

Statistiques Appliquées. L3  
Interrogation n°1

**EXERCICE 1 (2 points) Questions de cours**

- Est-ce que  $V(X - Y) = V(X) - V(Y)$  lorsque **X et Y** sont indépendantes ?  
Non. Lorsque  $X$  et  $Y$  sont indépendantes,  $V(X - Y) = V(X) + V(Y)$ .

**Que vaut  $V(X + Y)$  dans le cas où X et Y sont indépendantes et dans le cas où elles ne sont pas indépendantes ?**

Dans le cas général  $V(X + Y) = V(X) + V(Y) + 2cov(X, Y)$ .

On définit la covariance par  $cov(X, Y) = E(XY) - E(X)E(Y)$ .

Si  $X$  et  $Y$  sont indépendantes, alors  $cov(X, Y) = 0$  et donc  $V(X + Y) = V(X) + V(Y)$ .

- **Enoncer le théorème central limite (TCL).**

Si  $(X_n)$  est une suite de v.a. indépendantes et de même loi, admettant des moments d'ordre un et deux notés  $m = E(X_n)$  et  $\sigma^2 = V(X_n)$ , alors :

$$\sqrt{n} \frac{\bar{X}_n - m}{\sigma} \rightarrow_{loi} N(0, 1)$$

**EXERCICE 2 (2 points) Formule de Bayes**

La production de téléphones portables est assurée par 2 usines  $U_1$  et  $U_2$  qui fabriquent respectivement 45% et 55% de la production totale. La probabilité qu'un téléphone soit défectueux sachant qu'il provient de  $U_1$  est de 4% et la probabilité qu'un téléphone soit défectueux sachant qu'il provient de  $U_2$  est de 3%.

Quelle est la probabilité qu'un téléphone choisi au hasard provienne de  $U_1$  sachant qu'il est défectueux ?

On note  $D$  l'évènement "le téléphone portable est défectueux".

$$P(U_1/D) = \frac{P(D/U_1)P(U_1)}{P(D/U_1)P(U_1) + P(D/U_2)P(U_2)}$$

avec  $P(D/U_1) = 0.04$ ,  $P(U_1) = 0.45$ ,  $P(D/U_2) = 0.03$  et  $P(U_2) = 0.55$ . Ainsi :

$$P(U_1/D) = \frac{0,4 * 0,45}{0,4 * 0,45 + 0,3 * 0,55} \approx 0,57$$

### EXERCICE 3 (5 points) Fonction de densité conjointe

On considère la densité de probabilité de  $(X, Y)$  :

$$f_{X,Y}(x, y) = \begin{cases} kxy & \text{si } x \in [0, 2] \text{ et } y \in [0, 5] \\ 0 & \text{sinon} \end{cases}$$

#### 1. Calculer la constante $k$

L'intégrale de  $f$  sur  $R^2$  doit être égale à 1 :

$$1 = \int \int kxy dx dy = k \int_0^2 x dx \left( \int_0^5 y dy \right) = k \left[ \frac{x^2}{2} \right]_0^2 \left[ \frac{y^2}{2} \right]_0^5 = 25k$$

$$\text{donc } k = \frac{1}{25}$$

donc

$$f_{X,Y}(x, y) = \begin{cases} \frac{1}{25}xy & \text{si } x \in [0, 2] \text{ et } y \in [0, 5] \\ 0 & \text{sinon} \end{cases}$$

#### 2. Déterminer les densités marginales $f_X(x)$ et $f_Y(y)$ de $X$ et de $Y$ . Les v.a.r sont-elles indépendantes ?

$$\text{Si } x < 0 \text{ ou } x > 2, f_X(x) = 0$$

$$\text{Si } x \in [0, 2], f_X(x) = \int_0^5 \frac{1}{25}xy dy = \frac{x}{25} \int_0^5 y dy = \frac{x}{2}$$

$$\text{Si } y < 0 \text{ ou } y > 5, f_Y(y) = 0$$

$$\text{Si } y \in [0, 5], f_Y(y) = \int_0^2 \frac{1}{25}xy dx = \frac{y}{25} \int_0^2 x dx = \frac{2y}{25}$$

$f_X(x)f_Y(y) = f_{X,Y}(x, y) \forall x \in R, \forall y \in R$  donc les variables  $X$  et  $Y$  sont indépendantes.

#### 3. Déterminer, lorsqu'elles existent, $f_X(x|Y = y)$ et $f_Y(y|X = x)$ les densités conditionnelles de $X$ sachant $\{Y = y\}$ et de $Y$ sachant $\{X = x\}$ .

Les variables aléatoires  $X$  et  $Y$  sont indépendantes donc  $f_X(x|Y = y) = f_X(x)$  et  $f_Y(y|X = x) = f_Y(y) \forall x \in R, \forall y \in R$ .

### EXERCICE 4 (5 points) Convergence en probabilité

Soit  $(X_n)$  une suite de variables aléatoires i.i.d suivant une loi de Bernoulli de paramètre  $p$ , soit  $X_1, \dots, X_n \hookrightarrow i.i.d.B(1, p)$ . On pose  $S_n = X_1 + \dots + X_n$ .

#### 1. Calculer $E(\frac{S_n}{n})$ et $V(\frac{S_n}{n})$ .

$X_1, \dots, X_n \hookrightarrow i.i.d.B(1, p)$  donc pour  $1 \leq i \leq n$ ,  $E(X_i) = p$  et  $V(X_i) = p(1 - p)$ .

$$E(\frac{S_n}{n}) = E(\frac{\sum_{i=1}^n X_i}{n}) = \frac{1}{n}.n.E(X_i) = E(X_i) = p$$

$$V(\frac{S_n}{n}) = V(\frac{\sum_{i=1}^n X_i}{n}) = \frac{1}{n^2}V(\sum_{i=1}^n X_i) = \frac{1}{n^2} \sum_{i=1}^n V(X_i) = \frac{1}{n^2}.n.V(X_i) = \frac{p(1-p)}{n}$$

**2. En utilisant l'inégalité de Bienaymé-Tchebychev, montrer que  $\frac{S_n}{n}$  converge en probabilité vers  $p$ .**

On dit que la suite  $(\frac{S_n}{n})$  converge en probabilité vers  $p$  (noté  $\frac{S_n}{n} \rightarrow_p p$ ) lorsque pour tout  $\epsilon > 0$

$$\lim_{n \rightarrow +\infty} P(|\frac{S_n}{n} - p| > \epsilon) = 0$$

D'après l'inégalité de Bienaymé-Chebychev, pour tout  $\epsilon > 0$  fixé

$$P(|\frac{S_n}{n} - E(\frac{S_n}{n})| \geq \epsilon) \leq \frac{V(\frac{S_n}{n})}{\epsilon^2}$$

$$P(|\frac{S_n}{n} - p| > \epsilon) \leq \frac{p(1-p)}{n\epsilon^2}$$

Donc

$$\lim_{n \rightarrow +\infty} P(|\frac{S_n}{n} - p| > \epsilon) \leq \lim_{n \rightarrow +\infty} \frac{p(1-p)}{n\epsilon^2}$$

En outre une probabilité est toujours positive, donc

$$0 \leq \lim_{n \rightarrow +\infty} P(|\frac{S_n}{n} - p| > \epsilon) \leq \lim_{n \rightarrow +\infty} \frac{p(1-p)}{n\epsilon^2}$$

Or  $\lim_{n \rightarrow +\infty} \frac{p(1-p)}{n\epsilon^2} = 0$

Donc d'après le théorème d'encadrement

$$\lim_{n \rightarrow +\infty} P(|\frac{S_n}{n} - p| > \epsilon) = 0$$

Ainsi  $\frac{S_n}{n} \rightarrow_p p$ .

On a montré que la fréquence empirique de l'évènement  $\bar{X}_n = \frac{S_n}{n}$  converge en probabilité vers la fréquence théorique. C'est le théorème de Bernoulli. Cf Lecoutre p. 174

**EXERCICE 5 (7 points) Estimation par intervalle de confiance, intervalle pour une proportion**

**On s'intéresse à la valeur de la probabilité  $p$  d'être en faveur d'un candidat C à une élection.**

**On réalise un sondage sur un échantillon de  $n = 1000$  personnes et on observe le nombre de personnes parmi les 1000 qui se prononcent en faveur du candidat C.**

**1. Décrire le modèle statistique : quelles sont les variables aléatoires observées  $X_1, \dots, X_n$  ? Quelle est leur loi ?**

Les variables  $X_1, \dots, X_n$  prennent la valeur 1 si l'individu est en faveur du candidat C et 0 sinon. C'est un échantillon de Bernoulli  $X_1, \dots, X_n \leftrightarrow i.i.d.B(1, p)$ .

**2. Quel estimateur  $F$  proposez-vous pour  $p$  ? Quelle est la loi de  $1000F$  ?**

L'estimateur est la fréquence observée  $F = \frac{1}{n} \sum_{i=1}^n X_i$

Ici  $F = \frac{1}{1000} \sum_{i=1}^{1000} X_i$ .

$nF \hookrightarrow B(n, p)$

$1000F \hookrightarrow B(1000, p)$ .

**3. On suppose que la loi de  $1000F$  peut être approchée par une loi normale. Donner ses paramètres. Par quelle loi peut-on approcher la loi de  $F$  ?**

Tant que  $np(1-p) > 15$ , on peut approcher la loi de  $nF$  par une loi normale :

$$B(n, p) \approx N(np, np(1-p))$$

$$nF \hookrightarrow N(np, np(1-p))$$

$$1000F \hookrightarrow N(1000p, 1000p(1-p))$$

$$F \hookrightarrow N\left(p, \frac{p(1-p)}{n}\right)$$

$$F \hookrightarrow N\left(p, \frac{p(1-p)}{1000}\right)$$

**4. Construire un intervalle de confiance bilatéral à 0.95 pour  $p$ .**

$$\frac{F - p}{\sqrt{\frac{p(1-p)}{n}}} \approx N(0, 1)$$

On fait une seconde approximation en remplaçant  $p$  par  $F$  au dénominateur :

$$\frac{F - p}{\sqrt{\frac{F(1-F)}{n}}} \approx N(0, 1)$$

On commence par chercher la valeur  $a$  telle que

$$P\left(-a < \frac{F-p}{\sqrt{\frac{F(1-F)}{n}}} < a\right) = 0,95$$

$$\Leftrightarrow \Phi(a) - \Phi(-a) = 0,95$$

$$\Leftrightarrow 2\Phi(a) - 1 = 0,95$$

$$\Leftrightarrow \Phi(a) = 0,975.$$

La lecture de la table de la loi normale centrée réduite donne  $a = 1,96$

Donc

$$P\left(-1,96 \leq \frac{F-p}{\sqrt{\frac{F(1-F)}{n}}} \leq 1,96\right) = 0,95$$

$$\Leftrightarrow P\left(F - 1,96\sqrt{\frac{F(1-F)}{n}} \leq p \leq F + 1,96\sqrt{\frac{F(1-F)}{n}}\right) = 0,95$$

$$F - 1,96\sqrt{\frac{F(1-F)}{n}} \leq p \leq F + 1,96\sqrt{\frac{F(1-F)}{n}}$$

Avec un échantillon de taille  $n = 1000$ , nous obtenons l'intervalle de confiance  
 $F - 0,062\sqrt{F(1-F)} \leq p \leq F + 0,062\sqrt{F(1-F)}$

**5. Application numérique.** On constate que dans l'échantillon 510 personnes se prononcent en faveur du candidat C.

- Calculer l'estimation  $f$  correspondant aux observations.

$$f = \frac{510}{1000} = 0,51.$$

- Calculer l'intervalle de  $p$  correspondant aux observations.

$$0,51 - 0,062\sqrt{0,51(1-0,51)} \leq p \leq 0,51 + 0,062\sqrt{0,51(1-0,51)}$$

soit  $0,479 \leq p \leq 0,541$ .

- L'approximation normale est acceptable pour les calculs numériques lorsque  $np(1-p) > 15$ . Vérifier que pour la valeur de  $p$  la plus défavorable (dans l'intervalle), l'approximation normale est acceptable.

La valeur la plus défavorable de  $p$  est la valeur (dans l'intervalle) telle que  $np(1-p)$  soit "le plus petit possible". Ici la valeur la plus défavorable est la plus grande 0.541 et  $1000 * 0.541 * (1 - 0.541) = 248.32 > 15$ , donc l'approximation normale est acceptable.