



Construction d'intervalles de confiance

Mathieu Fauvernier

Equipe Biostatistique-Santé, UMR CNRS 5558, Université Lyon 1
Service de Biostatistique, Hospices Civils de Lyon

Section 1

Intervalle de confiance d'une moyenne

Rappel : théorème central limite

Soient X_1, \dots, X_n des v.a.r indépendantes, de même loi, et admettant une variance.

On note $\mu = E(X_1)$ et $\sigma^2 = \text{Var}(X_1)$.

Alors,

$$\hat{\mu} = \bar{X}_n \underset{n \rightarrow \infty}{\sim} \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right)$$

Intervalle de fluctuation

Autrement dit, on a la relation suivante

$$P\left(\mu - 1.96\frac{\sigma}{\sqrt{n}} < \hat{\mu} < \mu + 1.96\frac{\sigma}{\sqrt{n}}\right) = 95\%$$

Il s'agit ici d'un **intervalle de fluctuation** d'une variable aléatoire

Intervalle de fluctuation

Autrement dit, on a la relation suivante

$$P\left(\mu - 1.96\frac{\sigma}{\sqrt{n}} < \hat{\mu} < \mu + 1.96\frac{\sigma}{\sqrt{n}}\right) = 95\%$$

Il s'agit ici d'un **intervalle de fluctuation** d'une variable aléatoire

Or, de notre côté nous souhaitons un encadrement du paramètre inconnu μ

Intervalle de confiance de la moyenne

En inversant la relation précédente, on peut montrer qu'un encadrement de μ est donné par

$$P\left(\hat{\mu} - 1.96 \frac{\hat{\sigma}}{\sqrt{n}} < \mu < \hat{\mu} + 1.96 \frac{\hat{\sigma}}{\sqrt{n}}\right) = 95\%$$

On appelle cet encadrement l'**intervalle de confiance** à 95% de μ .

Intervalle de confiance : illustration 1

On dispose d'un échantillon représentatif de 50 individus avec pour taille moyenne $\hat{\mu}=175\text{cm}$ et pour écart-type $\hat{\sigma}=50\text{cm}$.

L'intervalle de confiance à 95% de la vraie moyenne μ (celle de la population) est

$$IC_{95\%}(\mu) = \left[\hat{\mu} - 1.96 \frac{\hat{\sigma}}{\sqrt{n}}; \hat{\mu} + 1.96 \frac{\hat{\sigma}}{\sqrt{n}} \right]$$

$$IC_{95\%}(\mu) = [161; 189]$$

Intervalle de confiance : illustration 2

On dispose d'un échantillon représentatif de **500** individus avec pour taille moyenne $\hat{\mu}=175\text{cm}$ et pour écart-type $\hat{\sigma}=50\text{cm}$.

L'intervalle de confiance à 95% de la vraie moyenne μ (celle de la population) est

$$IC_{95\%}(\mu) = \left[\hat{\mu} - 1.96 \frac{\hat{\sigma}}{\sqrt{n}}; \hat{\mu} + 1.96 \frac{\hat{\sigma}}{\sqrt{n}} \right]$$

$$IC_{95\%}(\mu) = [171; 179]$$

Intervalle de confiance : illustration 3

On dispose d'un échantillon représentatif de **5000** individus avec pour taille moyenne $\hat{\mu}=175\text{cm}$ et pour écart-type $\hat{\sigma}=50\text{cm}$.

L'intervalle de confiance à 95% de la vraie moyenne μ (celle de la population) est

$$IC_{95\%}(\mu) = \left[\hat{\mu} - 1.96 \frac{\hat{\sigma}}{\sqrt{n}}; \hat{\mu} + 1.96 \frac{\hat{\sigma}}{\sqrt{n}} \right]$$

$$IC_{95\%}(\mu) = [174; 176]$$

Section 2

Intervalle de confiance d'une proportion

Estimation d'une proportion

On cherche à estimer la proportion p de malades dans une population (p est appelée la prévalence).

On dispose d'une échantillon aléatoire i.i.d X_1, \dots, X_n avec $X_i \sim \mathcal{B}(p)$

Ainsi, pour tout i , $E(X_i) = p$ et $Var(X_i) = p(1 - p)$.

Estimation d'une proportion

On cherche à estimer la proportion p de malades dans une population (p est appelée la prévalence).

On dispose d'un échantillon aléatoire i.i.d X_1, \dots, X_n avec $X_i \sim \mathcal{B}(p)$

Ainsi, pour tout i , $E(X_i) = p$ et $Var(X_i) = p(1 - p)$.

p n'est rien d'autre qu'une moyenne de 0 et de 1. Ainsi, le théorème central limite nous donne

$$\hat{p} = \bar{X}_n \underset{n \rightarrow \infty}{\sim} \mathcal{N}\left(p, \frac{p(1-p)}{n}\right)$$

Intervalle de confiance d'une proportion

En reprenant les mêmes arguments que ceux exposés plus haut, on peut montrer qu'un encadrement de p est donné par

$$P \left(\hat{p} - 1.96 \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} < p < \hat{p} + 1.96 \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \right) = 95\%$$

On appelle cet encadrement l'**intervalle de confiance** à 95% de p .

Intervalle de confiance : illustration 4

On dispose d'un échantillon représentatif de 50 individus avec pour proportion de malades $\hat{p}=0.15$.

L'intervalle de confiance à 95% de la vraie proportion p (celle de la population) est

$$IC_{95\%}(p) = \left[\hat{p} - 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}; \hat{p} + 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \right]$$

$$IC_{95\%}(p) = [0.05; 0.25]$$

Intervalle de confiance : illustration 5

On dispose d'un échantillon représentatif de **500** individus avec pour proportion de malades $\hat{p}=0.15$.

L'intervalle de confiance à 95% de la vraie proportion p (celle de la population) est

$$IC_{95\%}(p) = \left[\hat{p} - 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{\mathbf{n}}}; \hat{p} + 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{\mathbf{n}}} \right]$$

$$IC_{95\%}(p) = [\mathbf{0.12}; \mathbf{0.18}]$$

Intervalle de confiance : illustration 6

On dispose d'un échantillon représentatif de **5000** individus avec pour proportion de malades $\hat{p}=0.15$.

L'intervalle de confiance à 95% de la vraie proportion p (celle de la population) est

$$IC_{95\%}(p) = \left[\hat{p} - 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{\mathbf{n}}}; \hat{p} + 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{\mathbf{n}}} \right]$$

$$IC_{95\%}(p) = [\mathbf{0.14}; \mathbf{0.16}]$$

Exercice 1

Un sondage réalisé sur un échantillon de 1000 votants avant le deuxième tour de la présidentielle donne le candidat A vainqueur à $\hat{p}=51\%$.

L'écart avec le candidat B est-il statistiquement significatif (la proportion estimée est-elle statistiquement différente de 0.5) ?

Exercice 1

Un sondage réalisé sur un échantillon de 1000 votants avant le deuxième tour de la présidentielle donne le candidat A vainqueur à $\hat{p}=51\%$.

L'écart avec le candidat B est-il statistiquement significatif (la proportion estimée est-elle statistiquement différente de 0.5) ?

L'intervalle de confiance à 95% de la vraie moyenne p (celle de la population de votants) est

$$IC_{95\%}(p) = \left[\hat{p} - 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}; \hat{p} + 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \right]$$

$$IC_{95\%}(p) = [0.48; 0.54]$$

Exercice 1

Un sondage réalisé sur un échantillon de 1000 votants avant le deuxième tour de la présidentielle donne le candidat A vainqueur à $\hat{p}=51\%$.

L'écart avec le candidat B est-il statistiquement significatif (la proportion estimée est-elle statistiquement différente de 0.5) ?

L'intervalle de confiance à 95% de la vraie moyenne p (celle de la population de votants) est

$$IC_{95\%}(p) = \left[\hat{p} - 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}; \hat{p} + 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \right]$$

$$IC_{95\%}(p) = [0.48; 0.54]$$

L'intervalle contient la valeur 0.5 donc l'écart n'est pas significatif

Exercice 2

Un sondage réalisé sur un échantillon de 1000 votants avant le deuxième tour de la présidentielle donne le candidat A vainqueur à $\hat{p}=55\%$.

La proportion estimée est-elle statistiquement différente de 0.5 ?

Exercice 2

Un sondage réalisé sur un échantillon de 1000 votants avant le deuxième tour de la présidentielle donne le candidat A vainqueur à $\hat{p}=55\%$.

La proportion estimée est-elle statistiquement différente de 0.5 ?

L'intervalle de confiance à 95% de la vraie moyenne p (celle de la population de votants) est

$$IC_{95\%}(p) = \left[\hat{p} - 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}; \hat{p} + 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \right]$$

$$IC_{95\%}(p) = [0.52; 0.58]$$

Exercice 2

Un sondage réalisé sur un échantillon de 1000 votants avant le deuxième tour de la présidentielle donne le candidat A vainqueur à $\hat{p}=55\%$.

La proportion estimée est-elle statistiquement différente de 0.5 ?

L'intervalle de confiance à 95% de la vraie moyenne p (celle de la population de votants) est

$$IC_{95\%}(p) = \left[\hat{p} - 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}; \hat{p} + 1.96\sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \right]$$

$$IC_{95\%}(p) = [0.52; 0.58]$$

La proportion estimée est statistiquement différente de 0.5

Exercice 3

On dispose d'un échantillon représentatif de 100 individus avec pour taux moyen de triglycérides $\hat{\mu}=0.38\text{g/L}$ et pour écart-type $\hat{\sigma}=0.5\text{g/L}$.

Le taux moyen estimé est-il statistiquement anormal (en dehors des bornes 0.45 et 1.75 g/L) ?

Exercice 3

On dispose d'un échantillon représentatif de 100 individus avec pour taux moyen de triglycérides $\hat{\mu}=0.38\text{g/L}$ et pour écart-type $\hat{\sigma}=0.5\text{g/L}$.

Le taux moyen estimé est-il statistiquement anormal (en dehors des bornes 0.45 et 1.75 g/L) ?

L'intervalle de confiance à 95% de la vraie moyenne μ est

$$IC_{95\%}(\mu) = \left[\hat{\mu} - 1.96 \frac{\hat{\sigma}}{\sqrt{n}}; \hat{\mu} + 1.96 \frac{\hat{\sigma}}{\sqrt{n}} \right]$$

$$IC_{95\%}(\mu) = [0.28; 0.48]$$

Exercice 3

On dispose d'un échantillon représentatif de 100 individus avec pour taux moyen de triglycérides $\hat{\mu}=0.38\text{g/L}$ et pour écart-type $\hat{\sigma}=0.5\text{g/L}$.

Le taux moyen estimé est-il statistiquement anormal (en dehors des bornes 0.45 et 1.75 g/L) ?

L'intervalle de confiance à 95% de la vraie moyenne μ est

$$IC_{95\%}(\mu) = \left[\hat{\mu} - 1.96 \frac{\hat{\sigma}}{\sqrt{n}}; \hat{\mu} + 1.96 \frac{\hat{\sigma}}{\sqrt{n}} \right]$$

$$IC_{95\%}(\mu) = [0.28; 0.48]$$

Le taux moyen estimé n'est pas statistiquement anormal