

## CORRECTION TD5 STATISTIQUES INFÉRENTIELLES

### Exercice 1

On peut modéliser l'expérience comme un 3-échantillon pour la loi géométrique de paramétrique  $p$  inconnu,  $X \sim \text{Geom}(p)$ . Ici on doit choisir entre  $p_1 = 5/6$ , qui correspond à  $D_1$  et  $p_2 = 1/6$ , qui correspond à  $D_2$ . Posons  $q_1 = 1 - p_1$  et  $q_2 = 1 - p_2$ .

#### Question 1 :

La probabilité sous l'hypothèse qu'on a tiré  $D_1$  au tout début de l'expérience, d'avoir le 3-échantillon  $(3, 5, 4)$  est :

$$P_{D_1}(3, 5, 4) = P_X(3)P_X(5)P_X(4) = q_1^2 p_1 q_1^4 p_1 q_1^3 p_1$$

$$P_{D_1}(3, 5, 4) = q_1^9 p_1^3$$

$$P_{D_1}(3, 5, 4) \cong 5.742421.10^{-8}$$

#### Question 2 :

$$P_{D_2}(3, 5, 4) = q_2^9 p_2^3$$

$$P_{D_2}(3, 5, 4) \cong 8,972532.10^{-8}$$

Question 3 : A la suite de cette expérience on choisit le modèle qui est le plus vraisemblable. Ici  $P_{D_2}(3, 5, 4) > P_{D_1}(3, 5, 4)$  donc on conclue que vraisemblablement le dé  $D_2$  est à l'origine de cet échantillon.

### Exercice 2

#### Question 1 :

Soit  $x_1, \dots, x_n$  une réalisation d'un échantillon distribué selon une loi normale de paramètre  $\mu$  inconnu et  $\sigma = 1$ . On note  $P_\mu(x_1 \dots x_n)$  la probabilité de cette réalisation sous l'hypothèse que l'échantillon est i.i.d suivant  $N(\mu, 1)$ .

$$P_\mu(x_1 \dots x_n) = \frac{1}{\sqrt{2\pi}^n} \prod_{i=1}^n e^{-\frac{1}{2}(x_i - \mu)^2}$$

$$P_\mu(x_1 \dots x_n) = \frac{1}{\sqrt{2\pi}^n} e^{-\frac{1}{2} \sum_{i=1}^n (x_i - \mu)^2}$$

$\max_{\mu \in \mathbb{R}} P_\mu(x_1 \dots x_n)$  est atteint quand  $\min_{\mu \in \mathbb{R}} \sum_{i=1}^n (x_i - \mu)^2$  est atteint. Posons pour tout  $\mu \in \mathbb{R}$ ,  $f(\mu) = \sum_{i=1}^n (x_i - \mu)^2$ ;  $f \in C^\infty(\mathbb{R})$  et convexe.

Pour tout  $\mu \in \mathbb{R}$ ,  $f'(\mu) = 2 \left( \sum_{i=1 \dots n} x_i - n\mu \right)$  donc,

$$\forall \mu \in \mathbb{R}, \quad f'(\mu) = 0 \quad \iff \quad \mu = \frac{\sum_{i=1 \dots n} x_i}{n}$$

On reconnaît que  $\bar{x}_n := \frac{\sum_{i=1 \dots n} x_i}{n}$ .

On a donc que  $f$  admet un minimum en  $\mu = \bar{x}_n$  donc  $P_\mu(x_1 \dots x_n)$  admet un maximum en  $\mu = \bar{x}_n$ .

L'estimateur du maximum de vraisemblance de  $\mu$  est  $\hat{\mu} = \bar{x}_n$ .

Question 2 :

On suppose que  $\sigma > 0$ .

$$P_{\sigma^2}(x_1 \dots x_n) = \frac{1}{(2\pi)^{\frac{n}{2}} \sigma^n} \prod_{i=1}^n e^{-\frac{1}{2}(x_i/\sigma)^2}$$

$$P_{\sigma^2}(x_1 \dots x_n) = \frac{1}{(2\pi)^{\frac{n}{2}} \sigma^n} e^{-\frac{1}{2} \sum_{i=1}^n (x_i/\sigma)^2} > 0$$

Considérons la log vraisemblance,

$$g(\sigma^2) := \ln P_{\sigma^2}(x_1 \dots x_n) = -\frac{1}{2} \sum_{i=1}^n (x_i/\sigma)^2 - \frac{n}{2} \ln \sigma^2 - \frac{n}{2} \ln(2\pi)$$

$g : \mathbb{R}_*^+ \rightarrow \mathbb{R}$  est  $C^1(\mathbb{R}_*^+)$ , pour tout  $t \in \mathbb{R}_*^+$ ,

$$g'(t) = \frac{1}{2} \sum_{i=1}^n x_i^2/t^2 - \frac{n}{2t}$$

$$\forall t > 0, \quad g'(t) = 0 \quad \iff \quad t = \frac{\sum_{i=1}^n x_i^2}{n}$$

Posons  $\hat{V} = \frac{\sum_{i=1}^n x_i^2}{n}$  et étudions les variations de  $g$ . Si  $0 < t < \hat{V}$ , alors  $g$  est strictement croissante ; si  $t > \hat{V}$ ,  $g$  est strictement décroissante. Comme  $g$  est continue elle atteint son maximum en  $\hat{V}$  ; il en est de même pour la vraisemblance, donc l'estimateur du maximum de vraisemblance est  $\hat{V}$ .

Par ailleurs,

$$E_{\sigma^2}[\hat{V}] = \frac{1}{n} \sum_{i=1}^n E_{\sigma^2}[X_i^2] = \frac{1}{n} \sum_{i=1}^n \sigma^2$$

$$E_{\sigma^2}[\hat{V}] = \sigma^2$$

Donc,

$$B(\hat{V}) = E_{\sigma^2}[\hat{V}] - \sigma^2 = 0$$

### Exercice 3

La vraisemblance de la réalisation est,

$$P_\delta(x_1 \dots x_n) = e^{-\sum_{i=1 \dots n} (x_i - \delta)} 1_{[\min_{i=1 \dots n} x_i \geq \delta]}$$

Posons,  $f(\delta) = e^{-\sum_{i=1 \dots n} (x_i - \delta)} = e^{n\delta} e^{-\sum_{i=1 \dots n} x_i}$  pour  $\delta \leq \min_{i=1 \dots n} x_i$  ; elle est croissante donc son maximum est atteint en  $\min_{i=1 \dots n} x_i$ . Par ailleurs,  $e^{n \min_{i=1 \dots n} x_i} e^{-\sum_{i=1 \dots n} x_i} > 0$  donc le maximum de vraisemblance est atteint en  $\hat{\delta} = \min_{i=1 \dots n} x_i$ .

### Exercice 4

On rappelle que la fonction de répartition de la loi de Pareto de paramètre  $\alpha > 0$  est donnée par, pour  $x < 1$ ,

$$F_\alpha(t) = 0$$

pour  $x \geq 1$ ,

$$F_\alpha(t) = 1 - t^{-\alpha}$$

$F_\alpha$  est  $C^1$  par morceaux, donc elle admet une densité de probabilité (par exemple) donnée par, si  $x < 1$ ,

$$f_\alpha(x) = 0$$

et si  $x \geq 1$ ,

$$f_\alpha(x) = \alpha t^{-(\alpha+1)}$$

Reparamétrisons cette densité en  $\beta = 1/\alpha$ , pour  $x < 1$ ,

$$f_\beta(x) = 0$$

pour  $x \geq 1$ ,

$$f_\beta(x) = \frac{1}{\beta} t^{-(1+\frac{1}{\beta})} = \frac{1}{\beta} e^{-(1+\frac{1}{\beta}) \ln(t)}$$

La vraisemblance est donnée par,

$$P_\beta(x_1 \dots x_n) = \frac{1}{\beta^n} e^{-(1+\frac{1}{\beta}) \sum_{i=1 \dots n} \ln x_i} 1_{[\min_{i=1 \dots n} x_i \geq 1]}$$

Posons  $f : \mathbb{R}_*^+ \rightarrow \mathbb{R}$ , pour tout  $\beta \in \mathbb{R}_*^+$ ,  $f(\beta) = P_\beta(x_1 \dots x_n)$ ; par ailleurs  $f \in C^\infty(\mathbb{R}_*^+)$ . Si  $\min_{i=1 \dots n} x_i < 1$  tout nombre dans  $\mathbb{R}_*^+$  maximise la vraisemblance, si  $\min_{i=1 \dots n} x_i \geq 1$ ,

$$\forall t \in \mathbb{R}_*^+, f'(t) \geq 0 \iff -\frac{n}{\beta^{n+1}} + \frac{\sum_{i=1 \dots n} \ln x_i}{\beta^{n+2}} = 0$$

$$\forall t \in \mathbb{R}_*^+, f'(t) \geq 0 \iff \beta \leq \frac{\sum_{i=1 \dots n} \ln x_i}{n}$$

Comme  $f$  est  $C^\infty$  elle est en particulier continue, donc elle atteint son maximum en  $\frac{\sum_{i=1 \dots n} \ln x_i}{n}$ .

### Exercice 5

#### Question 1

Pour tout  $0 < \theta < 1$ ,

$$L(\theta) = p(1)^{1997} p(2)^{32} p(3)^{906} p(4)^{904}$$

$$l(\theta) = 1997 \ln p(1) + 32 \ln p(2) + 906 \ln p(3) + 904 \ln p(4)$$

$$l(\theta) = 1997 \ln(2 + \theta) + 32 \ln(\theta) + 1810 \ln(1 - \theta) - 7646 \ln 2$$

Question 3

Supposons que  $n_1, n_2, n_3, n_4$  sont strictement positifs.

Il existe une constante  $C$  telle que pour tout  $\theta \in ]0, 1[$ ,

$$l(\theta) = n_1 \ln(2 + \theta) + n_2 \ln(\theta) + (n_3 + n_4) \ln(1 - \theta) + C$$

Posons  $n_5 = n_3 + n_4$ .

$l \in C^1(]0, 1[)$ , pour tout  $\theta \in ]0, 1[$ ,

$$l'(\theta) = \frac{n_1}{2 + \theta} + \frac{n_2}{\theta} - \frac{n_5}{1 - \theta}$$

$$\forall \theta \in ]0, 1[ \quad l'(\theta) \geq 0 \quad \iff \quad n_1\theta(1 - \theta) + n_2(2 + \theta)(1 - \theta) - n_5(2 + \theta)\theta \geq 0$$

Posons, pour  $\theta \in \mathbb{R}$ ,  $P(\theta) = n_1\theta(1 - \theta) + n_2(2 + \theta)(1 - \theta) - n_5(2 + \theta)\theta$ , c'est un polynôme du second degré.

Pour  $\theta \in \mathbb{R}$ ,

$$P(\theta) = n_1(\theta - \theta^2) + n_2(2 - 2\theta + \theta - \theta^2) - n_5(2\theta + \theta^2) = -n\theta^2 + (n_1 - n_2 - 2n_5)\theta + 2n_2$$

$\Delta = (n_1 - n_2 - 2n_5)^2 + 8nn_2 \geq 0$ . Donc une racine de  $P$  est  $\theta_1 = \frac{-(n_1 - n_2 - 2n_5) - \sqrt{\Delta}}{2n}$  et l'autre est  $\theta_2 = \frac{-(n_1 - n_2 - 2n_5) + \sqrt{\Delta}}{2n}$ ; Par ailleurs,  $\theta_2 \geq \theta_1$ .

Pour  $\theta \in ]0, 1[$  le signe de  $l'$  est le signe de  $P$ ; or  $P$  est positif en ses racines et négatif en dehors.

On remarque que  $\lim_{\theta \rightarrow 0} l'(\theta) = +\infty$  et que  $\lim_{\theta \rightarrow 1} l'(\theta) = -\infty$  donc le signe de  $P$  sur  $]0, 1[$  doit être positif puis négatif et ceci n'est possible que si  $\theta_2 \in ]0, 1[$  et  $\theta_1 < 0$ . Ainsi on trouve que pour tout  $\theta \in ]0, \theta_2[$   $l'(\theta) > 0$  et pour  $\theta \in ]\theta_2, 1[$   $l'(\theta) < 0$  donc

$$\hat{\theta} = \theta_2 = \frac{-(n_1 - n_2 - 2n_5) + \sqrt{\Delta}}{2n}$$