

## Contrôle continu 2 Correction du sujet B

**Correction 1.** (1) On commence par déterminer la valeur de  $\mathbb{P}(X_1 = 1)$ . Comme  $\mathbb{P}(X_1 = -1) + \mathbb{P}(X_1 = 0) + \mathbb{P}(X_1 = 1) = 1$ , on a donc  $\mathbb{P}(X_1 = 1) = 1 - \gamma$ . Ensuite,

$$\mathbb{E}[X_1] = -1 \times (\gamma(1 - \gamma)) + 1 \times (1 - \gamma) = (1 - \gamma)^2$$

et

$$\mathbb{E}[X_1^2] = (-1)^2 \times (\gamma(1 - \gamma)) + 1^2 \times (1 - \gamma) = 1 - \gamma^2.$$

(2) Les deux fonctions  $g_1$  et  $g_2$  vont de  $]0, 1[$  dans  $]0, 1[$ . Soient  $x$  et  $y$  dans  $]0, 1[$  tels que  $g_1(x) = y$ . On raisonne par équivalences :

$$g_1(x) = y \Leftrightarrow (1 - x)^2 = y \Leftrightarrow 1 - x = \sqrt{y} \text{ (car } 1 - x \geq 0 \text{ et } y \geq 0) \Leftrightarrow x = 1 - \sqrt{y}.$$

Ainsi  $g_1$  est inversible sur  $]0, 1[$  et son inverse est  $g_1^{-1} : ]0, 1[ \rightarrow ]0, 1[$  qui à  $y$  associe  $1 - \sqrt{y}$ . Soient  $x$  et  $y$  dans  $]0, 1[$  tels que  $g_2(x) = y$ . On raisonne par équivalences :

$$g_2(x) = y \Leftrightarrow 1 - x^2 = y \Leftrightarrow x^2 = 1 - y \Leftrightarrow x = \sqrt{1 - y} \text{ (car } x \geq 0 \text{ et } 1 - y \geq 0).$$

Ainsi  $g_2$  est inversible sur  $]0, 1[$  et son inverse est  $g_2^{-1} : ]0, 1[ \rightarrow ]0, 1[$  qui à  $y$  associe  $\sqrt{1 - y}$ .

On a  $\mathbb{E}[X_1] = g_1(\gamma)$ , donc l'estimateur donné par la méthode des moments (en utilisant le moment d'ordre 1) de  $\gamma$  est  $B_1 = g_1^{-1}(\frac{1}{n} \sum_{i=1}^n X_i) = 1 - \sqrt{\frac{1}{n} \sum_{i=1}^n X_i}$ . **Remarque :** la variable aléatoire  $\frac{1}{n} \sum_{i=1}^n X_i$  peut prendre des valeurs négatives et dans ce cas là, l'estimateur que l'on a donné n'est pas bien défini. Cependant, on sait que  $\sum_{i=1}^n X_i$  est proche de  $\mathbb{E}[X_1] = (1 - \gamma)^2 > 0$  quand  $n$  est grand. On peut donc espérer que ce cas là ne se produise pas souvent quand l'échantillon est assez grand.

On a  $\mathbb{E}[X_1^2] = g_2(\gamma)$ , donc l'estimateur donné par la méthode des moments (en utilisant le moment d'ordre 2) de  $\gamma$  est  $B_2 = g_2^{-1}(\frac{1}{n} \sum_{i=1}^n X_i^2) = \sqrt{1 - \frac{1}{n} \sum_{i=1}^n X_i^2}$ . **Remarque :** L'estimateur  $B_2$  est bien défini dans tous les cas. En effet,  $\frac{1}{n} \sum_{i=1}^n X_i^2 \leq 1$  en tant que variable aléatoire.

(3) La vraisemblance de l'échantillon est

$$L(x_1, \dots, x_n, \gamma) = \prod_{i=1}^n \mathbb{P}(X_i = x_i) = [\gamma(1 - \gamma)]^{n-1} \gamma^{2n_0} (1 - \gamma)^{n_1} = \gamma^{n-1+2n_0} (1 - \gamma)^{n-1+n_1}.$$

(4) On peut considérer  $\log(L(x_1, \dots, x_n, \gamma)) = (n-1 + 2n_0) \log(\gamma) + (n-1 + n_1) \log(1 - \gamma)$ . Sa dérivée par rapport à  $\gamma$  est  $\frac{n-1+2n_0}{\gamma} - \frac{n-1+n_1}{1-\gamma}$ . Elle est positive si et seulement si  $\gamma \leq \frac{n-1+2n_0}{2n-1+2n_0+n_1}$ . Donc l'estimateur par maximum de vraisemblance est  $B_{MV} = \frac{N_{-1}+2N_0}{2N_{-1}+2N_0+N_1}$  où  $N_{-1}$ ,  $N_0$  et  $N_1$  sont les variables aléatoires correspondantes aux réalisations  $n_{-1}$ ,  $n_0$  et  $n_1$ . C'est à dire,  $N_{-1} = \sum_{i=1}^n \mathbf{1}_{X_i=-1}$ ,  $N_0 = \sum_{i=1}^n \mathbf{1}_{X_i=0}$  et  $N_1 = \sum_{i=1}^n \mathbf{1}_{X_i=1}$ .

**Correction 2.** (1) On effectue un sondage au sein d'une population de grande taille. Ainsi, la probabilité qu'une personne de notre échantillon ait été touché par la grippe est  $q$  (la proportion dans la population totale). Comme  $X_1 = 1$  si la première personne interrogée a été touchée par la grippe (ce qui arrive avec probabilité  $q$ ), la loi de  $X_1$  est la loi de Bernoulli de paramètre  $q$ . **Remarque :** Ne surtout pas écrire  $q = 0,6$ . Ici,  $q$  est inconnu et on cherche à l'estimer.

(2) L'estimateur classique de la proportion théorique  $q$  est la proportion empirique qui s'écrit  $\bar{X}_n = n^{-1} \sum_{i=1}^n X_i$  avec les notations de l'énoncé et donne l'estimation  $\hat{q} = 0,6$ . **Remarque :** On différencie donc la variable aléatoire  $\bar{X}_n$  de sa réalisation  $\hat{q}$  mesurée par l'enquêteur. De plus, il ne faut surtout pas écrire  $q = \bar{X}_n$  ou  $q = 0,6$ .

(3) Les variables  $(X_1, \dots, X_n)$  forment un échantillon de loi  $\mathcal{B}(q)$ . Par le Théorème Central Limite ( $n \geq 30$ ), on peut approximer la variable aléatoire  $\bar{X}_n - q$  par la variable  $Y \sim \mathcal{N}(0, \sqrt{\frac{q(1-q)}{n}})$ .

(4) On commence par centrer et réduire nos variables. On sait que  $\bar{X}_n - q$  peut être approximer par  $Y$  donc  $\sqrt{n} \frac{\bar{X}_n - q}{\sqrt{q(1-q)}}$  peut être approximer par  $\sqrt{n} \frac{Y}{\sqrt{q(1-q)}} \sim \mathcal{N}(0, 1)$ . Comme  $F(z_\alpha) = 1 - \alpha/2$ , on sait que  $\mathbb{P}\left(-z_\alpha \leq \sqrt{n} \frac{Y}{\sqrt{q(1-q)}} \leq z_\alpha\right) = 1 - \alpha$  par symétrie de la loi normale. Or, l'approximation nous dit que

$$\mathbb{P}\left(-z_\alpha \leq \sqrt{n} \frac{\bar{X}_n - q}{\sqrt{q(1-q)}} \leq z_\alpha\right) \approx \mathbb{P}\left(-z_\alpha \leq \sqrt{n} \frac{Y}{\sqrt{q(1-q)}} \leq z_\alpha\right)$$

donc

$$\mathbb{P}\left(\bar{X}_n - z_\alpha \sqrt{\frac{q(1-q)}{n}} \leq q \leq \bar{X}_n + z_\alpha \sqrt{\frac{q(1-q)}{n}}\right) \approx 1 - \alpha.$$

(5) La réponse à la question précédente ne permet pas de donner directement un intervalle de fluctuation pour  $q$ . En effet, les bornes de l'encadrement autour de  $q$  dépendent de  $q$ . On connaît plusieurs techniques pour contourner ce problème : méthode de l'ellipse, méthode par excès, ou bien le remplacement de  $q$  par son estimation  $\hat{q}$  justifié par le Lemme de Slutsky.

**Correction 3.** On considère l'échantillon probabiliste  $(X_1, \dots, X_n)$ ,  $n = 4$  de loi mère  $\mathcal{N}(\theta, \sigma)$ . Cette échantillon est la modélisation aléatoire des tailles des 4 nouveau-nés données dans l'énoncé.

(1) L'estimateur classique de la moyenne théorique  $\theta$  est  $\bar{X}_n = n^{-1} \sum_{i=1}^n X_i$  et donne l'estimation  $\hat{\theta} = 50\text{cm}$ . **Remarque :** On différencie donc la variable aléatoire  $\bar{X}_n$  de sa réalisation  $\hat{\theta}$  mesurée par l'infirmier. De plus, il ne faut surtout pas écrire  $\theta = \bar{X}_n$  ou  $\theta = 50\text{cm}$ .

(2) Soit  $\alpha$  dans  $]0, 1[$ . **Remarque :** Comme les variables aléatoires  $X_i$  sont i.i.d. de loi  $\mathcal{N}(\theta, \sigma)$ , on sait que :

$$Z_n := \sqrt{n} \frac{\bar{X}_n - \theta}{\sigma} \sim \mathcal{N}(0, 1).$$

Cependant, cette variable ne nous est d'aucune utilité compte tenu du fait que l'on ne connaît pas  $\sigma$ .

Posons

$$T_n := \sqrt{n} \frac{\bar{X}_n - \theta}{\sqrt{V_n}},$$

où  $V_n = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ . D'après le cours, la variable  $T_n$  suit une loi de Student de paramètre  $n - 1$ . On note  $\phi$  la fonction de répartition de la loi de Student de paramètre

$n - 1$ . Soit  $t_\alpha$  tel que  $\phi(t_\alpha) = 1 - \alpha/2$  (**Remarque** : en pratique, on lit  $t_\alpha$  sur la table, mais il faut dire dès cette question quel est le lien entre  $\alpha$  et  $t_\alpha$ ). On a donc, par symétrie de la loi de Student,

$$\mathbb{P}(-t_\alpha \leq T_n \leq t_\alpha) = 1 - \alpha,$$

et donc

$$\mathbb{P}\left(\bar{X}_n - \frac{t_\alpha \sqrt{V_n}}{\sqrt{n}} \leq \theta \leq \bar{X}_n + \frac{t_\alpha \sqrt{V_n}}{\sqrt{n}}\right) = 1 - \alpha.$$

Ainsi,  $\left[\bar{X}_n - \frac{t_\alpha \sqrt{V_n}}{\sqrt{n}}, \bar{X}_n + \frac{t_\alpha \sqrt{V_n}}{\sqrt{n}}\right]$  est un intervalle de fluctuation pour  $\theta$  au niveau de confiance  $1 - \alpha$ .

- (3) Un niveau de confiance de 95% correspond à  $\alpha = 0.05$ . Sur la table de Student de paramètre égal à 3, on lit  $t_{0.05} = 3.182$ . De plus, on calcule la réalisation de la moyenne empirique donnée par l'échantillon,  $\bar{x}_n = \hat{\theta} = 50$  ainsi que la réalisation de la variance empirique donnée par l'échantillon,  $v_n = 0.313$ . Ainsi,  $[49, 11; 50, 89]$  est un intervalle de confiance pour  $\theta$  au niveau 95%.
- (4) L'intervalle de fluctuation que l'on a trouvé à la question 2 est centré sur la moyenne empirique. Notons  $\ell$  sa longueur. On a  $\ell = 2 \frac{t_\alpha \sqrt{V_n}}{\sqrt{n}}$ , et on en déduit  $t_\alpha = \frac{\ell \sqrt{n}}{2 \sqrt{V_n}}$ . Avec  $n = 4$ ,  $v_n = 0.313$  et  $\ell = 1.193$ , on trouve  $t_\alpha = 2, 131$ . On lit sur la table de la loi de Student de paramètre égal à 3,  $\phi(2, 131) \approx 0, 95$ . Or, on a la relation  $\phi(t_\alpha) = 1 - \alpha/2$ , donc on en déduit  $\alpha \approx 0, 1$ . Ainsi, le niveau de confiance d'un intervalle de fluctuation de longueur 1, 193cm centré en la moyenne empirique est approximativement de 90%.

**Correction 4.** (1) Comme les variables aléatoires  $X_i$  sont i.i.d. de loi  $\mathcal{N}(m, s)$ , on sait que les variables  $\frac{nV_n^*}{s^2}$  et  $\frac{(n-1)V_n}{s^2}$  suivent respectivement une loi du khi-deux à  $n$  degrés de libertés et une loi du khi-deux à  $n - 1$  degrés de libertés. On peut le justifier simplement pour  $\frac{nV_n^*}{s^2}$ . En effet,  $\frac{nV_n^*}{s^2} = \sum_{i=1}^n \left(\frac{X_i - m}{s}\right)^2$  est la somme des carrés de  $n$  variables gaussiennes  $\mathcal{N}(0, 1)$  indépendantes. Donc, par définition de la loi du khi-deux,  $\frac{nV_n^*}{s^2} \sim \chi^2(n)$ .

- (2) Soit  $\alpha$  dans  $]0, 1[$ . Comme la moyenne  $m$  est connue, on va utiliser la variable  $\frac{nV_n^*}{s^2}$ . D'après la question 1,  $\frac{nV_n^*}{s^2} \sim \chi^2(n)$ . On note  $\Phi$  la fonction de répartition de la loi  $\chi^2(n)$ . Soient  $u_\alpha$  et  $t_\alpha$  tels que  $\Phi(t_\alpha) = \alpha/2$  et  $\Phi(t_\alpha) = 1 - \alpha/2$  (**Remarque** : en pratique, on lit  $u_\alpha$  et  $t_\alpha$  sur la table, mais il faut dire dès cette question quels sont les liens entre  $\alpha$  et  $(u_\alpha, t_\alpha)$ ). Ainsi, on a

$$\mathbb{P}\left(u_\alpha \leq \frac{nV_n^*}{s^2} \leq t_\alpha\right) = 1 - \alpha,$$

et donc

$$\mathbb{P}\left(\frac{nV_n^*}{t_\alpha} \leq s^2 \leq \frac{nV_n^*}{u_\alpha}\right) = 1 - \alpha.$$

Ainsi,  $\left[\frac{nV_n^*}{t_\alpha}, \frac{nV_n^*}{u_\alpha}\right]$  est un intervalle de fluctuation pour  $s^2$  au niveau de confiance  $1 - \alpha$ .

- (3) Un niveau de confiance de 90% correspond à  $\alpha = 0.1$ . Sur la table de la loi du khi-deux, on lit  $u_{0.1} = 1, 145$  et  $t_{0.1} = 11, 07$ . De plus, on a  $m = 0$  et on calcule la réalisation de  $V_n^*$  donnée par l'échantillon,  $v_n^* = 0, 664$ . Ainsi,  $[0, 30; 2, 90]$  est un intervalle de confiance au niveau 90%.