

Une Procédure asymptotique de détection de rupture pour des observations à incréments indépendants.

D.GHORBANZADEH

<http://www.cnam.fr/maths/Membres/ghorbanzadeh/>

CNAM

17 juin 2008

Introduction

Modèle statistique

- Modèle de détection

- Comportements des observations sous l'hypothèse H_0

- Statistique du test pénalisée aux bords

- Comportements des observations sous l'hypothèse H_0

- Construction du test

Applications

- cas HSU (haemolytic uraemic syndrome)

- cas SIDA

Introduction

Modèle statistique

Modèle de détection

Comportements des observations sous l'hypothèse H_0

Statistique du test pénalisée aux bords

Comportements des observations sous l'hypothèse H_0

Construction du test

Applications

cas HSU (haemolytic uraemic syndrome)

cas SIDA

On considère une suite de variables aléatoires X_1, \dots, X_n avec des incréments indépendants qui sont susceptibles de changer de loi après les k premières observations.

On considère une suite de variables aléatoires X_1, \dots, X_n avec des incréments indépendants qui sont susceptibles de changer de loi après les k premières observations.

avant la rupture

les incréments $X_1, \dots, X_k - X_{k-1}$ sont indépendants et suivent une loi de Poisson $\mathcal{P}(\lambda)$

On considère une suite de variables aléatoires X_1, \dots, X_n avec des incréments indépendants qui sont susceptibles de changer de loi après les k premières observations.

avant la rupture

les incréments $X_1, \dots, X_k - X_{k-1}$ sont indépendants et suivent une loi de Poisson $\mathcal{P}(\lambda)$

après la rupture

les incréments $X_{k+1} - X_k, \dots, X_n - X_{n-1}$ sont indépendants et suivent une loi de Poisson $\mathcal{P}(\lambda + \frac{\delta}{\sqrt{n}})$

On propose le problème de test suivant :

$$\begin{cases} \mathbf{H}_0 : & \delta = 0 \\ \mathbf{H}_1 : & \delta \neq 0 \end{cases}$$

Pour tester l'existence le point de rupture, on propose la statistique du test :

statistique du test

$$R_n(k) = \sqrt{n} \left(\frac{X_n - X_k}{n - k} - \frac{X_k}{k} \right) \quad (1)$$

◀ $R_n(k)$

sous l'hypothèse H_0

$$X_i \sim \mathcal{P}(i \lambda)$$

$$\text{Cov}(X_i, X_j) = \min(i, j) \lambda$$

sous l'hypothèse H_0

$$X_i \sim \mathcal{P}(i \lambda)$$

$$\text{Cov}(X_i, X_j) = \min(i, j) \lambda$$

comportement de la statistique du test sous H_0

$$\mathbb{E}[R_n(k)] = 0$$

$$\forall k_1 \leq k_2 \quad \text{Cov}(R_n(k_1), R_n(k_2)) = \frac{\lambda}{\frac{k_2}{n} \left(1 - \frac{k_1}{n}\right)} \quad \triangleright R_n(k)$$

$$\text{Var}[R_n(k)] = \frac{\lambda}{\frac{k}{n} \left(1 - \frac{k}{n}\right)}$$

Soit φ une fonction continue par morceaux sur $[0, 1]$ satisfaisant :

$$\int_0^1 \left(\frac{\varphi(t)}{\sqrt{t}} \right)^2 dt < \infty$$

statistique du test pénalisée

$$R_{n,\varphi}^*(k) = \varphi\left(\frac{k}{n}\right) \varphi\left(1 - \frac{k}{n}\right) R_n(k) \quad (2)$$

◀ statistique pénalisée

$$\forall k_1 \leq k_2$$

$$\text{Cov}(R_{n,\varphi}^*(k_1), R_{n,\varphi}^*(k_2)) = \frac{\varphi\left(\frac{k_1}{n}\right) \varphi\left(1 - \frac{k_1}{n}\right) \varphi\left(\frac{k_2}{n}\right) \varphi\left(1 - \frac{k_2}{n}\right)}{\frac{k_2}{n} \left(1 - \frac{k_1}{n}\right)} \lambda \quad (3)$$

$$\text{Var}(R_{n,\varphi}^*(k)) = \left(\frac{\varphi\left(\frac{k}{n}\right) \varphi\left(1 - \frac{k}{n}\right)}{\sqrt{\frac{k}{n} \left(1 - \frac{k}{n}\right)}} \right)^2 \lambda$$

Si l'on prend $\varphi(t) = t$, l'équation (2) devient :

statistique pénalisée pour la fonction $\varphi(t) = t$

$$\mathbb{K}_n(k) = n^{-3/2}(k X_n - n X_k) \quad (4)$$

▶ équation (2)

Si l'on prend $\varphi(t) = t$, l'équation (2) devient :

statistique pénalisée pour la fonction $\varphi(t) = t$

$$\mathbb{K}_n(k) = n^{-3/2}(k X_n - n X_k) \quad (4)$$

▶ équation (2)

Définition

Pour tout estimateur consistant $\hat{\lambda}_n$ de λ , soit $\mathbb{K}_n^*(k) = \frac{1}{\sqrt{\hat{\lambda}_n}} \mathbb{K}_n(k)$.

On définit $\{\mathbb{K}_n^*(t); t \in [0, 1]\}$ comme le processus interpolé linéaire du processus $\{\mathbb{K}_n^*(k); 1 < k < n\}$.

Théorème

sous l'hypothèse \mathbf{H}_0 , $\mathbb{K}_n^*(t)$ converge au sens de la convergence en loi des marginales de dimension finie vers le pont Brownien $B(t) = W(t) - tW(1)$ où $\{W(t); t \in [0, 1]\}$ représente le mouvement Brownien.

Preuve

Par l'équation (3) on a :

$$\forall t_1 \leq t_2 \quad \text{cov}(\mathbb{K}_n(t_1), \mathbb{K}_n(t_2)) = \frac{[nt_1]}{n} \left(1 - \frac{[nt_2]}{n}\right) \lambda \quad (5)$$

Or,

$$\lim_{n \rightarrow \infty} \text{Cov}(\mathbb{K}_n^*(t_1), \mathbb{K}_n^*(t_2)) = t_1 (1 - t_2)$$

D'autre part, on a : $t_1 \leq t_2$, $\text{Cov}(B(t_1), B(t_2)) = t_1 (1 - t_2)$

Proposition

Sous \mathbf{H}_0 , pour tout $\eta > 0$, on a :

$$\lim_{n \rightarrow \infty} \mathbb{P}_{H_0} \left(\sup_{t \in [0,1]} |\mathbb{K}_n^*(t)| \geq \eta \right) = \mathbb{P} \left(\sup_{t \in [0,1]} |B(t)| \geq \eta \right) \quad (6)$$

Proposition

Sous \mathbf{H}_0 , pour tout $\eta > 0$, on a :

$$\lim_{n \rightarrow \infty} \mathbb{P}_{H_0} \left(\sup_{t \in [0,1]} |\mathbb{K}_n^*(t)| \geq \eta \right) = \mathbb{P} \left(\sup_{t \in [0,1]} |B(t)| \geq \eta \right) \quad (6)$$

Conséquence

Soit $\hat{\tau}_n = \text{Arg sup}_{t \in [0,1]} |\mathbb{K}_n^*(t)|$ et $\tau = \text{Arg sup}_{t \in [0,1]} |B(t)|$. Alors,

$$\hat{\tau}_n \xrightarrow[n \rightarrow \infty]{P} \tau \quad (7)$$

sous l'hypothèse H_1

$$\mathbb{E}[X_i] = \begin{cases} i\lambda & \text{si } 1 \leq i \leq k \\ k\lambda + (i - k)\left(\lambda + \frac{\delta}{\sqrt{n}}\right) & \text{si } k + 1 \leq i \leq n \end{cases}$$

pour tout k_1 et k_2 ,

$$\text{Cov}(X_{k_1}, X_{k_2}) = \begin{cases} k\lambda + (\min(k_1, k_2) - k)\left(\lambda + \frac{\delta}{\sqrt{n}}\right) & \text{si } \min(k_1, k_2) \geq k \\ \min(k_1, k_2)\lambda & \text{sinon} \end{cases}$$

Théorème

sous l'hypothèse \mathbf{H}_1 , \mathbb{K}_n^* converge au sens de la convergence en loi des marginales de dimension finie vers le processus process B_τ^* défini :

$$B_\tau^*(t) = (t \wedge \tau)(1 - t \vee \tau) \frac{\delta}{\sqrt{\lambda}} + B(t) \quad (8)$$

où $t \wedge \tau = \inf\{t, \tau\}$ et $t \vee \tau = \sup\{t, \tau\}$

Nous prenons comme région de rejet : où pour α donné dans $[0, 1]$, le seuil η_α est déterminé par :

$$P\left(\sup_{t \in [0,1]} |B(t)| \geq \eta_\alpha\right) = 2 \sum_{j=1}^{\infty} (-1)^{j+1} e^{-2j^2 \eta_\alpha^2} \quad (9)$$

Kolmogorov

On note que le test étudié a le même niveau asymptotique que le test classique de **Kolmogorov**

puissance du test

$$p(\tau) = P\left(\sup_{t \in [0,1]} |B_{\tau}^*(t)| \geq \eta_{\alpha}\right) \quad (10)$$

Introduction

Modèle statistique

Modèle de détection

Comportements des observations sous l'hypothèse H_0

Statistique du test pénalisée aux bords

Comportements des observations sous l'hypothèse H_0

Construction du test

Applications

cas HSU (haemolytic uraemic syndrome)


cas SIDA

HSU (haemolytic uraemic syndrome)

Les données représentent le nombre de 'HUS' à Birmingham et Newcastle de 1970 à 1989.

référence

R. W. West & R. T. Ogden. (1997). Continuous-time estimation of a change-point in a Poisson process. *Journ. Statist. Comput. Simul.* 56, pp 293-302.




graphe de $|K_n^*(k)|$ pour les données de Birmingham .

$$\hat{\lambda}_n = \frac{x_n}{n} = 5.65$$

le maximum est atteint au point : $k = 11$, ce qui correspond à la valeur de statistique : $|\mathbb{K}_n^*(11)| = 4.15$.

Pour $\alpha = 5\%$, la valeur critique $\eta_\alpha = 1.36$, on rejette donc l'hypothèse reject H_0 .

$\delta = |\mathbb{K}_n(11)| = 9.87$, ce qui donne une puissance égale à 41%.



graphe de $|K_n^*(k)|$ pour les données de Newcastle .

$$\hat{\lambda}_n = \frac{x_n}{n} = 5.$$

le maximum est atteint au point : $k = 15$, ce qui correspond à la valeur de statistique : $|\mathbb{K}_n^*(11)| = 1.6994$.

Pour $\alpha = 5\%$, la valeur critique $\eta_\alpha = 1.36$, on rejette donc l'hypothèse reject H_0 .


$\delta = |\mathbb{K}_n(15)| = 8.50$, ce qui donne une puissance égale à 21%.

Les données représentent le nombre de 'SIDA' au Cuba de 1986 à 1992.

référence

The HIV-AIDS Epidemic in Cuba. Internal Report. Departamento de Epidemiologia, Sanatorio Santiago de Las Vegas. Cuba 1999.

SIDA (cuba)



graphe de $|K_n^*(k)|$ pour les données SIDA au Cuba .

$$\hat{\lambda}_n = \frac{x_n}{n} = 32.15$$

le maximum est atteint au point : $k = 12$, ce qui correspond à la valeur de statistique : $|\mathbb{K}_n^*(11)| = 9.61$.

Pour $\alpha = 5\%$, la valeur critique $\eta_\alpha = 1.36$, on rejette donc l'hypothèse H_0 .

$\delta = |\mathbb{K}_n(15)| = 54.49$, ce qui donne une puissance égale à 98%.