

Statistiques Appliquées
Correction du Contrôle Continu N°1
TD N°3 et 4
Gwenn PARENT

1. **Rappelez l'énoncé du théorème Central-Limite.** (1 point)

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

$$\sqrt{n} \frac{\overline{X_n} - m}{\sigma} \xrightarrow{Loi} \mathcal{N}(0,1)$$

2. **Qu'est ce qu'un estimateur sans biais ?** (1 point)

Le biais de l'estimateur \hat{m} d'un paramètre m est : $Biais = E(\hat{m}) - m$. On dit d'un estimateur qu'il est non biaisé (ou sans biais), lorsque son biais est égal à 0.

Exercice 1 : Formule de Bayes (2 points)

Un étudiant doit répondre à un questionnaire à choix multiple où cinq réponses sont proposées à une question, une seule étant correcte. Quand l'évènement $A =$ "l'étudiant a bien travaillé pendant l'année" est réalisé, la réponse est fournie avec exactitude. Dans le cas contraire, l'étudiant répond au hasard. Si l'évènement $B =$ "il a fourni la réponse correcte" est réalisé, calculez la probabilité $P(A \setminus B)$ en fonction de $p = P(A)$.

D'après l'énoncé, on a $P(B \setminus A) = 1$, $P(B \setminus \bar{A}) = 1/5$ et $P(A) = p$.
Il suffit d'appliquer la Formule de Bayes :

$$P(A \setminus B) = \frac{P(A \cap B)}{P(B)} = \frac{P(B \setminus A)P(A)}{P(B \setminus A)P(A) + P(B \setminus \bar{A})P(\bar{A})}$$

$$P(A \setminus B) = \frac{p}{p + (1-p)/5} = \frac{5p}{4p + 1}$$

On peut noter que $P(A \setminus B) \geq P(A) = p$, avec bien sûr $P(A \setminus B) = 0$ si $p = 0$ et $P(A \setminus B) = 1$ si $p = 1$. Dans tous les autres cas, $P(A \setminus B) > P(A)$.

Exercice 2 : Fonction de densité conjointe (4,5 points)

Soit (X, Y) un couple de variables aléatoires dont la loi est déterminée par la densité conjointe suivante :

$$f_{X,Y}(x, y) = \begin{cases} k(x+y) & \text{si } (x, y) \in [0, 1] \times [0, x] \\ 0 & \text{sinon} \end{cases}$$

1. Déterminez la valeur de la constante k . (2 points)

On sait que k doit vérifier :

$$\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f_{X,Y}(x,y) dx dy = 1$$

On doit respecter la condition $(x,y) \in [0,1] \times [0,x]$ pour intégrer, d'où :

$$k \int_0^1 \left(\int_0^x (x+y) dy \right) dx = 1$$

$$\iff k \int_0^1 \left[\frac{(x+y)^2}{2} \right]_0^x dx = 1 \iff k \int_0^1 \left(\frac{(2x)^2}{2} - \frac{x^2}{2} \right) dx = 1$$

$$\iff \frac{3}{2} k \int_0^1 x^2 dx = 1 \iff \frac{3}{2} k \left[\frac{x^3}{3} \right]_0^1 \iff \frac{3}{2} k \frac{1}{3} = \frac{k}{2} = 1$$

Donc $k = 2$, et la densité s'écrit : $f_{X,Y}(x,y) = 2(x+y)$ si $(x,y) \in [0,1] \times [0,x]$ et $f_{X,Y}(x,y) = 0$ sinon.

2. Déterminez les lois marginales de X et de Y . Ces variables sont-elles indépendantes ? (1,5 points)

Pour $k = 2$, la densité marginale de x est :

$$f_X(x) = \int_{-\infty}^{+\infty} f_{X,Y}(x,y) dy \quad \text{si } x \in [0,1], 0 \text{ sinon}$$

$$f_X(x) = \int_0^x 2(x+y) dy \quad \text{si } x \in [0,1], 0 \text{ sinon}$$

$$f_X(x) = \left[(x+y)^2 \right]_0^x = (2x)^2 - x^2 \quad \text{si } x \in [0,1], 0 \text{ sinon}$$

$$f_X(x) = 3x^2 \quad \text{si } x \in [0,1], 0 \text{ sinon}$$

De même,

$$f_Y(y) = \int_{-\infty}^{+\infty} f_{X,Y}(x,y) dx \quad \text{si } y \in [0,x], 0 \text{ sinon}$$

$$f_Y(y) = \int_0^1 2(x+y) dx \quad \text{si } y \in [0,x], 0 \text{ sinon}$$

$$f_Y(y) = \left[(x+y)^2 \right]_0^1 = (y+1)^2 - y^2 = y^2 + 2y + 1 - y^2 \quad \text{si } y \in [0,x], 0 \text{ sinon}$$

$$f_Y(y) = 2y + 1 \quad \text{si } y \in [0,x], 0 \text{ sinon}$$

On remarque que $f_{X,Y}(x,y) \neq f_X(x) \times f_Y(y)$ (en effet : $2(x+y) \neq 3x^2 \times (2y+1)$), ce qui prouve que X et Y ne sont pas indépendantes. Cela nous était déjà suggéré car $0 < y < x$ (y est contraint par x , donc les variables aléatoires ne sont pas indépendantes).

3. Déterminez les densités conditionnelles de $X \setminus Y = y$ et de $Y \setminus X = x$.

La densité conditionnelle de $X|Y = y$ s'écrit :

$$f_{X|Y=y}(x, y) = \frac{f_{X,Y}(x, y)}{f_Y(y)} = \frac{2(x+y)}{2y+1} \quad \text{si } (x, y) \in [0, 1] \times [0, x], \text{ et } 0 \text{ sinon}$$

La densité conditionnelle de $Y|X = x$ s'écrit :

$$f_{Y|X=x}(x, y) = \frac{f_{X,Y}(x, y)}{f_X(x)} = \frac{2(x+y)}{3x^2} \quad \text{si } (x, y) \in [0, 1] \times [0, x], \text{ et } 0 \text{ sinon}$$

Exercice 3 : Intervalle de confiance (8 points)

Une entreprise de télécommunications cherche à développer un nouveau produit, et charge ses télé-opérateurs de contacter une base de 4000 clients pour leur proposer ce nouvel abonnement. Ils obtiennent 720 retours positifs de la part de leurs clients. Nous nous intéressons à la probabilité p de réponse favorable pour chaque appel et nous pouvons supposer que les comportements des individus sont indépendants les uns des autres.

1. **Décrire, avec précision le modèle statistique correspondant à ces observations : quelle est la variable aléatoire observée, quel est le nombre d'observations, quelle est la loi de ces observations ?**

La variable aléatoire observée X_i est une variable de Bernouilli valant 1 si le client i répond favorablement à l'appel du télé-opérateur, 0 sinon. Nous disposons de 4000 observations indépendantes et identiquement distribuées (tirage sans remise mais dans une très large population, ce qui est équivalent à un tirage avec remise, et les comportements sont indépendants). On peut donc considérer que l'on a un échantillon de taille 4000 d'une Bernouilli (p).

2. **Quel estimateur proposez-vous pour p ? Quelle est l'estimation correspondant aux observations faites ?**

L'estimateur optimal pour p est la fréquence observée :

$$\hat{p} = \frac{1}{4000} \sum_{i=1}^{4000} X_i = F$$

Les observations faites conduisent à $f = \frac{720}{4000} = 0,18$.

3. **Quelle est la loi de cet estimateur ? A quelle condition peut-on utiliser l'approximation normale ? Vérifiez cette condition, et donnez l'estimateur qui sera utilisé.**

Loi de cet estimateur :

$$\sum_{i=1}^{4000} X_i = 4000F \rightarrow \text{Binomiale } (4000, p)$$

Rappels sur la loi Binomiale $\mathcal{B}(n, p)$:

- On réalise n épreuves successives indépendantes où on observe à chaque fois la réalisation ou non d'un certain événement A et on note X le nombre de réalisation de A .

$$P(X = k) = C_n^k p^k (1 - p)^{n-k}$$

- Si $X_i \rightarrow B(1, p)$, alors $\sum_i^n X_i \rightarrow \mathcal{B}(n, p)$.
- Si $n > 30$ et $np < 15$, alors la loi $\mathcal{B}(n, p)$ converge en loi vers la loi de Poisson : $\mathcal{P}(np)$.
- Si $np(1 - p) > 15$, la loi $\mathcal{B}(np)$ converge en loi vers la loi normale : $\mathcal{N}(np, np(1 - p))$.

Nous pouvons utiliser l'approximation normale pour les calculs numériques, car $np(1 - p) = 4000 \times 0,18 \times (1 - 0,18) = 590,4 > 15$.

$$\text{Donc : } nF \rightarrow N\left(np, np(1 - p)\right) \text{ ou encore } F \rightarrow N\left(p, \frac{p(1-p)}{n}\right)$$

Redémontrons rapidement cela :

Si : $nF \rightarrow N\left(np, np(1 - p)\right)$ alors $E(nF) = np$ et $V(nF) = np(1 - p)$

Calculons $E(F)$ et $V(F)$:

$$E(F) = E\left(\frac{1}{n}(nF)\right) = \frac{1}{n}E(nF) = \frac{1}{n}(np) = p$$

$$V(F) = V\left(\frac{1}{n}(nF)\right) = \left(\frac{1}{n}\right)^2 V(nF) = \frac{1}{n^2} (np(1 - p)) = \frac{p(1 - p)}{n}$$

Nous avons donc bien : $F \rightarrow N\left(p, \frac{p(1-p)}{n}\right)$

4. Construisez un intervalle bilatéral de confiance à 90% pour p , et calculez l'intervalle ici observé.

Intervalle bilatéral de confiance proche de 90 % pour p :

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

Soit U la fonction pivotale associée $F : U = \frac{F-p}{\sqrt{\frac{p(1-p)}{n}}} \approx \mathcal{N}(0, 1)$ (donné par le théorème Central-Limite).

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

On lit dans la table de la loi Normale centrée réduite $P(|U| < 1,645) = 2F(1,645) - 1 = 0,90$

Attention, il s'agit d'un intervalle bilatéral de confiance, il faut donc rechercher la valeur 0,95 dans la table de la loi Normale Centrée Réduite : $P(U < 1,645) = 0,95$ donc $P(|U| < 1,645) = 0,90$ (refaites le graphique si nécessaire) d'où :

$$p\left(\left|\frac{F - p}{\sqrt{\frac{p(1-p)}{4000}}}\right| < 1,645\right) = 0,90$$

Pour approcher l'inégalité nous remplaçons p au dénominateur par son estimation F (utilisation de la variance empirique $\frac{F(1-F)}{4000}$) et nous obtenons :

$$-1,645 < \frac{F - p}{\sqrt{\frac{F(1-F)}{4000}}} < 1,645$$

$$-1,645 \sqrt{\frac{F(1-F)}{4000}} < F - p < 1,645 \sqrt{\frac{F(1-F)}{4000}}$$

$$p \left(F - 1,645 \sqrt{\frac{F(1-F)}{4000}} < p < F + 1,645 \sqrt{\frac{F(1-F)}{4000}} \right) \simeq 0,90$$

$$f - 1,645 \sqrt{\frac{f(1-f)}{4000}} < p < f + 1,645 \sqrt{\frac{f(1-f)}{4000}}$$

Réalisation observée : Intervalle de confiance bilatéral pour p à 90% : $0,17 < p < 0,35$

Exercice 4 : Convergence en probabilité et inégalité de Tchebychev (6 points)

Soit $(X_1, X_2, \dots, X_{n+1})$ une suite de variables aléatoires de Bernoulli de même paramètre p , deux à deux indépendantes. On introduit pour tout entier naturel non nul $n \in \mathbb{N}^*$, les variables aléatoires :

$$Y_n = \frac{X_n + X_{n+1}}{2} \quad \text{et} \quad T_n = \frac{Y_1 + Y_2 + \dots + Y_n}{n}$$

1. **Déterminez la loi de Y_n : Quelles valeurs peut prendre Y_n ? Donnez la distribution de probabilité de Y_n , et calculez son espérance et sa variance. (2 points)**

Les X_i sont des variables aléatoires de Bernoulli $B(p)$, donc nous avons : $P(X_i = 1) = p$ et $P(X_i = 0) = 1 - p$. Donc Y_n peut prendre les valeurs $0, \frac{1}{2}$ et 1 , avec les probabilités suivantes :

$$P(Y_n = 0) = P((X_n = 0) \& (X_{n+1} = 0)) = (1 - p) \times (1 - p) = (1 - p)^2$$

$$P(Y_n = 1) = P((X_n = 1) \& (X_{n+1} = 1)) = p \times p = p^2$$

$$P(Y_n = \frac{1}{2}) = 1 - P(Y_n = 1) - P(Y_n = 0) = 1 - p^2 - (1 - p)^2 = 1 - p^2 - (1 - 2p + p^2) = 2p(1 - p)$$

$$E(Y_n) = E\left(\frac{X_n + X_{n+1}}{2}\right) = \frac{1}{2}E(X_n + X_{n+1}) = \frac{1}{2}(2p) = p$$

$$V(Y_n) = V\left(\frac{X_n + X_{n+1}}{2}\right) = \left(\frac{1}{2}\right)^2 V(X_n + X_{n+1}) = \frac{1}{4}[V(X_n) + V(X_{n+1}) + 2cov(X_n, X_{n+1})]$$

Or les variables X_n et X_{n+1} sont indépendantes donc $cov(X_n, X_{n+1}) = 0$, donc :

$$V(Y_n) = \frac{1}{4}[p(1 - p) + p(1 - p)] = \frac{p(1-p)}{2}$$

2. **Calculez l'espérance et la variance de T_n . (Attention, les Y_i ne sont pas indépendantes)**

$$E(T_n) = E\left(\frac{Y_1 + Y_2 + \dots + Y_n}{n}\right) = \frac{1}{n}E\left(\sum_{i=1}^n Y_i\right) = \frac{1}{n} \sum_{i=1}^n E(Y_i) = \frac{1}{n}(np) = p$$

Faites très attention dans le calcul des variances... ici les Y_i et Y_{i+1} ne sont pas indépendantes. Il faut donc tenir compte des covariances $cov(Y_i, Y_{i+1})$.

$$V(T_n) = V\left(\frac{Y_1 + Y_2 + \dots + Y_n}{n}\right)$$

$$V(T_n) = \left(\frac{1}{n}\right)^2 V\left(\frac{X_1+X_2}{2} + \frac{X_2+X_3}{2} + \dots + \frac{X_n+X_{n+1}}{2}\right)$$

$$V(T_n) = \frac{1}{n^2} V\left(\frac{X_1}{2} + X_2 + X_3 + \dots + X_n + \frac{X_{n+1}}{2}\right)$$

Or les variables $X_1, X_2 \dots X_n, X_{n+1}$ sont indépendantes deux à deux, donc toutes les covariances deux à deux sont égales à 0. Donc :

$$V(T_n) = \frac{1}{n^2} [V\left(\frac{X_1}{2}\right) + V(X_2) + V(X_3) + \dots + V(X_n) + V\left(\frac{X_{n+1}}{2}\right)]$$

$$V(T_n) = \frac{1}{n^2} [V\left(\frac{X_1}{2}\right) + V\left(\frac{X_{n+1}}{2}\right) + \sum_{i=2}^n V(X_i)]$$

$$V(T_n) = \frac{1}{n^2} \left[\left(\frac{1}{4}p(1-p)\right) + \left(\frac{1}{4}p(1-p)\right) + (n-1)p(1-p)\right]$$

$$V(T_n) = \frac{1}{n^2} p(1-p) \left[\frac{1}{4} + \frac{1}{4} + (n-1)\right] = \frac{1}{n^2} p(1-p) \left(n - \frac{1}{2}\right)$$

$$V(T_n) = \frac{(2n-1)p(1-p)}{2n^2}$$

3. En déduire que $T_n \xrightarrow{P} p$. (T_n converge en probabilité vers p)

D'après l'inégalité de Bienaymé-Chebychev :

$$\forall k > 0, \quad P(|T_n - E(T_n)| \geq k) \leq \frac{V(T_n)}{k^2}$$

Donc :

$$\forall k > 0, \quad P(|T_n - p| \geq k) \leq \frac{(2n-1)p(1-p)}{2n^2 k^2}$$

Soit :

$$\forall k > 0, \quad P(|T_n - p| \geq k) \leq \frac{(2n-1)p(1-p)}{2n^2 k^2}$$

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

Donc d'après le théorème de l'encadrement :

$$\lim_{n \rightarrow +\infty} P(|T_n - p| \geq k) = 0$$

Donc T_n converge en probabilité vers p : $T_n \xrightarrow{P} p$.