

TP 7 - TEST DE NEYMAN PEARSON. RAPPORT DE VRAISEMBLANCE MONOTONE.

Exercice 1

On considère un échantillon (X_1, \dots, X_n) de loi $\mathcal{N}(\theta, \sigma^2)$. On souhaite tester l'hypothèse $H_0 : \theta = \theta_0$ contre l'alternative $H_1 : \theta = \theta_1$ avec $\theta_0 < \theta_1$

1. Montrer que le test de rapport de vraisemblance est fondé sur la statistique $S = X_1 + \dots + X_n$.
2. Sachant que si Y suit une loi $\mathcal{N}(0, 1)$, alors $\mathbb{P}(Y > 1.64) = 0.05$, expliciter la région de rejet du test de niveau 5% dans notre cas.
3. Proposer une estimation par minoration de la puissance de ce test.
4. Que suggérez-vous pour augmenter la puissance du test ?
5. On désire cette fois tester l'hypothèse $\mathcal{H}_0 : \theta \leq 0$ contre l'hypothèse $\mathcal{H}_1 : \theta \geq 0$. Montrer que le modèle est une famille à rapport de vraisemblances monotones.
6. Donner le test de puissance maximale de niveau α donné.
7. Un radar actif de surveillance aérienne a des caractéristiques telles qu'une éventuelle cible réfléchit 20 impulsions lors d'un balayage. À l'aide d'un traitement adapté, ces N impulsions réfléchies en cas de présence de la cible fournissent un vecteur d'observations (z_i) avec

$$\mathcal{H}_1 : z_i = A + b_i \quad \text{en présence de cible}$$

$$\mathcal{H}_0 : z_i = b_i \quad \text{en l'absence de cible}$$

où les b_i sont des variables aléatoires gaussiennes $\mathcal{N}(0, \sigma^2)$ indépendantes modélisant les divers bruit.

- (a) Donner le test de Neyman Pearson de niveau α de \mathcal{H}_0 contre \mathcal{H}_1 . Application numérique $A = 1, \sigma = 0.6$ et $\alpha = 10^{-6}$.
 - (b) Écrire un code matlab simulant n échantillons, chacun de taille N sous l'hypothèse nulle. Appliquer pour chacun des échantillons le test de N-P et calculer la fréquence empirique des fausses détections.
 - (c) Faire la même chose sous l'hypothèse \mathcal{H}_1 et calculer la fréquence empirique des cibles non détectées.
8. Une antenne de communication cherche à détecter l'émission d'un signal. À cause des perturbations atmosphériques, même en l'absence de signal, l'antenne perçoit du « bruit ». On procède à n mesures et on modélise le bruit par des v.a.i.i.d. de loi gaussienne $\mathcal{N}(0, \sigma^2)$ et le signal par des v.a.i.i.d. $\mathcal{N}(0, \xi^2)$, signal et bruit étant considérés indépendants. On veut tester l'hypothèse \mathcal{H}_0 « pas de signal » contre l'alternative « signal ».
 - (a) Formaliser le problème de test dans notre situation.
 - (b) Déterminer la statistique de test du rapport de vraisemblance. En déduire que le test est fondé sur une statistique de loi du χ^2 .
 - (c) Comment déterminer la région de rejet pour obtenir un test de niveau α donné et calculer sa puissance.

Exercice 2

Soient X et Y deux variables aléatoires. On veut tester l'hypothèse \mathcal{H}_0 : « X et Y ont même loi » contre \mathcal{H}_1 : « X et Y n'ont pas même loi ». On dispose pour cela d'un échantillon (X_1, \dots, X_m) de loi celle de X et d'un échantillon (Y_1, \dots, Y_n) de loi celle de Y .

Toutes ces $m+n$ variables aléatoires étant indépendantes. On range par ordre croissant les $m+n$ valeurs effectivement observées et après effacement des indices on obtient un « mot » de la forme $XXYXYYYXYXX$. On compte alors le nombre R de blocs de lettres identiques (les longueurs ou « runs » ou composantes connexes) dans ce mot, (sur cet exemple, $R = 7$ soit 4 longueurs de X et 3 de Y).

L'idée intuitive de ce test est que c'est sous \mathcal{H}_0 que le mélange entre les valeurs de X et celles de Y sera le plus intense et donc le nombre de longueur le plus élevé.

1. Sous \mathcal{H}_0 , calculer la loi de R par les formules suivantes où l'on suppose $m \leq n$:

$$P(R = 2k) \quad 1 \leq k \leq m$$

$$P(R = 2k + 1) \quad 1 \leq k < m$$

$$P(R = 2m + 1)$$

2. Lorsque m et n sont grands, quelle est la distribution (sous \mathcal{H}_0) asymptotiquement obtenue pour R (répondre grâce à Matlab)? On admettra que

$$\mathbb{E}[R] = 1 + \frac{2mn}{m+n} \quad \text{Var}(R) = \frac{2mn(2mn - m - n)}{(m+n)^2(m+n-1)}$$

3. Définir un test de niveau ϵ de rejet de \mathcal{H}_0 à partir de R .
4. Écrire une fonction Matlab qui calcule R pour les échantillons X et Y .
5. Écrire une fonction Matlab qui réalise le test des longueurs au niveau asymptotique α pour m et n grands.
6. Écrire une fonction Matlab qui calcule la fonction de répartition de R . La comparer avec la fonction de répartition de la loi gaussienne correspondant à l'approximation utilisée ci-dessus.

On verra dans les tps suivants d'autres tests asymptotiques ou non donnant des règles d'acceptation ou de rejet d'hypothèse d'adéquation à la même loi pour deux populations.