

L'estimation par intervalles

Frédéric Bertrand¹

¹IRMA, Université de Strasbourg
Strasbourg, France

ESIEA 4ème Année 01-03-2012

Ce chapitre s'appuie essentiellement sur trois livres :

- 1 Le livre de Pascal Ardilly, administrateur de l'INSEE, « Les techniques de sondage », Éditions Technip, 2006.
- 2 Le livre de Jean-Jacques Dreesbeke, professeur à l'Université Libre de Bruxelles, « Éléments de statistiques », Université de Bruxelles, Ellipses, 2001.
- 3 Le livre de Gilbert Saporta, professeur au CNAM à Paris « Probabilités, Analyse de données et Statistique », Éditions Technip, 2006.

Sommaire

- 1 Introduction
- 2 Principe
- 3 Estimation de la moyenne μ d'une variable gaussienne
- 4 Estimation de la variance d'une variable gaussienne
- 5 Estimation d'une proportion

Il est souvent plus réaliste et plus intéressant de fournir un renseignement du type

$$a < \theta < b$$

plutôt que d'écrire sèchement

$$\hat{\theta}_n = c.$$

Définition

Fournir un tel intervalle $]a; b[$ s'appelle donner une estimation par intervalle de confiance de θ ou une estimation ensembliste de θ .

Sommaire

- 1 Introduction
- 2 Principe**
- 3 Estimation de la moyenne μ d'une variable gaussienne
- 4 Estimation de la variance d'une variable gaussienne
- 5 Estimation d'une proportion

La méthode des intervalles de confiance est la suivante :
Soit $\hat{\theta}_n$ un estimateur de θ dont nous connaissons la loi de probabilité pour chaque valeur de θ .

Définition

Étant donné une valeur θ_0 de θ , nous déterminons un intervalle de probabilité de niveau $1 - \alpha$ pour $\hat{\theta}_n$, c'est-à-dire deux bornes θ_1 et θ_2 telles que

$$\mathbb{P} \left[\theta_1 < \hat{\theta}_n < \theta_2 \mid \theta = \theta_0 \right] = 1 - \alpha.$$

Remarque

Ces bornes dépendent évidemment de θ_0 .

Remarque

Nous choisissons dans la plupart des cas un intervalle à risque symétrique $\alpha/2$ et $\alpha/2$.

Nous adoptons la règle de décision suivante.

Soit $\hat{\theta}_n(x_1, \dots, x_n) = \hat{\theta}_n(obs)$ la valeur observée de $\hat{\theta}_n$:

- si $\hat{\theta}_n(obs) \in]\theta_1; \theta_2[$, nous conservons θ_0 comme valeur possible du paramètre θ ;
- si $\hat{\theta}_n(obs) \notin]\theta_1; \theta_2[$, nous éliminons θ_0 .

Nous répétons cette opération pour toutes les valeurs de θ .

Définition

$]a; b[$ est qualifié d'un intervalle de confiance de niveau $(1 - \alpha)$ (coefficient de confiance).

Remarque

$]a; b[$ est un intervalle aléatoire car il dépend de $\hat{\theta}_n(obs)$.

$]a, b[$ s'obtient par :

$$\begin{cases} a = \theta_2^{-1}(\hat{\theta}_n(obs)) \\ b = \theta_1^{-1}(\hat{\theta}_n(obs)) \end{cases} .$$

Remarque

Si nous augmentons $1 - \alpha$, nous augmentons la longueur de l'intervalle de probabilité.

Remarque

Si n augmente, comme $\hat{\theta}_n$ est supposé convergent, $\text{Var} [\hat{\theta}_n]$ diminue donc $] \theta_1; \theta_2 [$ diminue.

Sommaire

- 1 Introduction
- 2 Principe
- 3 Estimation de la moyenne μ d'une variable gaussienne**
- 4 Estimation de la variance d'une variable gaussienne
- 5 Estimation d'une proportion

$\hat{\mu}_n$ est le meilleur estimateur de μ et $\hat{\mu}_n$ suit une loi $\mathcal{N}\left(\mu; \frac{\sigma^2}{n}\right)$.

Définition

L'intervalle de probabilité de $\hat{\mu}_n$ à $1 - \alpha$ est :

$$\mu - u_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} < \hat{\mu}_n < \mu + u_{1-\alpha/2} \frac{\sigma}{\sqrt{n}},$$

où u_p est le quantile d'ordre p pour la loi gaussienne centrée et réduite.

Définition

L'intervalle de confiance de $\hat{\mu}_n$ à $1 - \alpha$ est :

$$\hat{\mu}_n(x_1, \dots, x_n) - u_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} < \mu < \hat{\mu}_n(x_1, \dots, x_n) + u_{1-\alpha/2} \frac{\sigma}{\sqrt{n}},$$

où $u_{1-\alpha/2} = 1,96$ si $1 - \alpha = 0,95$.

Nous utilisons le fait que $T_{n-1} = \sqrt{n-1} \frac{\hat{\mu}_n - \mu}{S_n}$ suit une loi de Student à $(n-1)$ degrés de liberté.

Définition

L'intervalle de probabilité pour T_{n-1} à $1 - \alpha$ est :

$$-t_{n-1;1-\alpha/2} < \sqrt{n-1} \frac{\hat{\mu}_n - \mu}{S_n} < t_{n-1;1-\alpha/2},$$

où $t_{n-1;1-\alpha/2}$ est le quantile d'ordre $1 - \alpha/2$ pour la loi de Student à $(n-1)$ degrés de liberté.

Définition

L'intervalle de confiance pour μ à $1 - \alpha$ est :

$$\hat{\mu}_n(obs) - t_{n-1; 1-\alpha/2} \frac{S_n(obs)}{\sqrt{n-1}} < \mu < \hat{\mu}_n(obs) + t_{n-1; 1-\alpha/2} \frac{S_n(obs)}{\sqrt{n-1}},$$

ou bien

$$\hat{\mu}_n(obs) - t_{n-1; 1-\alpha/2} \frac{S_{n,c}(obs)}{\sqrt{n}} < \mu < \hat{\mu}_n(obs) + t_{n-1; 1-\alpha/2} \frac{S_{n,c}(obs)}{\sqrt{n}}.$$

Le théorème de la limite centrée a pour conséquence que les intervalles précédents sont valables pour estimer μ d'une loi quelconque lorsque la taille n de l'échantillon est assez grande.

Sommaire

- 1 Introduction
- 2 Principe
- 3 Estimation de la moyenne μ d'une variable gaussienne
- 4 Estimation de la variance d'une variable gaussienne**
- 5 Estimation d'une proportion

Nous utilisons le fait que

1 $S_n^{*2} = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$ est le meilleur estimateur de la variance σ^2 lorsque la moyenne μ est connue,

2 $\frac{nS_n^{*2}}{\sigma^2}$ suit une loi du khi-deux à n degrés de liberté comme la somme de n carrés de loi $\mathcal{N}(0; 1)$ indépendantes.

Définition

k_1 et k_2 sont les bornes de l'intervalle de probabilité d'une loi $\chi^2(n)$ si :

$$\mathbb{P} \left[k_1 < \frac{n S_n^{*2}}{\sigma^2} < k_2 \right] = 1 - \alpha.$$

Définition

L'intervalle de confiance pour σ^2 à $1 - \alpha$ est :

$$\frac{n S_n^{*2}(x_1, \dots, x_n)}{k_2} < \sigma^2 < \frac{n S_n^{*2}(x_1, \dots, x_n)}{k_1}.$$

Nous utilisons le fait que

$$1 \quad S_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \hat{\mu}_n)^2,$$

- 2 $\frac{nS_n^2}{\sigma^2}$ suit une loi du khi-deux à $(n - 1)$ degrés de liberté comme la somme de $(n - 1)$ carrés de loi $\mathcal{N}(0; 1)$ indépendantes.

Définition

l_1 et l_2 sont les bornes de l'intervalle de probabilité d'un $\chi^2(n-1)$ si :

$$\mathbb{P} \left[l_1 < \frac{nS_n^2}{\sigma^2} < l_2 \right] = 1 - \alpha.$$

Définition

L'intervalle de confiance pour σ^2 est alors :

$$\frac{nS_n^2(x_1, \dots, x_n)}{l_2} < \sigma^2 < \frac{nS_n^2(x_1, \dots, x_n)}{l_1}.$$

Sommaire

- 1 Introduction
- 2 Principe
- 3 Estimation de la moyenne μ d'une variable gaussienne
- 4 Estimation de la variance d'une variable gaussienne
- 5 Estimation d'une proportion**

- Étant donné une population INFINIE (ou finie si le tirage s'effectue avec remise) où une proportion π_A des individus possède un certain caractère A , il s'agit de trouver un intervalle de confiance pour π_A à partir de $\hat{\pi}_{n,A}$, proportion trouvée dans un échantillon de taille n .
- Nous savons que $n\hat{\pi}_{n,A}$ suit une loi binomiale $\mathcal{B}(n; \pi_A)$. Deux cas alors se présentent :
 - 1 Si n est petit nous utiliserons les tables de la loi binomiale.
 - 2 Si n est grand nous savons que $\hat{\pi}_{n,A}$ suit une loi gaussienne de paramètres π_A et $\frac{\pi_A(1 - \pi_A)}{n}$.

Définition

L'intervalle de probabilité symétrique « approché » est :

$$\pi_A - u_{1-\alpha/2} \sqrt{\frac{\pi_A(1-\pi_A)}{n}} < \hat{\pi}_{n,A} < \pi_A + u_{1-\alpha/2} \sqrt{\frac{\pi_A(1-\pi_A)}{n}}.$$

Définition

L'intervalle de confiance « approché » est alors :

$$\begin{aligned} \hat{\pi}_{n,A}(\text{obs}) - u_{1-\alpha/2} \sqrt{\frac{\hat{\pi}_{n,A}(\text{obs})(1-\hat{\pi}_{n,A}(\text{obs}))}{n}} < \pi_A \\ < \hat{\pi}_{n,A}(\text{obs}) + u_{1-\alpha/2} \sqrt{\frac{\hat{\pi}_{n,A}(\text{obs})(1-\hat{\pi}_{n,A}(\text{obs}))}{n}}. \end{aligned}$$