

## T.D. 4 Statistique

### Théorème de Student

**Exercice 1.** Dans l'atmosphère, le taux d'un gaz nocif, pour un volume donné, suit une loi normale d'espérance  $\mu$  et de variance  $\sigma^2$  inconnues. On effectue  $n$  prélèvements conduisant aux valeurs  $X_1, X_2, \dots, X_n$ .

- Sur un échantillon de taille  $n = 10$ , on observe que  $\bar{X} = 50$  et  $S^2 = 100$  où  $S^2 = \frac{1}{9} \sum_{i=1}^{10} (X_i - \bar{X})^2$ .
- Quel est l'intervalle de confiance de niveau de confiance 95 % du taux moyen  $\mu$  de gaz dans l'atmosphère ?
- Construire un intervalle de confiance pour  $\sigma^2$  de niveau de confiance 95%.

**Exercice 2.** On s'interroge sur la comparaison des tailles moyennes des garçons et des filles de 6 ans dans une population; pour cela on a pris comme échantillon, jugé représentatif de cette tranche d'âge, une classe d'école primaire (niveau CP en France), et on a observé :

- $n_1 = 16$  garçons : moyenne 126,5 cm, écart-type 12,9 cm
- $n_2 = 15$  filles : moyenne 136,9 cm, écart-type 11,9 cm.

On admet que la distribution des tailles dans chacune des sous-populations (garçons, filles) suit une loi gaussienne.

- Donner des intervalles de confiance pour les tailles moyennes des garçons et des filles.
- Donner un intervalle de confiance pour l'écart type de la taille des garçons. Même question pour les filles.
- Sur la base de la réponse à la question précédente, on suppose que la variance est la même dans les deux populations et vaut  $\sigma^2$ . Montrer que

$$\hat{\sigma}^2 = \frac{1}{n_1 + n_2 - 2} \left( \sum_{i=1}^{n_1} (Y_i - \bar{Y})^2 + \sum_{i=1}^{n_2} (X_i - \bar{X})^2 \right)$$

est un estimateur sans biais de  $\sigma^2$ .

- Montrer que  $\hat{\sigma}^2$  est indépendant de  $\bar{X} - \bar{Y}$ .
- En déduire que la variable aléatoire

$$T = \left( \frac{1}{n_1} + \frac{1}{n_2} \right)^{-1/2} \frac{\bar{X} - \bar{Y} - \Delta}{\hat{\sigma}}$$

suit une loi de Student dont on précisera le nombre de degrés de liberté.

- Construire un intervalle de confiance de niveau de confiance 95% pour la différence entre la taille moyenne des filles et celle des garçons.

**Test statistique**

**Exercice 3** (Modèle binaire). Soit  $(\Omega, \mathcal{F})$  un espace mesurable et  $X : \Omega \rightarrow \mathbb{R}^n$  un vecteur aléatoire à valeurs dans  $\mathbb{R}^n$ . On suppose que  $P_{\theta_0}$  et  $P_{\theta_1}$  sont deux probabilités sur  $(\Omega, \mathcal{F})$ . On observe une réalisation de  $X$  sous  $P_\theta$  où  $\theta \in \{\theta_0, \theta_1\}$  est inconnu. On s'intéresse au problème de test suivant: au vu de l'observation  $X$  on veut décider si  $\theta = \theta_0$  ou si  $\theta = \theta_1$ .

Une fonction de test est une fonction  $\varphi : \mathbb{R}^n \rightarrow \{0, 1\}$  à laquelle on associe la procédure de décision suivante : si on observe  $\varphi(X) = 1$  on décide que  $\theta = \theta_0$ , si on observe  $\varphi(X) = 0$  on décide que  $\theta = \theta_1$ .

La question est: comment choisir  $\varphi$ ? A une fonction de test  $\varphi$  on associe deux probabilités d'erreur:

$$\alpha(\varphi) = P_{\theta_0}(\varphi(X) = 1) \quad \text{et} \quad \beta(\varphi) = P_{\theta_1}(\varphi(X) = 0).$$

On va construire une fonction de test qui minimise  $\alpha(\varphi) + \beta(\varphi)$  ou plus généralement  $\gamma\alpha(\varphi) + \beta(\varphi)$  où  $\gamma > 0$  est un paramètre donné, en faisant l'hypothèse suivante: sous  $P_{\theta_0}$  le vecteur aléatoire  $X$  admet comme densité  $f_0 : \mathbb{R}^n \rightarrow \mathbb{R}_+$ , sous  $P_{\theta_1}$  le vecteur aléatoire  $X$  admet comme densité  $f_1 : \mathbb{R}^n \rightarrow \mathbb{R}_+$ .

(a) Soit  $\gamma > 0$ . Montrer que pour toute fonction de test  $\varphi : \mathbb{R}^n \rightarrow \{0, 1\}$  on a

$$\gamma\alpha(\varphi) + \beta(\varphi) = 1 + \int_{\mathbb{R}^n} \varphi(x)(\gamma f_0(x) - f_1(x)) dx.$$

En déduire une fonction de test  $\varphi_\gamma$  telle que  $\gamma\alpha(\varphi_\gamma) + \beta(\varphi_\gamma) \leq \gamma\alpha(\varphi) + \beta(\varphi)$  pour tout  $\varphi$ .

(b) On suppose que  $n = 1$  et  $X \sim \mathcal{N}(\theta, 1)$  sous  $P_\theta$ . Calculer  $\varphi_1$ .

(c) Soit  $\alpha \in [0, 1]$ . On suppose qu'il existe  $\gamma_\alpha > 0$  tel que  $\alpha(\varphi_{\gamma_\alpha}) = \alpha$ . Montrer que pour tout  $\varphi$  telle que  $\alpha(\varphi) \leq \alpha$  on a  $\beta(\varphi_{\gamma_\alpha}) \leq \beta(\varphi)$ .

(d) On observe  $X_1, \dots, X_n$  i.i.d., tous de loi  $\mathcal{N}(\theta, 1)$ . Pour  $\alpha \in ]0, 1[$ , déterminer  $\varphi_{\gamma_\alpha}$ .

**Exercice 4.** On observe  $X_1, \dots, X_n$  i.i.d. de loi  $\mathcal{N}(\mu, \sigma^2)$  où  $\mu \in \mathbb{R}$  est inconnue et  $\sigma^2 > 0$  est connu. On s'intéresse au problème de test pour les hypothèses suivantes:

$H_0 : \mu \leq \mu_0$  contre  $H_1 : \mu > \mu_0$  où  $\mu_0 \in \mathbb{R}$  est donnée.  $H_0$  est donc l'hypothèse nulle et par définition un test de niveau  $\alpha \in [0, 1]$  est une fonction  $\varphi : \mathbb{R}^n \rightarrow \{0, 1\}$  telle que  $\sup_{\mu \leq \mu_0} P_\mu(\varphi(X_1, \dots, X_n) = 1) \leq \alpha$ .

(a) Soit  $\alpha \in ]0, 1[$ . Déterminer un test  $\varphi^*$  de niveau  $\alpha$  tel que pour tout autre test  $\varphi$  de niveau  $\alpha$  on a pour tout  $\mu > \mu_0$ :  $P_\mu(\varphi^* = 0) \leq P_\mu(\varphi = 0)$ .

(b) On suppose que  $\sigma^2$  est aussi inconnu. On considère la statistique

$$T = \frac{\sqrt{n}(\bar{X}_n - \mu_0)}{\hat{\sigma}_n}.$$

Soit  $\alpha \in ]0, 1[$ . Déterminer la constante  $C_\alpha$  tel que  $P_{\mu_0}(T > C_\alpha) = \alpha$ . Montrer que le test  $\varphi(X_1, \dots, X_n) = 1_{\{T > C_\alpha\}}$  est de niveau  $\alpha$ .

**Intervalle de confiance**

**Exercice 5.** Un gramme de carbone extrait d'un organisme mort contient un nombre  $\theta$  d'atomes de carbone C14. Ces atomes de C14 ne sont pas stables et on modélise leur durée de vie par des variables aléatoires  $X_1, X_2, \dots, X_\theta$  i.i.d. de loi commune la loi exponentielle de paramètre 1. Dans la situation où  $\theta$  est inconnu et que l'on veut l'estimer, on compte le nombre de désintégrations sur l'intervalle de temps  $[0, t_0]$  où  $t_0 > 0$  est une constante choisie, autrement dit on observe la variable aléatoire

$$S = \sum_{i=1}^{\theta} 1_{\{X_i \leq t_0\}}.$$

- (a) Déterminer la loi de  $S$  c'est-à-dire calculer  $P(S = k)$  pour tout entier  $k$ .
- (b) Calculer l'espérance et la variance de  $S$  en fonction de  $\theta$  et de  $t_0$ .
- (c) Démontrer que pour tout  $\varepsilon > 0$ , pour tout  $\theta \in \mathbb{N}$  on a

$$P_\theta\left(\left|\frac{S}{1 - e^{-t_0}} - \theta\right| > \varepsilon\sqrt{\theta}\right) \leq \frac{e^{-t_0}}{1 - e^{-t_0}} \frac{1}{\varepsilon^2}.$$

- (d) En déduire un intervalle de confiance pour  $\theta$  de niveau d'erreur  $\alpha \in ]0, 1[$ .

**Exercice 6.** On dispose de l'observation de  $n_1$  variables aléatoires  $X_1, \dots, X_{n_1}$  indépendantes, de loi de Bernoulli de paramètre  $p_1 \in [0, 1]$ . On observe aussi  $Y_1, \dots, Y_{n_2}$  indépendantes, de loi de Bernoulli de paramètre  $p_2 \in [0, 1]$ , et indépendantes des  $X_i$ .

On souhaite construire un intervalle de confiance pour  $p_1 - p_2$ , les paramètres  $p_1$  et  $p_2$  étant inconnus.

- (a) Construire un estimateur  $T$  satisfaisant pour tout  $\varepsilon > 0$ :

$$P\left(\left|T - p_1 + p_2\right| \geq \varepsilon\right) \leq \frac{1}{4\varepsilon^2} \left(\frac{1}{n_1} + \frac{1}{n_2}\right).$$

En déduire la construction d'un intervalle de confiance, noté  $I_1(\alpha)$ , de niveau d'erreur  $\alpha \in ]0, 1[$  pour  $p_1 - p_2$ .

- (b) A l'aide de l'inégalité de Hoeffding (*qui est rappelée plus bas*), construire un estimateur  $S$  tel que pour tout  $\varepsilon > 0$ :

$$P\left(\left|S - p_1 + p_2\right| \geq \varepsilon\right) \leq 2 \exp\left(-2\varepsilon^2 n_1 n_2 / (n_1 + n_2)\right).$$

En déduire la construction d'un intervalle de confiance, noté  $I_2(\alpha)$ , de niveau d'erreur  $\alpha \in ]0, 1[$  pour  $p_1 - p_2$ .

- (c) On a obtenu (avec  $n_1 = 30$ ,  $n_2 = 25$ ) les statistiques

$$\frac{1}{n_1} \sum_{i=1}^{n_1} X_i = 0,6 \quad \frac{1}{n_2} \sum_{i=1}^{n_2} Y_i = 0,75$$

Comparer les longueurs de  $I_1(\alpha)$  et  $I_2(\alpha)$  pour  $\alpha = 30\%$ .

*Inégalité de Hoeffding :*

Soit  $\xi_1, \dots, \xi_n$  des variables aléatoires réelles indépendantes telles que pour tout  $i \in \{1, \dots, n\}$  on a  $E(\xi_i) = 0$  et il existe des constantes  $a_i, b_i \in \mathbb{R}$  satisfaisant  $a_i \leq \xi_i \leq b_i$ . Alors on a

$$\forall t \geq 0 \quad P(|\xi_1 + \dots + \xi_n| \geq t) \leq 2 \exp(-2t^2 / \sum_{i=1}^n (b_i - a_i)^2).$$

**Exercice 7.** Soient  $X_1, \dots, X_n$ , i.i.d. de loi

$$\nu_\theta(dx) = \exp(\theta - x)1_{[\theta, +\infty[}(x)dx, \quad \theta > 0.$$

- (a) Ecrire le modèle statistique associé. Est-il identifiable ?
- (b) Calculer  $E_\theta^n\{X_1\}$  et en déduire un estimateur convergent de  $\theta$  que l'on notera  $\hat{\theta}_n$ .
- (c) Etudier le risque quadratique  $E_\theta^n\{(\hat{\theta}_n - \theta)^2\}$  de l'estimateur  $\hat{\theta}_n$ . En déduire un intervalle de confiance  $I_n$  pour  $\theta$  au niveau de risque  $0 < \alpha < 1$ .
- (d) Montrer que l'estimateur  $\theta_n^* := \min_{1 \leq i \leq n} X_i$  est meilleur que  $\hat{\theta}_n$  au sens du risque quadratique.
- (e) Construire à l'aide de  $\theta_n^*$  un intervalle de confiance pour  $\theta$  au niveau de risque  $\alpha$ , dont la longueur est plus petite que celle de  $I_n$ .

**Exercice 8.** Pour  $a > 0$  et  $b > 0$ , la densité  $\gamma_{(a,b)}$  de la loi Gamma( $a, b$ ) est définie par

$$\gamma_{(a,b)}(x) = \frac{1}{\Gamma(a)} b^a \exp(-bx) x^{a-1} 1_{\mathbb{R}_+^*}(x) \quad \text{où} \quad \Gamma(a) = \int_0^\infty e^{-x} x^{a-1} dx.$$

- (a) Soit  $X$  de loi Gamma( $a, b$ ), calculer  $E(X)$  et  $\text{Var}(X)$ .
- (b) Calculer la transformée de Laplace  $t \rightsquigarrow E(e^{-tX})$  de la loi Gamma.
- (c) On considère deux variables aléatoires indépendantes  $X_1$  et  $X_2$ , de loi Gamma( $a_1, b$ ) et Gamma( $a_2, b$ ). Déduire du calcul de la transformée de Laplace de  $X_1 + X_2$  la loi de  $X_1 + X_2$ .
- (d) Soit  $(X_1, \dots, X_n)$  un  $n$ -échantillon de la loi  $\mathcal{N}(0, 1)$ . Quelle est la densité de  $X_1^2 + \dots + X_n^2$  ? (On pourra d'abord reconnaître la loi de  $X_1^2$  via le calcul de sa transformée de Laplace.)

**Exercice 9.** La durée de vie d'une ampoule électrique est une variable aléatoire de loi  $\mathcal{E}(\lambda) = \text{Gamma}(1, \lambda)$ , la loi exponentielle de paramètre  $\lambda \in \mathbb{R}_+^*$ . On mesure la durée de vie de  $n$  ampoules, on obtient donc une réalisation des variables aléatoires  $X_1, \dots, X_n$ , que l'on supposera indépendantes.

- (a) Que vaut l'espérance de la durée de vie d'une ampoule ? Calculer le risque quadratique de la statistique  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  en tant qu'estimateur de  $1/\lambda$ .
- (b) On veut estimer  $\lambda$ . Calculer le risque quadratique de l'estimateur  $1/\bar{X}$ .
- (c) Soit  $\alpha \in ]0, 1[$ . Construire un intervalle de confiance asymptotique pour  $\lambda$  de niveau d'erreur  $\alpha$ .

**Exercice 10.** Soient  $X$  une variable aléatoire gaussienne centrée réduite, indépendante de la suite de variables aléatoires  $(Y_n)$  où  $Y_n$  suit la loi  $\chi^2(n)$ . On pose  $T_n = \frac{X}{\sqrt{Y_n/n}}$ .

(a) Montrer que la densité  $t_n$  de  $T_n$  est donnée par

$$t_n(x) = \frac{1}{\sqrt{\pi}} \frac{\Gamma((n+1)/2)}{\sqrt{n}\Gamma(n/2)} \frac{1}{(1+t^2/n)^{(n+1)/2}}.$$

(b) Montrer que pour tout  $x \in \mathbb{R}$   $\lim_{n \rightarrow \infty} t_n(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$ . On pourra tout d'abord montrer que  $\Gamma(a+1/2)/\Gamma(a) \sim \sqrt{a}$  quand  $a \rightarrow \infty$  en remarquant que  $\Gamma(a+1/2)/\Gamma(a) = E[\sqrt{U}]$  où  $U$  suit une loi *Gamma*( $a, 1$ ).

(c) Montrer que  $(T_n)$  converge en loi et identifier sa limite.

**Exercice 11.** Dans l'atmosphère, le taux d'un gaz nocif, pour un volume donné, suit une loi normale d'espérance  $\mu$  et de variance  $\sigma^2$  inconnues. On effectue  $n$  prélèvements conduisant aux valeurs  $X_1, X_2, \dots, X_n$ .

(a) Sur un échantillon de taille  $n = 10$ , on observe que  $\bar{X} = 50$  et  $S^2 = 100$  où  $S^2 = \frac{1}{9} \sum_{i=1}^{10} (X_i - \bar{X})^2$ .

(b) Quel est l'intervalle de confiance de niveau de confiance 95 % du taux moyen  $\mu$  de gaz dans l'atmosphère ?

(c) Construire un intervalle de confiance pour  $\sigma^2$  de niveau de confiance 95%.

**Exercice 12.** On cherche à évaluer la proportion  $p \in [0, 1]$  de personnes téléchargeant illégalement sur internet dans une population donnée. On choisit au hasard  $n$  individus dans cette population. La procédure de sondage est la suivante. On demande à chaque individu interrogé de tirer au préalable (sans être vu) une boule dans une urne, et de répondre ensuite par "OUI" ou "NON" à l'une des deux questions : Question 1 : "Est-ce que vous avez déjà téléchargé illégalement ?" si la boule tirée est blanche, Question 2 : "Est-ce que vous n'avez jamais téléchargé illégalement?" si la boule tirée n'est pas blanche. (bien sûr, seul l'individu interrogé a connaissance de la couleur de la boule, afin que personne d'autre ne sache à quelle question il a répondu). La proportion  $\varphi$  de boules blanches dans l'urne est connue et différente de 1/2. On note  $X_1, \dots, X_n$  les variables aléatoires qui correspondent aux réponses des  $n$  personnes interrogées (ce sont donc des variables aléatoires à valeurs dans  $\{Oui, Non\}$ ). Soit  $R$  le nombre de réponses "OUI" obtenues.

(a) Quelle est la loi de  $X_1$  ?

(b) Quelle la loi de  $R$  ? Calculer  $E(R)$ .

(c) En déduire un estimateur sans biais  $\hat{p}$  de  $p$ .

(d) Calculer le risque quadratique de l'estimateur  $\hat{p}$ . Commenter les cas  $\varphi = 0$ ,  $\varphi = 1$ ,  $\varphi \rightarrow 1/2$ .

(e) Construire à partir de  $\hat{p}$  un intervalle de confiance pour  $p$  de niveau  $\alpha$ .

### Histogramme

**Exercice 13.** On observe  $X_1, \dots, X_n$  à valeurs dans  $[0, 1]$ , tous de densité  $f : [0, 1] \rightarrow \mathbb{R}_+$ . Pour  $p \in \mathbb{N}^*$ , on introduit les classes

$$A(p, k) = [(k-1)/p, k/p[, \quad 1 \leq k \leq p-1, \quad A(p, p) = [(p-1)/p, 1]$$

et l'histogramme associé

$$\hat{f}_{n,p}(x) = \frac{p}{n} \sum_{k=1}^p N(n, p)_k 1_{A(p,k)}(x), \quad x \in [0, 1],$$

$$\text{où } N(n, p)_k = \sum_{i=1}^n 1_{\{X_i \in A(p, k)\}}.$$

On suppose dans la suite que  $f$  est continûment dérivable.

(a) Montrer que  $E_f^n[\hat{f}_{n,p}(x)]$  ne dépend de  $p$ . On le notera  $\bar{f}_p(x)$ .

(b) En utilisant que

$$\lim_{p \rightarrow \infty} p \max_{1 \leq k \leq p} \sup_{x \in A(k,p)} |f(x) - f((k-1)/p) - f'((k-1)/p)(x - (k-1)/p)| = 0$$

montrer qu'il existe une constante  $C_{f'}$  qui ne dépend que de  $f'$  telle que

$$p^2 \int_0^1 (f(x) - \bar{f}_p(x))^2 dx \rightarrow C_{f'} \quad \text{quand } p \rightarrow \infty.$$

(c) Montrer que

$$\frac{n}{p} \int_0^1 \text{Var}_{P_f^n}(\hat{f}_{n,p}(x)) dx \rightarrow 1 \quad \text{quand } (n, p) \rightarrow (\infty, \infty).$$

(d) On note  $\mathcal{R}_{\hat{f}_{n,p}}(f)$  le risque quadratique de  $\hat{f}_{n,p}$ . Soit  $a$  et  $b$  strictement positifs. On pose  $p_n = an^b$ . Montrer que si  $f$  n'est pas constante, il existe  $\alpha > 0$  tel que  $n^\alpha \mathcal{R}_{\hat{f}_{n,p_n}}(f)$  converge vers une limite strictement positive.

Pour quelle valeur de  $b$  l'exposant  $\alpha$  est-il le plus grand ? Pour ce choix de  $b$ , quelle est la meilleure valeur de  $a$  ?