

Chapitre 4

Intervalles de confiance

Dans une étude statistique, on peut se demander si les mesures observées peuvent correspondre à une certaine réalité. Par exemple, est-ce que notre série de jets d'une pièce de monnaie ($P; P; F; P; F; P$) peut correspondre à une pièce bien équilibrée ?

Pour répondre à cette question, on cherche à estimer la probabilité p que la pièce montre pile. Si on arrive à établir que $p = \frac{1}{2}$, alors la pièce est parfaitement équilibrée. Malheureusement, il est extrêmement difficile, voire impossible, de montrer que $p = \frac{1}{2}$.

On peut tenter d'estimer p à l'aide d'un estimateur \hat{P} , mais la probabilité $\mathbf{P}(\hat{P} = p)$ que \hat{P} soit exactement égal au paramètre p est, en général, extrêmement petite, voire nulle¹. Par conséquent, il est nécessaire de s'intéresser à la probabilité

$$\mathbf{P}(\hat{P} \geq p - r \text{ et } \hat{P} \leq p + r) = \mathbf{P}(\hat{P} - r \leq p \leq \hat{P} + r) = \mathbf{P}([\hat{P} - r, \hat{P} + r] \ni p)$$

Cette probabilité s'approche de 1 au fur et à mesure que le nombre positif r devient grand. Néanmoins, plus r grandit, plus l'approximation de p par un intervalle perd en précision. Il faut donc trouver des compromis.

Définition

Un *intervalle de confiance* est un intervalle $[G, D]$ qui contient le paramètre θ à estimer avec une certaine probabilité β (G et D sont des variables aléatoires).

$$\mathbf{P}([G, D] \ni \theta) = \beta$$

On dit que β est le *seuil de confiance* ou encore la *probabilité de couverture*, tandis que $\alpha = 1 - \beta$ est appelé le *risque d'erreur*.

Construction d'un intervalle de confiance

Pour construire un intervalle de confiance pour le paramètre θ , on commence par choisir le seuil de confiance β désiré (ce qui est équivalent à choisir un risque d'erreur $\alpha = 1 - \beta$). Ensuite, il faut réussir à déterminer le nombre positif r correspondant en utilisant la distribution théorique de l'estimateur $\hat{\theta}$.

Comme d'habitude, on choisit un seuil de confiance de 95% dans une démarche infirmative, et un seuil de confiance de 99% dans une démarche confirmative.

1. De plus, la probabilité pour que deux estimations \hat{p}_1 et \hat{p}_2 de l'estimateur \hat{P} soient égales est aussi, en général, extrêmement faible.

4.1 L'intervalle de confiance sur une moyenne, variance connue


On considère n variables aléatoires indépendantes, notées X_1, X_2, \dots, X_n , qui suivent toutes une loi normale $\mathcal{N}(\mu, \sigma^2)$ où seul le paramètre σ est connu. Pour estimer μ , on prend le MLE \bar{X} qui est aussi sans biais. Sous ces hypothèses, \bar{X} suit une loi normale de paramètres $\mathcal{N}(\mu, \frac{\sigma^2}{n})$. Afin de déterminer l'intervalle de confiance, on va devoir centrer-réduire cet estimateur de sorte à pouvoir utiliser la table concernant la fonction de répartition ϕ de la loi normale $\mathcal{N}(0, 1)$. On trouvera l'intervalle de confiance suivant :

$$\left[\bar{X} - \phi^{-1}\left(1 - \frac{\alpha}{2}\right) \cdot \frac{\sigma}{\sqrt{n}}, \bar{X} + \phi^{-1}\left(1 - \frac{\alpha}{2}\right) \cdot \frac{\sigma}{\sqrt{n}} \right]$$

En effet, on cherche $r > 0$ tel que :

$$\begin{aligned} 1 - \alpha &= \beta = \mathbf{P}([\bar{X} - r, \bar{X} + r] \ni \mu) = \mathbf{P}(\bar{X} - r \leq \mu \leq \bar{X} + r) \\ &= \mathbf{P}(\bar{X} \geq \mu - r \text{ et } \bar{X} \leq \mu + r) = \mathbf{P}(\mu - r \leq \bar{X} \leq \mu + r) \\ &= \mathbf{P}(-r \leq \bar{X} - \mu \leq r) = \mathbf{P}\left(\frac{-r}{\frac{\sigma}{\sqrt{n}}} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq \frac{r}{\frac{\sigma}{\sqrt{n}}}\right) \end{aligned}$$

On s'est maintenant ramené à la loi normale centrée réduite Z .



On peut ensuite utiliser la fonction de répartition ϕ de la loi normale centrée réduite.

$$\begin{aligned} 1 - \alpha &= \mathbf{P}\left(\frac{-r}{\frac{\sigma}{\sqrt{n}}} \leq Z \leq \frac{r}{\frac{\sigma}{\sqrt{n}}}\right) = \mathbf{P}\left(Z \leq \frac{r}{\frac{\sigma}{\sqrt{n}}}\right) - \mathbf{P}\left(Z < \frac{-r}{\frac{\sigma}{\sqrt{n}}}\right) \\ &= \mathbf{P}\left(Z \leq \frac{r}{\frac{\sigma}{\sqrt{n}}}\right) - \underbrace{\left(1 - \mathbf{P}\left(Z \leq \frac{r}{\frac{\sigma}{\sqrt{n}}}\right)\right)}_{\text{par symétrie}} = 2\mathbf{P}\left(Z \leq \frac{r}{\frac{\sigma}{\sqrt{n}}}\right) - 1 \\ &= 2\phi\left(\frac{r}{\frac{\sigma}{\sqrt{n}}}\right) - 1 \quad \text{car } \mathbf{P}\left(Z < \frac{-r}{\frac{\sigma}{\sqrt{n}}}\right) = \mathbf{P}\left(Z > \frac{r}{\frac{\sigma}{\sqrt{n}}}\right) \text{ par symétrie} \end{aligned}$$

Finalement, on isole r :

$$\begin{aligned} 1 - \alpha &= 2\phi\left(\frac{r}{\frac{\sigma}{\sqrt{n}}}\right) - 1 \iff 2\phi\left(\frac{r}{\frac{\sigma}{\sqrt{n}}}\right) = 2 - \alpha \iff \phi\left(\frac{r}{\frac{\sigma}{\sqrt{n}}}\right) = 1 - \frac{\alpha}{2} \\ &\iff \frac{r}{\frac{\sigma}{\sqrt{n}}} = \phi^{-1}\left(1 - \frac{\alpha}{2}\right) \iff r = \phi^{-1}\left(1 - \frac{\alpha}{2}\right) \cdot \frac{\sigma}{\sqrt{n}} \end{aligned}$$

4.2 L'intervalle de confiance sur une moyenne, variance inconnue

On considère n variables aléatoires indépendantes, notées X_1, X_2, \dots, X_n , qui suivent toutes une loi normale $\mathcal{N}(\mu, \sigma^2)$ où le paramètre σ est aussi inconnu. Pour estimer μ , on prend le MLE \bar{X} qui est aussi sans biais. Sous ces hypothèses, \bar{X} suit une loi normale de paramètres $\mathcal{N}(\mu, \frac{\sigma^2}{n})$.

Malheureusement, comme on ne connaît pas σ , ce n'est pas très utile. Mais, en utilisant l'estimateur sans biais de σ , noté S , on peut utiliser le résultat de William Gosset : la variable aléatoire $\frac{\bar{X}-\mu}{S/\sqrt{n}}$ suit une distribution de Student avec $n - 1$ degrés de liberté.

Afin de déterminer l'intervalle de confiance, on procède comme ci-dessus de sorte à pouvoir utiliser la table concernant la fonction de répartition ϕ_{n-1} de la loi de Student à $n - 1$ degrés de liberté.

On trouvera l'intervalle de confiance suivant :

$$\left[\bar{X} - \phi_{n-1}^{-1}\left(1 - \frac{\alpha}{2}\right) \cdot \frac{S}{\sqrt{n}}, \bar{X} + \phi_{n-1}^{-1}\left(1 - \frac{\alpha}{2}\right) \cdot \frac{S}{\sqrt{n}} \right]$$

2. Ce n'est pas la variable centrée réduite de \bar{X} , car on a remplacé σ par son estimateur sans biais S .