

Généralités

X est une variable aléatoire qui suit une loi binomiale $B(n; f)$. n est fixé et f inconnue.

E désigne l'ensemble $\{0; 1; \dots; n\}$. t est un réel de $]0; 1[$.

Pour tout événement A on note $P_r(A)$ la probabilité de A lorsque f vaut r .

Définition

Soient A et B deux applications de E dans $[0; 1]$. Soit $I(X)$ l'intervalle $[A(X); B(X)]$.

On dira que $I(X)$ est un intervalle de confiance de f au risque t lorsque $P_r(r \in I(X)) = 1 - t$.

Remarques :

Soit Ξ l'ensemble des intervalles inclus dans $[0; 1]$

$A(X)$ et $B(X)$ désignent deux variables aléatoires à valeurs dans $[0; 1]$.

Ainsi $I(X)$ est une variable aléatoire à valeurs dans Ξ .

L'événement « $r \in I(X)$ » devrait donc plutôt de noter « $I(X) \ni r$ ».

Utilisation d'une loi normale pour la recherche d'un intervalle de confiance.

On suppose donc que les conditions justifient l'utilisation d'une loi normale...

1. Méthode de l'ellipse

Si l'on note Y la variable aléatoire égale à $\frac{X}{n}$, on peut alors considérer que, lorsque $f = r$, Y

suit « à peu près » la loi normale de moyenne r et de variance $\sigma_r^2 = \frac{r(1-r)}{n}$.

α est le seuil de risque et u le réel tel que $\Pi(u) = 1 - \frac{\alpha}{2}$ où Π est la fonction de répartition de la loi normale centrée réduite. Soit $I(X)$ l'ensemble des r tels que $r - \sigma_r \cdot u \leq Y \leq r + \sigma_r \cdot u$

$I(X)$ est un intervalle de confiance de r au risque α puisque $P_r\left(-u \leq \frac{Y-r}{\sigma_r} \leq u\right) = 1 - \alpha$.

Ainsi, $r \in I(X)$ signifie $(r - Y)^2 \leq u^2 \cdot \frac{r(1-r)}{n}$ (I)

En notant $a = 1 + \frac{u^2}{n}$; $b(X) = 2Y + \frac{u^2}{n}$ et $c(X) = Y^2$ cette contrainte devient :

$$a \cdot r^2 - b(X) \cdot r + c(X) \leq 0. \quad (I')$$

Le discriminant de ce polynôme est $\Delta(X) = \dots = 4Y \frac{u^2}{n} (1-Y) + \frac{u^4}{n^2} = \delta(X)^2$.

Les résultats classiques concernant le signe du trinôme du second degré donnent :

$$I(X) = \left[\frac{b(X) - \delta(X)}{2a}, \frac{b(X) + \delta(X)}{2a} \right]$$

En Remplaçant Y par $\frac{X}{n}$ on obtient :

$$a = 1 + \frac{u^2}{n} \quad ; \quad b(X) = \frac{2X + u^2}{n} \quad ; \quad c(X) = \frac{X^2}{n^2} \quad ; \quad \delta(X) = \frac{u}{n} \sqrt{u^2 + 4X - \frac{4X^2}{n}}$$

Remarque :

Notons que $b(0) = \delta(0)$ et que $b(n) + \delta(n) = 2a$. Ainsi, ces formules fournissent des bornes raisonnables.

C'est la forme de l'inégalité (I) qui est à l'origine du nom de cette méthode ...

Correction de continuité : On remplace X par l'intervalle $[X - 0,5 ; X + 0,5]$

L'encadrement désiré $n \cdot r - u \cdot n \cdot \sigma_r \leq X \leq n \cdot r + u \cdot n \cdot \sigma_r$ devient :

$$\text{Si } X \neq 0 \text{ et } X \neq n \quad [X - 0,5 ; X + 0,5] \subset [n \cdot r - u \cdot n \cdot \sigma_r ; n \cdot r + u \cdot n \cdot \sigma_r]$$

$$\text{Si } X = 0 \quad [0 ; 0,5] \subset [n \cdot r - u \cdot n \cdot \sigma_r ; n \cdot r + u \cdot n \cdot \sigma_r]$$

$$\text{Si } X = n \quad [n - 0,5 ; n] \subset [n \cdot r - u \cdot n \cdot \sigma_r ; n \cdot r + u \cdot n \cdot \sigma_r]$$

$$\text{Posons : } b_1(z) = \frac{2z + u^2}{n} - \frac{u}{n} \sqrt{u^2 + 4z - \frac{4z^2}{n}} \quad \text{et} \quad b_2(z) = \frac{2z + u^2}{n} + \frac{u}{n} \sqrt{u^2 + 4z - \frac{4z^2}{n}}$$

En dérivant, on trouve que b_1' et b_2' sont positives sur $[0 ; n]$. Ainsi, la réunion des $I(z)$ où z parcourt une partie $[z_1 ; z_2]$ de $[0 ; n]$ est égale à $\left[\frac{b_1(z_1)}{2a} , \frac{b_2(z_2)}{2a} \right]$

En résumé :

$$\begin{array}{lll} \text{Si } X = 0 & \text{on prend} & I(0) = \left[0 , \frac{b_2(0,5)}{2a} \right] \\ \text{Si } 0 < X < n & & I(X) = \left[\frac{b_1(X - 0,5)}{2a} , \frac{b_2(X + 0,5)}{2a} \right] \\ \text{Si } X = n & & I(n) = \left[\frac{b_1(n - 0,5)}{2a} , 1 \right] \end{array}$$

2. Méthodes simplifiées

Dans ces deux cas, il faudra éventuellement tronquer l'intervalle obtenu par calcul pour ne garder que les valeurs effectivement contenues dans $[0 ; 1]$...

a. La plus célèbre

La simplification consiste à remplacer $\sigma_r^2 = \frac{r \cdot (1 - r)}{n}$ par son estimateur $s(X)^2 = \frac{Y \cdot (1 - Y)}{n - 1}$.

Cette méthode n'est donc pas utilisable lorsque $X = 0$ ou $X = n$

L'intervalle de confiance obtenu est $J(X) = \left[\frac{X}{n} - u \cdot s(X) , \frac{X}{n} + u \cdot s(X) \right]$.

La correction de continuité donne $J(X) = \left[\frac{2X-1}{2n} - u \cdot s(X) , \frac{2X+1}{2n} + u \cdot s(X) \right]$

b. La plus simple

On peut aussi remplacer σ_r^2 par son majorant $\frac{1}{4n}$...

On obtient alors l'intervalle $J^*(X) = \left[\frac{X}{n} - \frac{u}{2\sqrt{n}} , \frac{X}{n} + \frac{u}{2\sqrt{n}} \right]$

ou, avec correction de continuité : $J^*(X) = \left[\frac{2X-1}{2n} - \frac{u}{2\sqrt{n}} , \frac{2X+1}{2n} + \frac{u}{2\sqrt{n}} \right]$

Cette méthode, bien qu'assez grossière, possède l'avantage de son extrême simplicité...