

**Examen Estimation - Détection**  
 Mercredi 19 Novembre 2008, 8h00-10h00

**1<sup>ère</sup> Partie**

1) La vraisemblance s'écrit

$$L(x_1, \dots, x_n; \lambda) = \prod_{i=1}^n \frac{\lambda^{x_i}}{x_i!} e^{-\lambda}$$

et donc son logarithme est

$$\ln [L(x_1, \dots, x_n; \lambda)] = \left( \sum_{i=1}^n x_i \right) \ln \lambda - n\lambda - \sum_{i=1}^n \ln [x_i!]$$

La dérivée de la log-vraisemblance possède donc l'expression suivante

$$\frac{\partial \ln [L(x_1, \dots, x_n; \lambda)]}{\partial \lambda} = \frac{1}{\lambda} \sum_{i=1}^n x_i - n$$

d'où

$$\frac{\partial \ln [L(x_1, \dots, x_n; \lambda)]}{\partial \lambda} = 0 \iff \lambda = \frac{1}{n} \sum_{i=1}^n x_i$$

On vérifie aisément que cette valeur de  $\lambda$  correspond au maximum global unique de la log-vraisemblance, d'où

$$\hat{\lambda}_{MV} = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

Cet estimateur est sans biais et de variance

$$\text{Var} [\hat{\lambda}_{MV}] = \frac{\text{Var} [X_1]}{n} = \frac{\lambda}{n}$$

L'estimateur  $\hat{\lambda}_{MV}$  est donc convergent.

2) Des calculs élémentaires permettent d'obtenir

$$\begin{aligned} \text{BCR}(\lambda) &= -E \left[ \frac{\partial^2 \ln [L(x_1, \dots, x_n; \lambda)]}{\partial \lambda^2} \right]^{-1} \\ &= \frac{-1}{E \left[ \frac{-1}{\lambda^2} \sum_{i=1}^n X_i \right]} = \frac{\lambda^2}{n\lambda} = \frac{\lambda}{n} \end{aligned}$$

L'estimateur  $\hat{\lambda}_{MV}$  est donc sans biais et de variance égale à la borne de Cramer-Rao associée à un estimateur non-biaisé de  $\lambda$ . L'estimateur  $\hat{\lambda}_{MV}$  est donc l'estimateur efficace de  $\lambda$ .

3a) La matrice d'information de Fisher a été déterminée à la question précédente

$$E \left[ \frac{1}{\lambda^2} \sum_{i=1}^n X_i \right] = \frac{n}{\lambda}$$

La matrice d'information a priori est définie par

$$E \left[ -\frac{\partial^2 \ln [g(\lambda)]}{\partial \lambda^2} \right]$$

Mais

$$\ln [g(\lambda)] = C + (\alpha - 1) \ln \lambda - \beta \lambda$$

d'où

$$\frac{\partial^2 \ln [g(\lambda)]}{\partial \lambda^2} = \frac{1 - \alpha}{\lambda^2}$$

On en déduit

$$E \left[ -\frac{\partial^2 \ln [g(\lambda)]}{\partial \lambda^2} \right] = (\alpha - 1) E \left[ \frac{1}{\lambda^2} \right]$$

Le calcul de  $E[\lambda^{-2}]$  est élémentaire

$$\begin{aligned} E \left[ \frac{1}{\lambda^2} \right] &= \int_0^\infty \frac{\beta^\alpha}{\Gamma(\alpha)} \lambda^{\alpha-3} e^{-\lambda\beta} d\lambda \\ &= \frac{\beta^\alpha}{\Gamma(\alpha)} \int_0^\infty \left( \frac{u}{\beta} \right)^{\alpha-3} e^{-u} \frac{du}{\beta} \\ &= \frac{\beta^2}{\Gamma(\alpha)} \int_0^\infty u^{\alpha-3} e^{-u} du \\ &= \beta^2 \frac{\Gamma(\alpha - 2)}{\Gamma(\alpha)} \\ &= \frac{\beta^2}{(\alpha - 1)(\alpha - 2)} \end{aligned}$$

d'où

$$E \left[ -\frac{\partial^2 \ln [g(\lambda)]}{\partial \lambda^2} \right] = \frac{\beta^2}{(\alpha - 2)}$$

La borne de Cramer-Rao a posteriori s'écrit donc

$$\begin{aligned} \text{BCR}_{\text{post}}(\lambda) &= \left[ E \left[ -\frac{\partial^2 \ln [f(x_1, \dots, x_n | \lambda)]}{\partial \lambda^2} \right] + E \left[ -\frac{\partial^2 \ln [g(\lambda)]}{\partial \lambda^2} \right] \right]^{-1} \\ &= \left[ \frac{n}{\lambda} + \frac{\beta^2}{(\alpha - 2)} \right]^{-1} \\ &= \frac{\lambda(\alpha - 2)}{n(\alpha - 2) + \lambda\beta^2} \\ &= \frac{\lambda}{n} \frac{1}{1 + \frac{\lambda\beta^2}{n(\alpha - 2)}} \end{aligned}$$

On vérifie que

$$\frac{n}{\lambda} + \frac{\beta^2}{(\alpha - 2)} \geq \frac{n}{\lambda}$$

et donc

$$\text{BCR}_{\text{post}}(\lambda) = \left[ \frac{n}{\lambda} + \frac{\beta^2}{(\alpha - 2)} \right]^{-1} \leq \frac{\lambda}{n} = \text{BCR}(\lambda)$$

3b) L'estimateur du maximum a posteriori du paramètre  $\lambda$  noté  $\hat{\lambda}_{\text{MAP}}$  s'obtient en maximisant le logarithme de la densité a posteriori, c'est-à-dire de la façon suivante

$$\frac{\partial \ln [f(\lambda | x_1, \dots, x_n)]}{\partial \lambda} = 0 \iff \lambda = \frac{n\bar{x} + \alpha - 1}{n + \beta} = \frac{\bar{x} + \frac{\alpha-1}{n}}{1 + \frac{\beta}{n}}$$

L'estimateur du maximum a posteriori du paramètre  $\lambda$  est donc

$$\hat{\lambda}_{\text{MAP}} = \frac{\bar{X} + \frac{\alpha-1}{n}}{1 + \frac{\beta}{n}} = \frac{\hat{\lambda}_{\text{MV}} + \frac{\alpha-1}{n}}{1 + \frac{\beta}{n}}$$

Pour  $n$  grand, l'information a priori influe peu sur l'estimation et donc l'estimateur du maximum a posteriori se réduit à l'estimateur du maximum de vraisemblance  $\hat{\lambda}_{\text{MAP}} \simeq \hat{\lambda}_{\text{MV}}$ .

3c) L'estimateur  $\hat{\lambda}$  qui minimise l'erreur quadratique moyenne  $E \left[ (\lambda - \hat{\lambda})^2 \right]$  est l'estimateur MMSE défini par

$$\hat{\lambda}_{\text{MMSE}} = E[\lambda | X_1, \dots, X_n]$$

La loi a posteriori de  $\lambda | X_1, \dots, X_n$  est telle que

$$f(\lambda | x_1, \dots, x_n) \propto \lambda^{n\bar{x} + \alpha - 1} e^{-\lambda(n + \beta)}$$

C'est donc une loi gamma de paramètres  $n\bar{x} + \alpha$  et  $n + \beta$ , i.e.

$$\lambda | X_1, \dots, X_n \sim \Gamma(n\bar{x} + \alpha, n + \beta)$$

On en déduit

$$E[\lambda | X_1, \dots, X_n] = \frac{n\bar{X} + \alpha}{n + \beta} = \frac{\bar{X} + \frac{\alpha}{n}}{1 + \frac{\beta}{n}}$$

## 2<sup>ème</sup> Partie

1) Le test de Neyman-Pearson pour le problème

$$\begin{cases} H_0 : \lambda = \lambda_0 \\ H_1 : \lambda = \lambda_1 \end{cases}$$

s'écrit

$$\text{Rejet de } H_0 \text{ si } \frac{L(x_1, \dots, x_n; \lambda_1)}{L(x_1, \dots, x_n; \lambda_0)} > S_\alpha$$

c'est-à-dire qu'on rejette  $H_0$  si

$$\ln [L(x_1, \dots, x_n; \lambda_1)] - \ln [L(x_1, \dots, x_n; \lambda_0)] > \ln [S_\alpha]$$

ou

$$\left( \sum_{i=1}^n x_i \right) (\ln \lambda_1 - \ln \lambda_0) - n(\lambda_1 - \lambda_0) > \ln [S_\alpha]$$

d'où le test suivant

- Si  $\lambda_1 > \lambda_0$

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

- Si  $\lambda_1 < \lambda_0$

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

2) La fonction caractéristique de  $T$  est

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

qui est la fonction caractéristique d'une loi de Poisson de paramètre  $n\lambda$  donc  $T \sim P(n\lambda)$ . On en déduit donc

$$\text{Sous } H_0 : T \sim P(n\lambda_0)$$

$$\text{Sous } H_1 : T \sim P(n\lambda_1)$$

3) On a

$$\begin{aligned} \alpha &= P[\text{rejeter } H_0 | H_0 \text{ vraie}] \\ &= P[T < K_\alpha | T \sim P(n\lambda_0)] \\ &= F_{n\lambda_0}(K_\alpha) \end{aligned}$$

où  $F_{n\lambda_0}(\cdot)$  est la fonction de répartition de la loi de Poisson de paramètre  $n\lambda_0$ . On a donc

$$K_\alpha = F_{n\lambda_0}^{-1}(\alpha)$$

4a) Le théorème de la limite centrale s'écrit

$$\frac{\sum_{i=1}^n X_i - n\lambda}{\sqrt{n\lambda}} \sim \mathcal{N}(0, 1) \quad \text{ou } T \underset{\text{pour } n \text{ grand}}{\sim} \mathcal{N}(n\lambda, n\lambda)$$

4b) En utilisant la loi normale pour  $T$ , on a

$$\begin{aligned} \alpha &= P[\text{rejeter } H_0 | H_0 \text{ vraie}] \\ &= P[T < K_\alpha | T \sim \mathcal{N}(n\lambda_0, n\lambda_0)] \\ &= P \left[ U = \frac{T - n\lambda_0}{\sqrt{n\lambda_0}} < \frac{K_\alpha - n\lambda_0}{\sqrt{n\lambda_0}} \mid U \sim \mathcal{N}(0, 1) \right] \\ &= F \left( \frac{K_\alpha - n\lambda_0}{\sqrt{n\lambda_0}} \right) \end{aligned}$$

d'où

$$K_\alpha = \sqrt{n\lambda_0} F^{-1}(\alpha) + n\lambda_0$$

De la même façon, la puissance du test (ou puissance du test) s'écrit

$$\begin{aligned} PD &= P[\text{rejeter } H_0 | H_1 \text{ vraie}] \\ &= P[T < K_\alpha | T \sim \mathcal{N}(n\lambda_1, n\lambda_1)] \\ &= F\left(\frac{K_\alpha - n\lambda_1}{\sqrt{n\lambda_1}}\right) \end{aligned}$$

Les courbes COR expriment  $PD$  en fonction de  $\alpha$  et s'écrivent donc

$$\begin{aligned} PD &= F\left[\frac{\sqrt{n\lambda_0}F^{-1}(\alpha) + n\lambda_0 - n\lambda_1}{\sqrt{n\lambda_1}}\right] \\ &= F\left[\sqrt{\frac{\lambda_0}{\lambda_1}}F^{-1}(\alpha) + \sqrt{n}\frac{\lambda_0 - \lambda_1}{\sqrt{\lambda_1}}\right] \end{aligned}$$

Les paramètres qui influent sur la performance asymptotique ( $n \rightarrow \infty$ ) du test sont donc  $n$ ,  $\lambda_0$  et  $\lambda_1$ . On en déduit

$$\begin{aligned} \text{Premier Cas} &: n = 100, \lambda_0 = 1, \lambda_1 = 0.1 \\ PD &= F\left[\sqrt{10}F^{-1}(\alpha) + 9\sqrt{10}\right] \\ \text{Deuxième Cas} &: n = 100, \lambda_0 = 10, \lambda_1 = 1 \\ PD &= F\left[\sqrt{10}F^{-1}(\alpha) + 90\right] \end{aligned}$$

Comme  $F$  est une fonction croissante, on aura une meilleure performance dans le second cas.

5) On suppose désormais que les connaissances sur le paramètre  $\lambda$  sous les deux hypothèses  $H_0$  et  $H_1$  sont contenues dans la loi a priori  $\lambda \sim \Gamma(\alpha, \beta)$  avec

$$\begin{cases} H_0 : \alpha = \alpha_0, \beta = 1 \\ H_1 : \alpha = \alpha_1, \beta = 1 \end{cases}$$

La vraisemblance s'écrit alors

$$\begin{aligned} f(x_1, \dots, x_n) &= \int f(x_1, \dots, x_n, \lambda) d\lambda \\ &= \int f(x_1, \dots, x_n | \lambda) g(\lambda) d\lambda \\ &= \frac{\beta^\alpha}{\Gamma(\alpha)} \left(\prod_{i=1}^n x_i!\right)^{-1} \int_0^\infty \lambda^{n\bar{x} + \alpha - 1} e^{-\lambda(n+\beta)} d\lambda \end{aligned}$$

En posant  $u = \lambda(n + \beta)$ , on obtient

$$\begin{aligned} f(x_1, \dots, x_n) &= \frac{\beta^\alpha}{\Gamma(\alpha)} \left(\prod_{i=1}^n x_i!\right)^{-1} \frac{1}{(n + \beta)^{n\bar{x} + \alpha - 1}} \int_0^\infty u^{n\bar{x} + \alpha - 1} e^{-u} \frac{du}{n + \beta} \\ &= \frac{\beta^\alpha}{\Gamma(\alpha)} \left(\prod_{i=1}^n x_i!\right)^{-1} \frac{1}{(n + \beta)^{n\bar{x} + \alpha}} \int_0^\infty u^{n\bar{x} + \alpha - 1} e^{-u} du \\ &= \frac{\beta^\alpha}{\Gamma(\alpha)} \left(\prod_{i=1}^n x_i!\right)^{-1} \frac{\Gamma(n\bar{x} + \alpha)}{(n + \beta)^{n\bar{x} + \alpha}} \end{aligned}$$

Le test de Bayes associé à ce problème s'écrit

$$\text{Rejet de } H_0 \text{ si } \frac{f(x_1, \dots, x_n | H_1)}{f(x_1, \dots, x_n | H_0)} > S_\alpha$$

c'est-à-dire

$$\text{Rejet de } H_0 \text{ si } \frac{\Gamma(n\bar{x} + \alpha_1) (n+1)^{\alpha_0} \Gamma(\alpha_0)}{\Gamma(n\bar{x} + \alpha_0) (n+1)^{\alpha_1} \Gamma(\alpha_1)} > S_\alpha$$

Finalement, on rejette  $H_0$  si

$$\frac{\Gamma(n\bar{x} + \alpha_1)}{\Gamma(n\bar{x} + \alpha_0)} > K_\alpha$$

### 3<sup>ème</sup> Partie

1) Le paramètre  $\lambda$  étant inconnu, on l'estime à l'aide de la méthode du maximum de vraisemblance et on obtient

$$\hat{\lambda}_{MV} = \bar{X}$$

On construit des classes comme par exemple

- Classe 1 :  $X_i \in \{0, 1, 2\}$  de probabilité  $p_1$
- Classe 2 :  $X_i \in \{3, 4, 5\}$  de probabilité  $p_2$
- Classe 3 :  $X_i \geq 6$  de probabilité  $p_3$

On calcule les effectifs des trois classes, notés  $n_1, n_2$  et  $n_3$  calculés à l'aide des données. On en déduit la statistique du test

$$\phi = \sum_{i=1}^3 \frac{1}{np_i} (n_i - np_i)^2$$

On a estimé un paramètre donc la loi asymptotique de  $\phi$  est une loi du  $\chi_1^2$ . On se fixe  $\alpha$  (par exemple  $\alpha = 0.05$ ) qui vérifie la relation suivante

$$\begin{aligned} \alpha &= P[\text{rejeter } H_0 | H_0 \text{ vraie}] \\ &= P[\phi > K_\alpha | \phi \sim \chi_1^2] \\ &= 1 - G_1(K_\alpha), \end{aligned}$$

où  $G_1$  est la fonction de répartition d'une loi du  $\chi_1^2$ . On en déduit le seuil  $K_\alpha$  comme suit

$$K_\alpha = G_1^{-1}(1 - \alpha)$$

On accepte l'hypothèse  $H_0$  si  $\phi < K_\alpha$  et on rejette  $H_0$  dans le cas contraire

2) Ce test a un fonctionnement très similaire au test du  $\chi^2$  puisque

$$\begin{aligned} \alpha &= P[\text{rejeter } H_0 | H_0 \text{ vraie}] \\ &= P\left[U = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\bar{X}} > S_\alpha \mid U \sim \chi_{n-1}^2\right] \\ &= 1 - G_{n-1}(S_\alpha), \end{aligned}$$

où  $G_{n-1}$  est la fonction de répartition d'une loi du  $\chi_{n-1}^2$ . On a donc

$$S_\alpha = G_{n-1}^{-1}(1 - \alpha)$$

On accepte l'hypothèse  $H_0$  si  $U < S_\alpha$  et on rejette  $H_0$  dans le cas contraire.