}{24n^2}$ .

Les conditions que j'ai imposées au départ sur  $n, p, q$  et  $b$  permettent d'encadrer les termes  $X$  et  $K$  et alors de calculer l'erreur commise en remplaçant la loi binomiale par la loi normale.

Voici mes résultats :

$$\left| \text{Prob}(|\xi_n^*| \leq b) - \frac{1}{\sqrt{2\pi}} \int_{-b}^b e^{-\frac{u^2}{2}} du \right| \leq \frac{0,1062 + e^{-\frac{1}{2}\left(b - \frac{0.5}{\sqrt{npq}}\right)^2}}{\sqrt{2\pi npq}} \text{ pour } b \leq 3$$

$$\left| \text{Prob}(|\xi_n^*| \leq b) - \frac{1}{\sqrt{2\pi}} \int_{-b}^b e^{-\frac{u^2}{2}} du \right| \leq \frac{0,097}{\sqrt{npq}} \text{ pour } b \geq 3$$

**Exemple** :  $p=0,03$  ;  $n=4000$  ;  $np=120$  ;  $npq=116,4$  ;  $b = \frac{10}{\sqrt{116,4}}$ . On a :

$$A = \text{Prob}\left(110 \leq \sum_{i=0}^{4000} X_i \leq 130\right) = \text{Prob}\left(\left|\xi_{4000}^*\right| \leq \frac{10}{\sqrt{116,4}}\right)$$

le calcul donne une erreur inférieure à 0,02902 et donc une valeur de  $A$  comprise entre 0,6751 et 0,61699. La valeur réelle est d'environ 0,66969. Par conséquent l'approximation est relativement précise compte tenu du caractère un peu "limite" car la valeur minimale d'utilisation est  $npq$  supérieur à 116, et ici on a 116,4.