

**Vrai ou faux**

1- Faux : la variance de la somme de deux variables aléatoires est égale à la somme de leurs variances si et seulement si leur covariance est nulle. C'est en particulier le cas lorsque les deux variables aléatoires en question sont indépendantes.

- 2- Vrai
- 3- Vrai
- 4- Vrai

**Exercice 1**

**Première partie**

1- La variable aléatoire  $X_i$  définie par  $X_i = 0$  si l'individu  $i$  ne fume pas et  $X_i = 1$  si l'individu  $i$  fume suit une loi de Bernoulli de paramètre  $p$ . Le tirage s'effectue dans une très large population (par rapport à la taille de l'échantillon). Dans ce cas, même si le tirage est fait sans remise, on peut considérer que les variables  $X_i$  sont indépendantes et identiquement distribuées, comme s'il avait été fait avec remise.

2-  $\hat{p}_n = \frac{1}{n} \sum_{i=1}^n X_i$  est un estimateur convergent de  $p$  car  $E(X_i) = p$ . L'estimateur  $\hat{p}_n$  n'est autre que la proportion (ou la fréquence) de fumeurs observée dans l'échantillon. Pour déterminer la loi de  $\hat{p}_n$ , il suffit de remarquer que  $n\hat{p}_n = \sum_{i=1}^n X_i$  est la somme de  $n$  variables de Bernoulli indépendantes et de même paramètre  $p$  :  $n\hat{p}_n$  suit donc une loi binômiale  $B(n, p)$  (la connaissance de la loi de  $n\hat{p}_n$  est équivalente à la connaissance de la loi de  $\hat{p}_n$ )

Pour déterminer l'espérance et la variance de  $\hat{p}_n$ , on peut procéder de deux façons.

La première consiste à utiliser le fait que  $n\hat{p}_n$  suit une loi binômiale  $B(n, p)$  ce qui implique que  $E(n\hat{p}_n) = np$  et  $V(n\hat{p}_n) = np(1-p)$  (cette méthode exige la connaissance préalable de l'espérance et de la variance d'une loi binômiale  $B(n, p)$ ). Or  $E(n\hat{p}_n) = nE(\hat{p}_n)$  et  $V(n\hat{p}_n) = n^2V(\hat{p}_n)$  donc  $E(\hat{p}_n) = \frac{np}{n} = p$  et  $V(\hat{p}_n) = \frac{np(1-p)}{n^2} = \frac{p(1-p)}{n}$ .

La seconde méthode (plus générale) consiste à faire le calcul classique suivant:

$$E(\hat{p}_n) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} np = p$$

$V(\hat{p}_n) = V\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} V\left(\sum_{i=1}^n X_i\right)$  or  $V\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n V(X_i)$  car les  $X_i$  sont supposés indépendants, donc

$V(\hat{p}_n) = \frac{1}{n^2} \sum_{i=1}^n V(X_i) = \frac{1}{n^2} np(1-p) = \frac{p(1-p)}{n}$  (rappel:  $V(X_i) = p(1-p)$  car  $X_i$  suit une loi de Bernoulli de paramètre  $p$ ).

3- Le nombre d'observations est  $n = 200$  et la proportion de fumeurs observée dans l'échantillon est  $\hat{p}_{200} = 0.35$ . On a donc  $n\hat{p}_n(1-\hat{p}_n) = 200 \times 0.35 \times 0.65 = 45.5 > 15$ . Il paraît donc légitime de penser que la condition  $np(1-p) > 15$  est vérifiée, ce qui permet d'utiliser l'approximation normale de la loi binômiale (rappelons qu'il n'est pas possible de calculer  $np(1-p)$  car  $p$  est un paramètre inconnu, d'où le recours à un estimateur de  $p$ , à savoir  $\hat{p}_n$ ). Cette approximation permet d'écrire que:

$$n\hat{p}_n \rightsquigarrow N(np, np(1-p))$$

ce qui revient à dire que :

$$\hat{p}_n \rightsquigarrow N\left(p, \frac{p(1-p)}{n}\right)$$

ou encore :

$$U_n = \frac{\hat{p}_n - p}{\sqrt{\frac{p(1-p)}{n}}} \rightsquigarrow N(0, 1)$$

Il est demandé de déterminer un intervalle bilatéral de confiance à 95%. On a donc besoin de déterminer le nombre  $a$  tel que  $P(|U_n| \leq a) = 0.95$ . Le caractère symétrique de la loi normale centrée réduite permet d'écrire que:  $P(U_n \leq a) = P(|U_n| \leq a) + \frac{1-P(|U_n| \leq a)}{2} = 0.95 + 0.025 = 0.975$ . Sur une table statistique, on trouve  $P(U_n \leq 1.96) = 0.975$  c'est-à-dire  $a = 1.96$ . On a donc:

$$P\left(-1.96 \leq \frac{\hat{p}_n - p}{\sqrt{\frac{p(1-p)}{n}}} \leq 1.96\right) = 0.95$$

égalité qu'on peut réécrire sous la forme

$$P\left(-1.96\sqrt{\frac{p(1-p)}{n}} \leq \hat{p}_n - p \leq 1.96\sqrt{\frac{p(1-p)}{n}}\right) = 0.95$$

ou encore

$$P\left(\hat{p}_n - 1.96\sqrt{\frac{p(1-p)}{n}} \leq p \leq \hat{p}_n + 1.96\sqrt{\frac{p(1-p)}{n}}\right) = 0.95$$

Les bornes de l'intervalle de confiance ne devant pas contenir de paramètre inconnu, on remplace  $p$  par son estimation  $\hat{p}_n$  (cette approximation est valable pour  $n$  suffisamment grand; on suppose que c'est le cas ici). On obtient alors

$$P\left(\hat{p}_n - 1.96\sqrt{\frac{\hat{p}_n(1-\hat{p}_n)}{n}} \leq p \leq \hat{p}_n + 1.96\sqrt{\frac{\hat{p}_n(1-\hat{p}_n)}{n}}\right) \simeq 0.95$$

Application numérique : pour  $n = 200$  et  $\hat{p}_{200} = 0.35$  on trouve l'intervalle  $[0.2839, 0.4161]$ .

### Deuxième partie

1- Le meilleur estimateur de  $m$  est la moyenne empirique  $\bar{Y}_n = \frac{1}{n} \sum_{i=1}^n Y_i$ . Cet estimateur est convergent d'après la loi des grands nombres. Il est sans biais car, par linéarité de l'espérance, on a:  $E(\bar{Y}_n) = \frac{1}{n} \sum_{i=1}^n E(Y_i) = \frac{nm}{n} = m$ . Une autre façon d'établir que l'estimateur est convergent est la suivante: on commence par établir qu'il est sans biais :  $E(\bar{Y}_n) = m$ , puis on calcule sa variance :  $V(\bar{Y}_n) = \frac{1}{n^2} \sum_{i=1}^n V(Y_i)$  car les variables  $Y_i$  sont indépendantes, d'où  $V(\bar{Y}_n) = \frac{\sigma^2}{n}$ ; on peut donc affirmer que

$$E\left((\bar{Y}_n - m)^2\right) = E\left((\bar{Y}_n - E(\bar{Y}_n))^2\right) = V(\bar{Y}_n) = \frac{\sigma^2}{n} \xrightarrow{n \rightarrow +\infty} 0$$

c'est-à-dire que  $\bar{Y}_n$  converge en moyenne quadratique vers  $m$ . Or la convergence en moyenne quadratique implique la convergence en probabilité, donc  $\bar{Y}_n$  converge en probabilité vers  $m$  (lorsqu'on parle de la convergence d'un estimateur sans précision supplémentaire, c'est de la convergence en probabilité qu'il s'agit).

L'estimateur  $\bar{Y}_n$  est la moyenne de  $n$  variables normales indépendantes. Il suit donc une loi normale, de paramètres  $E(\bar{Y}_n) = m$  et  $V(\bar{Y}_n) = \frac{\sigma^2}{n} = \frac{16}{200} = \frac{2}{25}$ .

2- On sait que  $\bar{Y}_n \rightsquigarrow N(m, \frac{\sigma^2}{n})$  donc, en centrant et en réduisant la variable  $\bar{Y}_n$ , on obtient:

$$T_n = \frac{\bar{Y}_n - m}{\frac{\sigma}{\sqrt{n}}} \rightsquigarrow N(0, 1)$$

Notons que cette relation est valable pour toute valeur de  $n$  (y compris les petites valeurs de  $n$ ).

Il est demandé de déterminer un intervalle de confiance bilatéral à 90%. Nous avons donc besoin de déterminer le nombre  $b$  tel que  $P(|T_n| \leq b) = 0.90$ . Or  $T_n$  est symétrique donc  $P(T_n \leq b) = P(|T_n| \leq a) + \frac{1-P(|T_n| \leq a)}{2} = 0.90 + 0.05 = 0.95$ .

**Remarque:** La valeur de  $b$ , à savoir 1.645, est donnée dans l'énoncé. Cette valeur ne se lit pas directement sur la table statistique de la loi normale centrée. En effet, sur la table statistique de  $T_n \rightsquigarrow N(0, 1)$ , on trouve  $P(T_n \leq 1.64) = 0.9495$  et  $P(T_n \leq 1.65) = 0.9505$ . On sait donc que  $b$  se trouve entre 1.64 et 1.65. On procède alors par approximation (ou extrapolation) linéaire, c'est-à-dire qu'on fait l'approximation suivante:  $P(T_n \leq 1.645) \simeq \frac{P(T_n \leq 1.64) + P(T_n \leq 1.65)}{2} = \frac{0.9495 + 0.9505}{2} = 0.95$

Ainsi, on a :

$$P\left(-1.645 \leq \frac{\bar{Y}_n - m}{\frac{\sigma}{\sqrt{n}}} \leq 1.645\right) = 0.90$$

c'est-à-dire:

$$P\left(-1.645 \frac{\sigma}{\sqrt{n}} \leq \bar{Y}_n - m \leq 1.645 \frac{\sigma}{\sqrt{n}}\right) = 0.90$$

qu'on peut réécrire sous la forme :

$$P\left(\bar{Y}_n - 1.645 \frac{\sigma}{\sqrt{n}} \leq m \leq \bar{Y}_n + 1.645 \frac{\sigma}{\sqrt{n}}\right) = 0.90$$

Application numérique: pour  $n = 200$ ,  $\sigma = 4$  et  $\bar{Y}_{200} = 12$ , on trouve l'intervalle [11.5347, 12.4653]

3- La différence fondamentale entre l'estimation par intervalle de confiance de la proportion  $p$  et l'estimation par intervalle de confiance de la consommation journalière moyenne  $m$  est que la première n'est valable que si la taille de l'échantillon est suffisamment grande (en l'occurrence  $n > \frac{15}{p(1-p)}$ ) ce qui permet de recourir à une approximation de la loi de l'estimateur par une loi normale, alors que la seconde est valable quelle que soit la taille de l'échantillon.

### Exercice 2

1-a- La moyenne empirique  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$  est un estimateur convergent de  $E(X)$ . Or  $E(X) = \theta + 1$ ,

donc  $\hat{\theta}_n = \bar{X}_n - 1$  est un estimateur convergent de  $\theta$ .

Cet estimateur est sans biais car:

$$E(\hat{\theta}_n) = E(\bar{X}_n - 1) = E(\bar{X}_n) - 1 = E(X) - 1 = \theta$$

Calculons la variance de l'estimateur  $\hat{\theta}_n$  :

$$V(\hat{\theta}_n) = V(\bar{X}_n - 1) = E((\bar{X}_n - 1 - E(\bar{X}_n - 1))^2)$$

or  $\bar{X}_n - 1 - E(\bar{X}_n - 1) = \bar{X}_n - 1 - (E(\bar{X}_n) - 1) = \bar{X}_n - E(\bar{X}_n)$  donc

$$V(\hat{\theta}_n) = E((\bar{X}_n - E(\bar{X}_n))^2) = V(\bar{X}_n)$$

Par ailleurs,  $V(\bar{X}_n) = \frac{1}{n^2} \sum_{i=1}^n V(X_i)$  car les  $X_i$  sont indépendants et  $V(X_i) = V(X)$  car les  $X_i$  sont identiquement distribués donc  $V(\bar{X}_n) = \frac{nV(X)}{n^2} = \frac{1}{n}$  d'où

$$V(\hat{\theta}_n) = \frac{1}{n}$$

1-b- D'après le TCL, on sait que, lorsque  $n \rightarrow +\infty$

$$\frac{\bar{X}_n - E(X)}{\sqrt{\frac{V(X)}{n}}} \xrightarrow{\text{loi}} N(0, 1)$$

or  $\bar{X}_n = \hat{\theta}_n + 1$ ,  $E(X) = \theta + 1$  et  $V(X) = 1$  donc, lorsque  $n \rightarrow +\infty$

$$\frac{\hat{\theta}_n - \theta}{\sqrt{\frac{1}{n}}} \xrightarrow{\text{loi}} N(0, 1)$$

On dispose d'un échantillon de grande taille  $n$  donc on peut faire l'approximation :

$$\frac{\hat{\theta}_n - \theta}{\sqrt{\frac{1}{n}}} \rightsquigarrow N(0, 1)$$

Il s'ensuit que

$$P(-1.96 \leq \frac{\hat{\theta}_n - \theta}{\sqrt{\frac{1}{n}}} \leq 1.96) \simeq 0.95$$

ce qu'on peut réécrire sous la forme :

$$P(\hat{\theta}_n - 1.96 \frac{1}{\sqrt{n}} \leq \theta \leq \hat{\theta}_n + 1.96 \frac{1}{\sqrt{n}}) \simeq 0.95$$

Ainsi,  $[\hat{\theta}_n - 1.96 \frac{1}{\sqrt{n}}, \hat{\theta}_n + 1.96 \frac{1}{\sqrt{n}}]$  est un intervalle de confiance à 95% du paramètre  $\theta$ .

2- La fonction de vraisemblance de l'échantillon  $(x_1, x_2, \dots, x_n)$  est

$$L(\theta, x_1, \dots, x_n) = \prod_{i=1}^n f(x_i)$$

donc

$$L(\theta, x_1, \dots, x_n) = \begin{cases} e^{n\theta - \sum_{i=1}^n x_i} & \text{si } \forall i \ x_i \geq \theta \\ 0 & \text{sinon} \end{cases}$$

L'assertion  $\forall i \ x_i \geq \theta$  étant équivalente à  $\theta \leq \min(x_i)$ , on peut réécrire la fonction de vraisemblance sous la forme:

$$L(\theta, x_1, \dots, x_n) = \begin{cases} e^{n\theta - \sum_{i=1}^n x_i} & \text{si } \theta \leq \min(x_i) \\ 0 & \text{si } \theta > \min(x_i) \end{cases}$$

On en déduit la log-vraisemblance

$$l(\theta, x_1, \dots, x_n) = \begin{cases} n\theta - \sum_{i=1}^n x_i & \text{si } \theta \leq \min(x_i) \\ -\infty & \text{si } \theta > \min(x_i) \end{cases}$$

**Question bonus:** l'estimateur du maximum de vraisemblance  $\hat{\theta}_{MV}$  est donné par la valeur de  $\theta$  qui maximise la fonction de vraisemblance (ou de log-vraisemblance, c'est la même chose car le logarithme est une fonction strictement croissante) à  $(x_1, x_2, \dots, x_n)$  donnés. La fonction  $\theta \rightarrow L(\theta, x_1, \dots, x_n)$  est strictement croissante et strictement positive sur  $]-\infty, \min(x_i)]$  et est nulle sur  $]\min(x_i), +\infty[$ . Elle atteint donc son maximum au point  $\theta = \min(x_i)$  (pour s'en convaincre tracer le graphe de  $\theta \rightarrow L(\theta, x_1, \dots, x_n)$  à  $(x_1, x_2, \dots, x_n)$  donnés). L'estimateur du maximum de vraisemblance est donc  $\hat{\theta}_{MV} = \min(x_i)$ .

**Remarque:** La fonction  $\theta \rightarrow L(\theta, x_1, \dots, x_n)$  est discontinue, et donc non dérivable, au point  $\theta = \min(x_i)$ . On ne peut donc pas procéder par dérivation pour déterminer le maximum de cette fonction.