

Chapitre 5 : Estimation

5.1 « Prédiction » de la valeur d'une loi normale

A) Loi normale centrée réduite

Si $Z \sim \mathcal{N}(0; 1)$, alors

$$\begin{aligned} \blacktriangleright \mathbb{P}[-1,96 \leq Z \leq 1,96] &= \underbrace{F(1,96)}_{0,975} - \underbrace{F(-1,96)}_{1 - \underbrace{F(1,96)}_{0,975}} \\ &\simeq 0,975 - (1 - 0,975) \simeq 0,95 \end{aligned}$$

- ▶ Donc avec la confiance 95%,
 Z doit être entre -1,96 et 1,96
- ▶ $\mathbb{P}[-2,576 \leq Z \leq 2,576] \simeq 0,99$
- ▶ Donc avec la confiance 99%,
 Z doit être entre -2,576 et 2,576
- ▶ Pour d'autres niveaux de confiance : table en bas de la page 10 du formulaire.

B) Loi normale générale

Si $X \sim \mathcal{N}(\mu; \sigma)$, alors

$$\begin{aligned} \blacktriangleright \mathbb{P}[\mu - 1,96\sigma \leq X \leq \mu + 1,96\sigma] \\ = \mathbb{P}\left[\underbrace{\frac{\mu - 1,96\sigma - \mu}{\sigma}}_{-1,96} \leq \underbrace{\frac{X - \mu}{\sigma}}_Z \leq \underbrace{\frac{\mu + 1,96\sigma - \mu}{\sigma}}_{1,96}\right] \\ = \mathbb{P}[-1,96 \leq Z \leq 1,96] \simeq 0,95 \end{aligned}$$

- ▶ Donc avec la confiance 95%,
 X doit être entre $\mu - 1,96\sigma$ et $\mu + 1,96\sigma$
- ▶ Autres niveaux de confiance : remplacer 1,96 par la valeur issue de la table en bas de la page 10 du formulaire

5.2 Estimation d'une proportion

Question : Quelle est la proportion p des étudiant·e·s Dijonnais qui sont stressé·e·s ?

- ▶ Échantillon de 75 étudiant·e·s, parmi lesquels X sont stressé·e·s

A) Ce qu'on pourrait dire si on connaissait la proportion p

Par exemple si on sait que $p = 0,4$, alors

$$X \approx \mathcal{B}(75; 0,4) \approx \mathcal{N}\left(\underbrace{30}_{75 \times 0,4}; \underbrace{4,24}_{\sqrt{75 \times 0,4 \times 0,6}}\right).$$

Avec la confiance 95%,

X est donc dans l'intervalle $\left[\underbrace{22}_{30 - 1,96 \times 4,24}; \underbrace{38}_{30 + 1,96 \times 4,24}\right]$

Conclusion : si dans notre échantillon le nombre d'individus stressés n'est pas dans cet intervalle, on conclura avec la confiance 95% que ces probabilités sont incorrectes, et que la proportion p n'était pas égale à 0,4.

B) Si on ne connaît pas p (on essaie de l'estimer)

$$X \approx \mathcal{B}(75, p) \approx \mathcal{N}(75 p; \sqrt{75 \times p \times (1 - p)})$$

$P = \frac{X}{75}$: proportion qui sont stressé·e·s parmi l'échantillon

$m(P) = \frac{m(X)}{75} = p$ et $s(P) = \frac{s(X)}{75} = \sqrt{\frac{p \times (1 - p)}{75}}$, et on peut montrer que

$$P \approx \mathcal{N}\left(p; \underbrace{\sqrt{\frac{p \times (1 - p)}{75}}}_s\right).$$

Avec la confiance 95% P est dans l'intervalle

$$[p - 1,96 s; p + 1,96 s].$$

C) Estimation

Supposons qu'on réalise l'expérience : parmi 75 étudiant·e·s choisi·e·s au hasard, 18 sont stressé·e·s

- ▶ $p_e = 6326$: proportion expérimentale
- ▶ p_e devrait être dans $[p - 1,96 s ; p + 1,96 s]$
(avec confiance 95%)
- ▶ donc p devrait être dans $[p_e - 1,96 s ; p_e + 1,96 s]$
(avec confiance 95%)
- ▶ on approxime $s \simeq 2,55$.
- ▶ donc $p_e - 1,96s \simeq 1,3$ et $p_e + 1,96s \simeq$

On lit sur la table inverse que pour la confiance 0,95
1,96 d'où $a_\alpha = z_\alpha \frac{s_e}{\sqrt{n-1}} \simeq 0,03204$

On estime donc que μ est dans l'intervalle $[2,55 - 0,03204 ; 2,55 + 0,03204] \simeq$
 $[2,52 ; 2,58]$, avec la confiance $c = 0,95$..

- ▶ Avec la confiance 95%, on affirme que la proportion p est dans l'intervalle $[0,144 ; 0,336]$

Remarque : Cet intervalle s'appelle « intervalle de confiance »

D) Procédure générale (page 5 du formulaire)

- ▶ Échantillon de taille n , au sein d'une population qui contient beaucoup d'individus
- ▶ p_e : proportion au sein de l'échantillon
- ▶ c niveau de confiance que l'on souhaite
- ↪ risque d'erreur $\alpha = 1 - c$ (exemple : la confiance $c = 95\%$ signifie un risque d'erreur $\alpha = 5\%$).

Hypothèses à vérifier

$$n \geq 30, n p_e \geq 5 \text{ et } n(1 - p_e) \geq 5.$$

Dans ce cas, le formulaire indique comment calculer un intervalle de confiance :

- ▶ La table du formulaire indique un nombre z_α selon le niveau de confiance
- ▶ On calcule $a_\alpha = z_\alpha \sqrt{\frac{p_e(1-p_e)}{n}}$, puis on calcule les nombres $p_e - a_\alpha$ et $p_e + a_\alpha$.
- ▶ Avec la confiance $c = 1 - \alpha$, on peut affirmer que le proportion sur l'ensemble de la population se trouve dans l'intervalle $[p_e - a_\alpha, p_e + a_\alpha]$.

E) Taille de l'échantillon (page 5 du formulaire)

- ▶ Pour avoir une précision h (c'est à dire $a_\alpha < h$), prendre un échantillon de taille $n > z_\alpha^2 \frac{p_e(1-p_e)}{h^2}$.
- ▶ Si on ne connaît pas p_e , il suffit de prendre $n > z_\alpha^2 \frac{1}{4h^2}$.

5.3 Estimation d'une moyenne

A) Procédure du formulaire (page 5 du formulaire)

- ▶ Échantillon de taille n , au sein d'une population qui contient beaucoup d'individus
- ▶ m_e et s_e : moyenne et écart type au sein de l'échantillon
- ▶ c niveau de confiance que l'on souhaite
- ▶ On veut estimer la moyenne μ au sein de la grande population

Premier cas : si $n \geq 30$

- ▶ La table du formulaire indique un nombre z_α selon le niveau de confiance
- ▶ On calcule $a_\alpha = z_\alpha \frac{s_e}{\sqrt{n-1}}$, puis on calcule les nombres $m_e - a_\alpha$ et $m_e + a_\alpha$.
- ▶ Avec la confiance $c = 1 - \alpha$, on peut affirmer que μ se trouve dans l'intervalle $[m_e - a_\alpha, m_e + a_\alpha]$.

Deuxième cas : si $n < 30$

- ▶ On doit supposer que la variable suit une loi normale
- ▶ On lit un seuil t_α dans la table de la loi de student à $n - 1$ degrés de liberté : page 11, ligne $n - 1$, colonne $p = \alpha/2$.
- ▶ On calcule $a_\alpha = t_\alpha \frac{s_e}{\sqrt{n-1}}$, puis on calcule les nombres $m_e - a_\alpha$ et $m_e + a_\alpha$.
- ▶ Avec la confiance $c = 1 - \alpha$, on peut affirmer que μ se trouve dans l'intervalle $[m_e - a_\alpha, m_e + a_\alpha]$.

B) Exemples

Données de l'exercice 8

▶ On a déjà $n = 16$, que $m_e = 28,94$ et $s_e = 7,09$.

▶ On utilise la confiance $c = 0,95$ et on applique la procédure du cas où $n \geq 30$:

On cherche t_α dans la table page 11 du formulaire, en ligne 15 (car $16 - 1 = 15$) et colonne 0,025 (car $c = 0,95$),

On lit $t_\alpha \simeq 2,1314$ d'où $a_\alpha = t_\alpha \frac{s_e}{\sqrt{n-1}} \simeq 3,9018$.

On estime donc que μ est dans l'intervalle

$[28,94 - 3,9018 ; 28,94 + 3,9018] \simeq [25,04 ; 32,84]$

avec la confiance $c = 0,95$

Données de l'exercice 25

▶ Niveaux d'anxiété avant thérapie : $n = 7,09$, que $m_e =$

On lit dans la table du χ^2 à 15 degrés de liberté la valeur 6,262 correspondant à $p = 0,025$ et la valeur $x_2 = 27,49$ correspondant à $q = 0,025$

Cela donne $s_e \sqrt{\frac{n}{x_2}} \simeq 7,09 \sqrt{\frac{16}{27,49}} \simeq 5,41$

et $s_e \sqrt{\frac{n}{x_1}} \simeq 7,09 \sqrt{\frac{16}{6,262}} \simeq 11,3$

On estime donc que l'ecarttype est dans l'intervalle $[$ 0,95. et $s_e = 16$.

▶ On prend la confiance $c = 0,95$, et en supposant qu'on ait une loi normale, on applique la procédure pour $n < 30$:

▶ 7,09

C) Taille de l'échantillon (page 5 du formulaire)

- ▶ Pour avoir une précision h (c'est à dire $a_\alpha < h$), prendre un échantillon de taille $n > z_\alpha^2 \frac{(s_e)^2}{h^2}$.

5.4 Estimation d'un écart type

A) Procédure du formulaire (page 6 du formulaire)

- ▶ On lit dans la table du χ^2 à $n - 1$ degrés de libertés deux nombres x_1 et x_2 :
 - ▶ Ligne $n - 1$ de la table en page 12 du formulaire.
 - ▶ x_1 est à la colonne $q = \frac{1-c}{2}$ et x_2 à la colonne $p = \frac{1-c}{2}$.
- ▶ Avec la confiance c , on peut affirmer que l'écart type sur l'ensemble de la population est dans l'intervalle $\left[s_e \sqrt{\frac{n}{x_2}}; s_e \sqrt{\frac{n}{x_1}} \right]$.

B) Exemple (exercice 25)

- ▶ $n = ??$, et $s_e = ??$.
- ▶ ??

5.5 Que conclure d'un intervalle de confiance ?

- ▶ Si la question est par exemple « L'anxiété moyenne est-elle plus grande que 30 ? », ou « La proportion d'étudiants stressés est-elle plus petite que 40% ? »
 - ▶ On parvient à conclure uniquement si la valeur de l'énoncé est en dehors de l'intervalle de confiance.
- ▶ Si la question est par exemple « L'anxiété moyenne est-elle plus petite après la thérapie qu'avant ? »
 - ▶ Si les deux intervalles se chevauchent, on ne peut pas conclure. S'ils sont disjoints, on peut conclure.
 - ▶ Dans le cas de variables appariées, on peut calculer leur différence et se demander si la moyenne de la différence est positive ou négative.