

**Exercice 1**

On dispose de  $n$  observations  $x_1, \dots, x_n$  issues d'un échantillon  $(X_1, \dots, X_n)$  de loi normale  $\mathcal{N}(0, \sigma^2)$ .

1. Déterminer suivant les valeurs de  $\sigma_0^2$  et de  $\sigma_1^2$ , la statistique  $T(X_1, \dots, X_n)$  et la région critique du test de Neyman-Pearson associé au problème suivant :

$$\begin{cases} H_0 : \sigma^2 = \sigma_0^2 \\ H_1 : \sigma^2 = \sigma_1^2 \end{cases}$$

Commenter la forme de la statistique de test. Dans la suite de ce problème, on supposera  $\sigma_1 > \sigma_0$ .

2. On admettra que  $T = \frac{1}{\sigma^2} \sum_{i=1}^n X_i^2$  suit une loi du  $\chi_n^2$ . Déterminer la valeur des risques de première et seconde espèce  $\alpha$  et  $\beta$  en fonction du seuil du test noté  $S$ , de la fonction de répartition d'une loi du  $\chi_n^2$  notée  $F_n$  et de  $\sigma_0$  et  $\sigma_1$ .
3. Déterminer les courbes COR (caractéristiques opérationnelles du récepteur) associées au problème précédent. Comment la puissance du test de Neyman Pearson dépend-elle de  $\sigma_0$  et de  $\sigma_1$  ? Représenter la forme approximative des courbes COR pour différentes valeurs de ces paramètres.
4. Quelle est la loi asymptotique de la statistique de  $T(X_1, \dots, X_n)$  sous les deux hypothèses  $H_0$  et  $H_1$  issue de l'application du théorème de la limite centrale ? En utilisant cette loi asymptotique, déterminer les courbes COR du problème et montrer que leur expression en fonction de  $\sigma_0^2$  et  $\sigma_1^2$  est en accord avec la question précédente.

**Exercice 2 : Test Statistique**

On considère  $n$  variables aléatoires  $Y_1, \dots, Y_n$  indépendantes de densités

$$f(y_i; \theta) = \frac{1}{\sqrt{2\pi\theta y_i}} \exp\left(-\frac{y_i}{2\theta}\right) \mathbb{I}_{\mathbb{R}^+}(y_i)$$

avec  $\theta > 0$  et où  $\mathbb{I}_{\mathbb{R}^+}$  indique la fonction indicatrice sur  $\mathbb{R}^+$ . On veut à l'aide d'observations  $y_1, \dots, y_n$  de ces variables aléatoires tester les deux hypothèses suivantes

$$H_0 : \theta = \theta_0 \text{ contre } H_1 : \theta = \theta_1 \quad \text{avec } \theta_1 > \theta_0.$$

1. À l'aide du théorème de Neyman-Pearson, calculer la statistique  $T_n$  du test le plus puissant et indiquer la région critique de ce test (comme d'habitude, on retiendra pour  $T_n$  la fonction seule des observations).
2. Montrer que  $\frac{Y_i}{\theta}$  possède une loi du  $\chi_1^2$ . En déduire que  $\frac{T_n}{\theta}$  suit une loi du  $\chi_n^2$ .
3. En déduire une expression des risques de première et seconde espèce  $\alpha$  et  $\beta$  du test en fonction des paramètres  $\theta_0$  et  $\theta_1$  et de la fonction de répartition d'une loi du  $\chi_n^2$  notée  $F_n$ .
4. Déterminer les courbes COR associées à ce test et expliquer comment les performances de ce test dépendent des valeurs de  $\theta_0$  et  $\theta_1$ .
5. On désire à partir d'un ensemble d'observations  $(y_1, \dots, y_n)$  déterminer s'il est raisonnable de supposer que ces observation sont issues de la densité  $f(y_i; \theta)$ . Expliquer le principe du test de Kolmogorov pour résoudre ce problème: on précisera avec soin 1) comment calculer la statistique de ce test notée  $D_n$ , 2) la région critique du test, 3) l'expression du seuil du test en fonction du risque de première espèce  $\alpha$  et de la loi asymptotique de  $\sqrt{n}D_n$  et 4) la manière de prendre en compte le fait que  $\theta$  soit inconnu.

### Exercice 3.

On considère les observations  $x_i, i = 1, \dots, n$  (avec  $n = 10$ ) définies par

$x_1 = 1$	$x_2 = 0$	$x_3 = 1$	$x_4 = 1$	$x_5 = 1$	$x_6 = 1$	$x_7 = 1$	$x_8 = 2$	$x_9 = 0$	$x_{10} = 0$
-----------	-----------	-----------	-----------	-----------	-----------	-----------	-----------	-----------	--------------

On suppose que les variables aléatoires associées à ces observations sont indépendantes et issues de la même loi de Poisson  $P(\lambda)$ . On rappelle que si  $X$  suit une loi de Poisson de paramètre  $\lambda$ , on a  $E[X] = \text{var}[X] = \lambda$  et  $\varphi_X(t) = E[e^{itX}] = \exp[\lambda(e^{it} - 1)]$ . On désire tester les deux hypothèses

$$\begin{cases} H_0 : \lambda = \lambda_0 \text{ (absence de planète)} \\ H_1 : \lambda = \lambda_1 \text{ (présence de planète)} \end{cases}$$

avec  $\lambda_1 < \lambda_0$ .

1. Vérifier que la statistique du test de Neyman-Pearson peut s'écrire  $T = \sum_{i=1}^n X_i$  et déterminer la région critique associée.
2. Déterminer la fonction caractéristique de  $T$  et en déduire que  $T$  suit une loi de Poisson que l'on précisera sous chaque hypothèse.
3. On suppose que  $n$  est suffisamment grand pour pouvoir utiliser les résultats du théorème de la limite centrale.
  - Donner la loi approchée de  $T$  issue de ce théorème.
  - Quelle est la valeur du seuil obtenue lorsqu'on confond la loi de  $T$  avec son approximation.
  - Déterminer les courbes COR (caractéristiques opérationnelles du récepteur) découlant de cette loi approchée. On posera

$$\Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}} du$$

et on notera  $\Phi^{-1}(x)$  son inverse. En supposant que  $n$  est suffisamment grand pour faire les approximations nécessaires, déterminer les paramètres qui influent sur la performance asymptotique ( $n \rightarrow \infty$ ) du test. De ces deux cas

*Premier Cas* :  $n = 100, \lambda_0 = 1, \lambda_1 = 0.1$

*Deuxième Cas* :  $n = 100, \lambda_0 = 2, \lambda_1 = 1.1$

indiquer celui qui engendre la meilleure performance.

### Exercice 4.

Afin de tester la satisfaction des clients à service donné, on effectue un sondage et on définit une variable aléatoire  $Y_i$  de la façon suivante :

$$Y_i = 1 \text{ si le client } i \text{ est satisfait}$$

$$Y_i = 0 \text{ si le client } i \text{ n'est pas satisfait}$$

A l'aide d'un échantillon  $(Y_1, \dots, Y_n)$  de même loi de Bernoulli

$$P[Y_i = 0] = \theta$$

$$P[Y_i = 1] = 1 - \theta$$

on désire tester les hypothèses  $H_0 : \theta = \theta_0 = 0.52$  et  $H_1 : \theta = \theta_1 = 0.48$ .

1. Construire la vraisemblance des observations  $y_1, \dots, y_n$  et expliciter la région de rejet de  $H_0$  du test de Neyman-Pearson (pour l'application numérique, on choisira un risque de première espèce  $\alpha = 0.1$ ).

2. Déterminer la puissance de ce test.

### Exercice 5.

On lance un dé 60 fois et on relève les nombres de fois où on a observé les différentes faces

$x_i$	1	2	3	4	5	6
$n_i$	15	7	4	11	6	17

On se demande si ce dé est truqué (Hypothèse  $H_1$ ) ou non (Hypothèse  $H_0$ ).

1. Déterminer la statistique du test du chi-deux noté  $\phi$  associée à ce problème.
2. Quelle est la loi de cette statistique de test sous l'hypothèse  $H_0$  ?
3. Expliquer comment déterminer le seuil de décision  $S_\alpha$  du test du chi-deux à l'aide de la fonction de répartition de la loi déterminée à la question précédente et du risque  $\alpha$  de ce test. Pour  $\alpha = 0.05$ , on trouve  $S_{0.05} = 11.07$  et pour  $\alpha = 0.01$ , on a  $S_{0.01} = 15.09$ . Que conclut-on ?

### Exercice 6.

Un statisticien pose la question suivante à un échantillon de 30 participants : "Préférez-vous boire du thé ou du café ?". Parmi cet échantillon, 10 préfèrent le thé et 20 préfèrent le café. Il désire effectuer un test du chi-deux pour déterminer s'il y a une véritable préférence pour le café dans cet échantillon. Pour cela, il définit l'hypothèse  $H_0$  par "la probabilité de boire du thé est égale à la probabilité de boire du café", i.e., les deux classes {Thé} et {Café} sont équiprobables ( $P[\text{Thé}] = P[\text{Café}] = \frac{1}{2}$ ).

1. Déterminer la statistique du test du chi-deux noté  $\phi$  associée à ce problème.
2. Rappeler la loi de  $\phi$  sous l'hypothèse  $H_0$  (définie par "Il n'y a pas de préférence ni pour le thé, ni pour le café").
3. Expliquer comment déterminer le seuil de décision  $S_\alpha$  du test du chi-deux à l'aide de la fonction de répartition de la loi déterminée à la question précédente et du risque  $\alpha$  de ce test. Pour  $\alpha = 0.05$ , on trouve  $S_{0.05} = 3.84$ . Que conclut-on ?

## Corrections exercices des TDs

### Exercice 1

1) Des calculs classiques permettent d'obtenir la règle de décision suivante :

$$\begin{aligned} \text{Si } \sigma_1 > \sigma_0, \quad \text{rejet de } H_0 \text{ si } T = \sum_{i=1}^n X_i^2 > S \\ \text{Si } \sigma_1 < \sigma_0, \quad \text{rejet de } H_0 \text{ si } T = \sum_{i=1}^n X_i^2 < S. \end{aligned}$$

La statistique du test est donc  $T = T(X_1, \dots, X_n) = \sum_{i=1}^n X_i^2$ , c'est-à-dire  $n$  fois le moment d'ordre 2 empirique des variables  $X_i$ . Ceci semble naturel puisque  $E[X_i^2] = \sigma^2$  varie sous les deux hypothèses  $H_0$  et  $H_1$ .

2) Le risque de première espèce est

$$\begin{aligned} \alpha &= P[\text{rejeter } H_0 | H_0 \text{ vraie}] \\ &= P[T > S | \sigma = \sigma_0] \\ &= P\left[\frac{1}{\sigma_0^2}T > \frac{S}{\sigma_0^2} \mid \sigma = \sigma_0\right] \end{aligned}$$

On sait que  $\frac{1}{\sigma_0^2}T$  suit une loi du chi2 à  $n$  degrés de liberté sous l'hypothèse  $H_0$ , donc

$$\alpha = 1 - F_n\left(\frac{S}{\sigma_0^2}\right), \text{ i.e., } S = \sigma_0^2 F_n^{-1}(1 - \alpha).$$

Le risque  $\beta$  peut se calculer de la même façon

$$\begin{aligned} \beta &= P[\text{rejeter } H_1 | H_1 \text{ vraie}] \\ &= P[T \leq S | \sigma = \sigma_1] \\ &= P\left[\frac{1}{\sigma_1^2}T \leq \frac{S}{\sigma_1^2} \mid \sigma = \sigma_1\right] \\ &= F_n\left(\frac{S}{\sigma_1^2}\right). \end{aligned}$$

3) Si on appelle  $\pi$  la puissance du test, les courbes COR sont définies par

$$\begin{aligned} \pi &= 1 - \beta = 1 - F_n\left(\frac{S}{\sigma_1^2}\right) \\ \pi &= 1 - F_n\left(\frac{\sigma_0^2}{\sigma_1^2} F_n^{-1}(1 - \alpha)\right) \end{aligned}$$

On voit donc que  $\pi$  est une fonction décroissante de  $\frac{\sigma_0^2}{\sigma_1^2}$ , c'est-à-dire une fonction croissante de  $\frac{\sigma_1^2}{\sigma_0^2}$ , ce qui est normal.

4) Le théorème de la limite centrale nous permet d'approcher, pour  $n$  "grand", la loi de  $T(X_1, \dots, X_n) = \sum_{i=1}^n X_i^2$  par une loi normale  $\mathcal{N}(nE[X_1^2], n\text{var}[X_1^2])$ . Mais

$$\begin{aligned} E[X_1^2] &= \sigma^2 \\ \text{var}[X_1^2] &= E[X_1^4] - E[X_1^2]^2 = 3\sigma^4 - \sigma^4 = 2\sigma^4. \end{aligned}$$

Donc, on peut approcher la loi de  $T$  par une loi normale  $\mathcal{N}(n\sigma^2, 2n\sigma^4)$ . En notant  $G$  la fonction de répartition d'une loi normale  $\mathcal{N}(0, 1)$ , on en déduit

$$\begin{aligned}\alpha &= P[\text{rejeter } H_0 \mid H_0 \text{ vraie}] \\ &= P\left[\frac{T - n\sigma^2}{\sqrt{2n\sigma^2}} > \frac{S - n\sigma^2}{\sqrt{2n\sigma^2}} \mid \sigma = \sigma_0\right] \\ &= 1 - G\left(\frac{S - n\sigma_0^2}{\sqrt{2n\sigma_0^2}}\right)\end{aligned}$$

d'où

$$S = n\sigma_0^2 + \sqrt{2n\sigma_0^2}G^{-1}(1 - \alpha).$$

et

$$\begin{aligned}\beta &= P[\text{rejeter } H_1 \mid H_1 \text{ vraie}] \\ &= P[T \leq S \mid \sigma = \sigma_1] \\ &= P\left[\frac{T - n\sigma_1^2}{\sqrt{2n\sigma_1^2}} \leq \frac{S - n\sigma_1^2}{\sqrt{2n\sigma_1^2}} \mid \sigma = \sigma_1\right] \\ &= G\left(\frac{S - n\sigma_1^2}{\sqrt{2n\sigma_1^2}}\right).\end{aligned}$$

La puissance du test s'écrit donc

$$\pi = 1 - \beta = 1 - G\left(\frac{S - n\sigma_1^2}{\sqrt{2n\sigma_1^2}}\right).$$

Après avoir remplacé  $S$  par son expression trouvée ci-dessus, on obtient

$$\pi = 1 - \beta = 1 - G\left(-\sqrt{\frac{n}{2}} + \frac{\sigma_0^2}{\sigma_1^2} \left[\sqrt{\frac{n}{2}} + G^{-1}(1 - \alpha)\right]\right).$$

qui est une fonction croissante de  $\frac{\sigma_1^2}{\sigma_0^2}$ , comme dans la question précédente.

On a donc  $\beta(\alpha) = \frac{n}{n+2}$

$\beta(\alpha) \rightarrow 1$   $\alpha \rightarrow 0$  donc  $\hat{\sigma}_{MMSE}^2$  se comporte comme  $\hat{\sigma}_{MV}^2$  quand  $n \rightarrow \infty$   
 (on fait confiance aux données)

$\beta(\alpha) \rightarrow 0$   $\alpha \rightarrow 1$  donc  $\hat{\sigma}_{MMSE}^2$  se comporte comme  $\sigma_0^2$  qui est la  
 moyenne de la loi a priori (on fait confiance à l'information a priori)

**Exercice 2**

① Le test de Neyman-Pearson s'écrit

Rejet de  $H_0$  si  $\frac{L(y_1, \dots, y_n; \theta_1)}{L(y_1, \dots, y_n; \theta_0)} > \text{seuil}$

soit  $\frac{\frac{1}{(2\pi\theta_1)^{n/2}} \frac{1}{\pi\sqrt{2}} \exp\left(-\frac{1}{2\theta_1} \sum_{i=1}^n y_i\right)}{\frac{1}{(2\pi\theta_0)^{n/2}} \frac{1}{\pi\sqrt{2}} \exp\left(-\frac{1}{2\theta_0} \sum_{i=1}^n y_i\right)} > \text{seuil}$

Un test équivalent est donc (on simplifie et on calcule le logarithme des deux membres de l'inégalité)

Rejet de  $H_0$  si  $\underbrace{\left(\frac{1}{\theta_0} - \frac{1}{\theta_1}\right)}_{> 0 \text{ car } \theta_1 > \theta_0} \sum_{i=1}^n y_i > \text{seuil}$

soit

Rejet de  $H_0$  si  $\sum_{i=1}^n y_i > S_\alpha$

la statistique de test est donc  $T_n = \sum_{i=1}^n y_i$  et la région critique du test est  $\{(y_1, \dots, y_n) / \sum_{i=1}^n y_i > S_\alpha\}$

2) on pose  $z_i = \frac{y_i}{\theta}$  qui est un changement de variable bijectif de  $\mathbb{R}^+$  dans  $\mathbb{R}^+$  de Jacobien  $\left| \frac{dy_i}{dz_i} \right| = \theta$  - On en déduit la densité de  $z_i$

(5)

$$g(z_i) = \frac{1}{\sqrt{2\pi} z_i \theta^2} \exp\left(-\frac{z_i}{\theta}\right) \quad \theta > 0 \quad z_i > 0$$

Soit

$$g(z_i) = \frac{1}{\sqrt{2\pi} z_i} e^{-z_i/\theta} \quad \mathbb{1}_{\mathbb{R}^+}(z_i)$$

On reconnaît d'après les tables la densité d'une loi du  $\chi_1^2$  donc

$$z_i = \frac{y_i}{\theta} \sim \chi_1^2$$

$U_n = \frac{T_n}{\theta} = \sum_{i=1}^n \frac{y_i}{\theta} = \sum_{i=1}^n z_i$  qui admet la fonction caractéristique

$$\phi_{U_n}(t) = E[e^{itU_n}] = \prod_{k=1}^n E[e^{itz_k}] = \frac{1}{(1-2it)^{n/2}}$$

les variables  $z_i$  sont indépendantes

c'est la fonction caractéristique d'une loi du  $\chi_n^2$  donc

$$U_n \sim \chi_n^2$$

$$3) \alpha = P[\text{rejeter } H_0 \mid H_0 \text{ vraie}] = P\left[\sum_{i=1}^n Y_i > s_\alpha \mid \theta = \theta_0\right]$$

$$= P\left[U_n = \frac{T_n}{\theta_0} > \frac{s_\alpha}{\theta_0} \mid \theta = \theta_0\right]$$

$$\text{donc } 1 - F_n\left(\frac{s_\alpha}{\theta_0}\right) = \alpha$$

$$\text{d'où } s_\alpha = \theta_0 F_n^{-1}(1-\alpha)$$

$$\beta = P[\text{rejeter } H_1 \mid H_1 \text{ vraie}] = P\left[\sum_{i=1}^n Y_i \leq s_\alpha \mid \theta = \theta_1\right]$$

$$= P\left[\frac{1}{\theta_1} \sum_{i=1}^n Y_i \leq \frac{s_\alpha}{\theta_1} \mid \theta = \theta_1\right]$$

$$\beta = F_n\left(\frac{s_\alpha}{\theta_1}\right)$$

④ Les courbes COR représentent  $\pi = 1 - \beta$  en fonction de  $\alpha$ .

Elles sont définies par

$$\pi = 1 - F_n\left(\frac{S\alpha}{\theta_1}\right) = \boxed{1 - F_n\left[\frac{\theta_0}{\theta_1} F_n^{-1}(1-\alpha)\right]}$$

Quand  $\frac{\theta_1}{\theta_0} \nearrow$  ( $\theta_1$  s'éloigne de  $\theta_0$ ),  $\frac{\theta_0}{\theta_1} \searrow$  donc  $F_n\left[\frac{\theta_0}{\theta_1} F_n^{-1}(1-\alpha)\right] \searrow$

donc  $\pi \nearrow$

Le test est donc d'autant plus puissant que  $\frac{\theta_1}{\theta_0}$  est grand, ce qui est naturel

⑤ La statistique du test de Kolmogorov se calcule comme suit

$$\boxed{D_n = \sup_{x \in \mathbb{R}} |\hat{F}(x) - F_0(x)| = \max_{i \in \{1, \dots, n\}} \{E_i^+, E_i^-\}}$$

avec  $E_i^+ = \left| \frac{i}{n} - F_0(x_i^*) \right|$  ou  $E_i^- = \left| \frac{i-1}{n} - F_0(x_i^*) \right|$

où  $F_0$  est la fonction de répartition de loi de densité  $f(y; \theta)$

La région critique du test est  $\boxed{\{(y_1, \dots, y_n) / D_n > S\alpha\}}$

On a d'après le cours

$$P[\sqrt{n} D_n < y] \xrightarrow[n \rightarrow \infty]{} K(y) = \sum_{k=-\infty}^{+\infty} (-1)^k \exp(-2k^2 y)$$

et  $\boxed{S\alpha \approx \frac{1}{\sqrt{n}} K^{-1}(1-\alpha)}$

Quand  $\theta$  est inconnu, on peut l'estimer à l'aide de la méthode du maximum de vraisemblance et tester si  $(y_1, \dots, y_n)$  suit une loi de densité  $f(y; \hat{\theta}_{MV})$  où  $\hat{\theta}_{MV}$  est l'estimateur du maximum de vraisemblance de  $\theta$ .



### Correction exercice 3

1) Des calculs élémentaires donnent

$$\text{Rejet de } H_0 \text{ si } T = \sum_{i=1}^n X_i < S_\alpha$$

2) La fonction caractéristique de  $T$  est

$$E [e^{itT}] = \prod_{j=1}^n E [e^{itX_j}] = \exp [n\lambda (e^{it} - 1)]$$

qui est la fonction caractéristique d'une loi de Poisson de paramètre  $n\lambda$  donc  $T \sim P(n\lambda)$ . Sous  $H_0$ , on a  $T \sim P(n\lambda_0)$  et sous  $H_1$ , on a  $T \sim P(n\lambda_1)$ .

3) a) Pour  $n$  grand, l'approximation normale est  $\sum_{i=1}^n X_i \sim \mathcal{N}(n\lambda, n\lambda)$ .

b) On trouve  $K_\alpha = n\lambda_0 + \sqrt{n\lambda_0}\Phi^{-1}(\alpha)$ .

c) Un calcul simple conduit à

$$\text{PD} = 1 - \beta = \Phi \left( \sqrt{n} \frac{\lambda_0 - \lambda_1}{\sqrt{\lambda_1}} + \sqrt{\frac{\lambda_0}{\lambda_1}} \Phi^{-1}(\alpha) \right)$$

c'est-à-dire asymptotiquement

$$\text{PD} = 1 - \beta \sim \Phi \left( \sqrt{n} \frac{\lambda_0 - \lambda_1}{\sqrt{\lambda_1}} \right)$$

Le paramètre qui règle la performance asymptotique du test est donc  $\sqrt{n} \frac{\lambda_0 - \lambda_1}{\sqrt{\lambda_1}}$ . Dans les deux cas proposés  $\lambda_0 - \lambda_1 = 0.9$  et  $n = 100$ . Le premier test est meilleur car PD est une fonction décroissante de  $\lambda_1$  lorsque  $\lambda_0 - \lambda_1$  et  $n$  sont fixés.

### Correction exercice 4

1) La vraisemblance de ce problème est

$$\begin{aligned} L(y_1, \dots, y_n; \theta) &= \prod_{i=1}^n P[Y_i = y_i] \\ &= \prod_{i=1}^n \theta^{1-y_i} (1-\theta)^{y_i} \\ &= \theta^{n-n\bar{y}} (1-\theta)^{n\bar{y}} \end{aligned}$$

avec

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

On rejette donc  $H_0$  si

$$\frac{L(y_1, \dots, y_n; \theta_1)}{L(y_1, \dots, y_n; \theta_0)} > K_\alpha \iff \bar{y} \ln \left( \frac{\theta_0 (1-\theta_1)}{\theta_1 (1-\theta_0)} \right) > S_\alpha$$

Pour  $\theta_0 = 0.52$  et  $\theta_1 = 0.48$ , on a

$$\frac{\theta_0 (1-\theta_1)}{\theta_1 (1-\theta_0)} = \left( \frac{0.52}{0.48} \right)^2 > 1$$

donc on rejette  $H_0$  si

$$\bar{y} > \nu_\alpha$$

où  $\nu_\alpha$  est un seuil dépendant du risque de première espèce  $\alpha$ . Pour déterminer ce seuil, on se fixe une valeur de  $\alpha$

$$\begin{aligned}\alpha &= P[\text{Rejeter } H_0 | H_0 \text{ vraie}] \\ &= P[\bar{Y} > \nu_\alpha | \theta = \theta_0]\end{aligned}$$

En utilisant le théorème de la limite centrale, on peut approcher la loi de  $\bar{Y}$  comme suit

$$\bar{Y} \sim \mathcal{N}\left(1 - \theta, \frac{\theta(1 - \theta)}{n}\right)$$

Donc

$$\begin{aligned}\alpha &= P\left[U = \frac{\bar{Y} - (1 - \theta_0)}{\sqrt{\frac{\theta_0(1 - \theta_0)}{n}}} > \frac{\nu_\alpha - (1 - \theta_0)}{\sqrt{\frac{\theta_0(1 - \theta_0)}{n}}} \mid U \sim \mathcal{N}(0, 1)\right] \\ &= 1 - F\left(\frac{\nu_\alpha - (1 - \theta_0)}{\sqrt{\frac{\theta_0(1 - \theta_0)}{n}}}\right)\end{aligned}$$

On en déduit

$$\frac{\nu_\alpha - (1 - \theta_0)}{\sqrt{\frac{\theta_0(1 - \theta_0)}{n}}} = F^{-1}(1 - \alpha)$$

où  $F$  est la fonction de répartition d'une loi normale  $\mathcal{N}(0, 1)$ , d'où

$$\nu_\alpha = \sqrt{\frac{\theta_0(1 - \theta_0)}{n}} F^{-1}(1 - \alpha) + (1 - \theta_0)$$

2) La puissance du test est

$$\begin{aligned}\pi &= P[\text{Rejeter } H_0 | H_1 \text{ vraie}] \\ &= P[\bar{Y} > \nu_\alpha | \theta = \theta_1] \\ &= 1 - F\left(\frac{\nu_\alpha - (1 - \theta_1)}{\sqrt{\frac{\theta_1(1 - \theta_1)}{n}}}\right)\end{aligned}$$

### Exercice 5

1) La statistique du test du  $\chi^2$  est

$$\phi = \sum_{k=1}^K \frac{(n_k - np_k)^2}{np_k}$$

avec  $K = 6$  (nombre de classes),  $p_k = \frac{1}{6}$  (probabilité de chaque classe sous  $H_0$ ) et  $n_k$  est le nombre d'éléments de la classe  $k$ . On a donc

$$\phi = \frac{(15 - 10)^2}{10} + \frac{(7 - 10)^2}{10} + \frac{(4 - 10)^2}{10} + \frac{(11 - 10)^2}{10} + \frac{(6 - 10)^2}{10} + \frac{(17 - 10)^2}{10}.$$

On a donc

$$\phi = \frac{25 + 9 + 36 + 1 + 16 + 49}{10} = 13.6.$$

2) La loi de la statistique de test  $\phi$  sous l'hypothèse  $H_0$  est une loi du chi-deux à  $K - 1 = 5$  degrés de liberté.

3) On a

$$\alpha = P[\phi > S_\alpha | \phi \sim \chi_5^2] = 1 - F_{\chi_5^2}(S_\alpha), \text{ soit } S_\alpha = F_{\chi_5^2}^{-1}(1 - \alpha).$$

On a  $\phi > S_{0.05} = 11.07$  donc on rejette l'hypothèse  $H_0$  (le dé n'est pas truqué) avec le risque  $\alpha = 0.05$ . Par contre,  $\phi < S_{0.01} = 15.09$  donc on accepte l'hypothèse  $H_0$  avec le risque  $\alpha = 0.01$ .

### Correction exercice 6

1. La statistique du test du chi-deux noté  $\phi$  est définie par

$$\phi = \sum_{k=1}^2 \frac{(Z_k - np_k)^2}{np_k}$$

avec  $p_1 = p_2 = 0.5$ ,  $n = 30$ ,  $Z_1 = 10$  et  $Z_2 = 20$ . Une application numérique donne

$$\phi = \frac{(10 - 15)^2}{15} + \frac{(20 - 15)^2}{15} = \frac{10}{3}.$$

2. Sous l'hypothèse  $H_0$ ,  $\phi$  suit une loi du  $\chi^2$  à 1 degré de liberté, i.e.,  $\phi \sim \chi_1^2$ .

3. On a

$$\alpha = P[\text{Rejeter } H_0 | H_0 \text{ vraie}] = P[\phi > S_\alpha | \phi \sim \chi_1^2] = 1 - F_{\chi_1^2}(S_\alpha).$$

donc

$$S_\alpha = F_{\chi_1^2}^{-1}(1 - \alpha).$$

Pour  $\alpha = 0.05$ , on trouve  $S_{0.05} = 3.84 > \phi$  donc on accepte  $H_0$  (pas de préférence pour le thé ou le café) avec  $\alpha = 0.05$ .

### Exercice 1 de révision

(corrections sur page perso, examen MFEE année 2022-2023)

On considère un ensemble de variables aléatoires  $(X_1, \dots, X_n)$  indépendantes et de même loi beta  $B(1, \theta)$  de densité

$$f(x_i; \theta) = \begin{cases} \theta(1 - x_i)^{\theta-1} & \text{si } x_i \in ]0, 1[ \\ 0 & \text{sinon} \end{cases}$$

avec  $\theta > 0$ . On désire tester les deux hypothèses

$$H_0 : \theta = \theta_0, \quad H_1 : \theta = \theta_1 > \theta_0.$$

1. À l'aide du théorème de Neyman-Pearson, montrer que la statistique du test le plus puissant est  $T_n = -\sum_{i=1}^n \ln(1 - X_i)$  et indiquer la région critique de ce test.
2. On admet que si  $X_i$  suit une loi de densité  $f(x_i; \theta)$ , alors  $Y_i = -\ln(1 - X_i)$  suit une loi gamma  $\mathcal{G}(1, \theta)$ . En utilisant le théorème central limite, déterminer la loi asymptotique de  $T_n$  sous les deux hypothèses.
3. En utilisant la loi asymptotique de la question précédente, déterminer les risques de première et seconde espèce  $\alpha$  et  $\beta$  du test en fonction des paramètres  $\theta_0$  et  $\theta_1$  et de la fonction de répartition d'une loi normale  $\mathcal{N}(0, 1)$  notée  $F$ .
4. Déterminer les courbes COR associées à ce test montrer qu'elles ne dépendent que de  $n$  et de  $\frac{\theta_1}{\theta_0}$ . Tracer l'allure de ces courbes COR pour différentes valeurs de  $n$  dans une première figure et pour différentes valeurs de  $\frac{\theta_1}{\theta_0}$  dans une seconde figure.
5. On désire vérifier que l'ensemble des observations  $(x_1, \dots, x_n)$  suit une loi beta  $B(1, \theta)$  avec le paramètre  $\theta = \frac{1}{2}$  à l'aide d'un test du  $\chi^2$ . Déterminer la fonction de répartition de cette loi et en déduire que l'intervalle  $]0, 1[$  est la réunion de trois intervalles équiprobables pour la loi  $B(1, \frac{1}{2})$  que l'on précisera. On compte le nombre d'observations  $x_i$  appartenant à ces trois intervalles et on trouve  $K_1 = 13$ ,  $K_2 = 8$  et  $K_3 = 9$ . Quelle est la valeur de la statistique du test du  $\chi^2$ ? Exprimer le seuil de ce test noté  $S_\alpha$  en fonction du risque  $\alpha$  et de l'inverse de la fonction de répartition d'une loi du  $\chi^2$  dont on précisera le nombre de degrés de liberté. On donne  $S_{0.05} = 5.991$ . Qu'en conclut-on ?

### Exercice 2 de révision

(corrections sur page perso, examen MFEE année 2021-2022)

On considère un triplet de variables aléatoires  $(N_1, N_2, N_3)$  de loi multinomiale définie par  $P[N_1 = n_1, N_2 = n_2, N_3 = n_3] = \frac{n!}{n_1!n_2!n_3!} p_1^{n_1} p_2^{n_2} p_3^{n_3}$  avec  $n_1 + n_2 + n_3 = n$  et  $\mathbf{p} = (p_1, p_2, p_3) = (\theta, \theta, 1 - 2\theta)$ . On admettra que pour un tel modèle statistique, la loi marginale de  $N_i$  est une loi binomiale  $B(n, p_i)$  de moyenne  $E[N_i] = np_i$  et de variance  $\text{var}(N_i) = np_i(1 - p_i)$ . On veut à l'aide de l'observation de  $(N_1, N_2, N_3)$  tester les deux hypothèses suivantes

$$H_0 : \theta = \theta_0 \text{ contre } H_1 : \theta = \theta_1 \quad \text{avec } \theta_1 > \theta_0.$$

1. À l'aide du théorème de Neyman-Pearson, montrer que la statistique du test le plus puissant est  $T_n = N_3$  (on n'oubliera pas que  $N_1 + N_2 + N_3 = n$ ) et indiquer la région critique de ce test.
2. En utilisant le théorème central limite, déterminer la loi asymptotique de  $T_n$  sous les deux hypothèses.
3. En utilisant la loi asymptotique de la question précédente, déterminer les risques de première et seconde espèce  $\alpha$  et  $\beta$  du test en fonction des paramètres  $\theta_0$  et  $\theta_1$  et de la fonction de répartition d'une loi normale  $\mathcal{N}(0, 1)$  notée  $F$ .
4. Déterminer les courbes COR associées à ce test et tracer l'allure de ces courbes pour différentes valeurs de  $n$ .

5. On désire à partir d'un ensemble de  $K = 10$  observations de  $N_1$  notées  $(n_{11}, \dots, n_{1K})$  et données dans le tableau ci-dessous déterminer s'il est raisonnable de supposer que  $N_1$  suit une loi binomiale  $B(K, \theta)$ .

2	3	3	2	2	0	4	3	1	0
---	---	---	---	---	---	---	---	---	---

- Expliquer pourquoi on est amené à choisir  $\theta = 0.2$  pour effectuer ce test.
- Les probabilités associées à une loi binomiale  $B(K, \theta)$  avec  $\theta = 0.2$  et  $K = 10$  sont données dans le tableau ci-dessous

$p_0$	$p_1$	$p_2$	$p_3$	$p_4$	$\sum_{k=5}^{10} p_k$
0.11	0.27	0.30	0.20	0.09	0.03

On décide de faire un test du  $\chi^2$  avec 3 classes notées  $C_1, C_2$  et  $C_3$ . Justifier le choix suivant pour ces trois classes :  $C_1 = \{0, 1\}$ ,  $C_2 = \{2\}$  et  $C_3 = \{3, \dots, 10\}$ .

- Exprimer la statistique de ce test notée  $\phi$  en fonction des données du problème (sans chercher à la calculer) et préciser la région critique.
- Quelle est la loi asymptotique de  $\phi$  ?
- Les seuils obtenus pour  $\alpha = 0.05$  et  $\alpha = 0.01$  sont  $S_{0.05} = 5.99$  et  $S_{0.01} = 9.21$ . Expliquer pourquoi  $S_{0.05} < S_{0.01}$ .