

Master Ingénierie mathématique, Univ. Nantes  
Option Mathématiques et applications, ECN

Statistique Inférentielle.

Anne PHILIPPE  
Université de Nantes, LMJL

**Fiche 2. Modèle logistique et efficacité asymptotique**

On considère un n-échantillon  $(X_1, \dots, X_n)$  d'une loi logistique de paramètre  $\theta \in \mathbb{R}$ , de densité

$$f(x) = \frac{e^{-(x-\theta)}}{(1 + e^{-(x-\theta)})^2}, \quad x \in \mathbb{R}$$

EXERCICE 1. PARTIE THÉORIQUE :

- 1) Montrer que  $f$  est symétrique autour de  $\theta$ . En déduire l'espérance de  $X_1$ .
- 2) En déduire un estimateur de  $\theta$ .
- 3) En admettant que  $Var(X_1) = \pi^2/3$ , donner une approximation de la loi asymptotique de votre estimateur.
- 4) On admet que l'information de Fisher apportée par une observation vaut  $I(\theta) = 1/3$ . L'estimateur proposé précédemment est-il asymptotiquement efficace ?
- 5) Montrer que le maximum de vraisemblance existe. Peut-on en donner une formule explicite ? Quelle est approximativement sa loi asymptotique ?
- 6) Proposer un estimateur asymptotiquement efficace qui ne nécessite pas le calcul du maximum de vraisemblance.
- 7) Montrer que la médiane  $m(X_1)$  de  $X_1$  est égale à  $\theta$ ,

$$m(X_1) = F_\theta^{-1}(1/2) = \theta.$$

## EXERCICE 2. AVEC R

- 1) La médiane empirique  $\hat{m}_n$  (cf. cours sur les quantiles empiriques) est un estimateur de la médiane qui vérifie la propriété suivante

$$\sqrt{n}(m_n - \theta) \xrightarrow{\mathcal{L}} \mathcal{N}\left(0, \frac{1}{4} \frac{1}{f(\theta)^2}\right)$$

Illustrer ce résultat par la simulation.

*Indications :*

- Simuler  $N = 500$  échantillons de taille  $n$  (= 50 augmenter  $n$  pour visualiser la convergence) suivant la loi la loi logistique de paramètre  $\theta = 1$  (utiliser la fonction `rlogis`).
- Calculer sur chaque échantillon  $T_{n,i} = \sqrt{n}(m_n - \theta)$ , pour  $i = 1, \dots, N$ .
- comparer la densité de la loi limite avec une estimation de la densité calculée sur l'échantillon  $T_{n,1}, \dots, T_{n,N}$

Objectif :

On veut comparer les cinq estimateurs de  $\theta$  suivants :

- la moyenne empirique  $\bar{X}_n$ ,
- la médiane empirique  $m_n$ ,
- le maximum de vraisemblance  $\hat{\theta}_n$   
(indication : pour trouver le zéro d'une fonction, on pourra utiliser la fonction `uniroot` sous R, qui approche les zéros sur un intervalle que l'on fixe assez grand  $[-10,10]$ ),
- l'estimateur asymptotiquement optimal associé à la moyenne empirique

$$\tilde{\theta}_n^1 = \bar{X}_n - \frac{h_n(\bar{X}_n)}{h'_n(\bar{X}_n)}$$

- l'estimateur asymptotiquement optimal associé à la médiane

$$\tilde{\theta}_n^2 = m_n - \frac{h_n(m_n)}{h'_n(m_n)}$$

où

$$h_n(\theta) = \frac{1}{n} \sum_{i=1}^n \frac{\partial}{\partial \theta} \log(f_\theta(X_i))$$

- 2) Pour chacun des 5 estimateurs, construire une fonction dont le paramètre d'entrée est  $X$  un vecteur de longueur  $n$  et le paramètre de sortie est le vecteur constitué des estimations de  $\theta$  calculées sur  $(X_1, \dots, X_k)$  pour  $k$  variant de 10 à  $n$  par pas de  $d = 10$ .  
Indications : pour éviter des boucles !

```
est.1 = function(k,x)
{
  calcul de 1 estimateur sur x[1:k]
}
```

```
est.V1 =function(x,d)
{
  sapply(seq(d,n,d) , est.1 ,x)
}
```

- 3) Simuler un échantillon de taille  $n = 300$ , calculer et représenter l'évolution des estimateurs en fonction du nombre d'observations pour  $k$  variant de  $d$  à  $n$  par pas de  $d = 10$ .

On veut maintenant comparer les variances des 5 estimateurs.

- 4) Reprendre la question précédente sur  $N = 200$  échantillons de taille  $n = 100$  (il faudra éventuellement augmenter  $n = 200$  et  $N = 500$  pour bien estimer les variances des lois limites. Si le temps de calcul est trop long augmenter le pas  $d$  entre deux valeurs calculées ) .

Pour chaque estimateur, stocker les résultats dans une matrice à  $N$  colonnes. Soit  $\eta_k$  un des estimateurs calculé sur les  $k$  premières observations. Soit  $\eta_k(1), \dots, \eta_k(N)$  les  $N$  estimations obtenues sur les  $N$  échantillons. On note  $\widehat{\text{Var}}(\eta_k)$  la variance empirique de  $\eta_k(1), \dots, \eta_k(N)$ .

Remarque : c'est aussi la variance empirique de  $\eta_k(1) - \theta, \dots, \eta_k(N) - \theta$

- 5) Pour chacun des estimateurs, calculer  $\widehat{\text{Var}}(\eta_k)$  pour  $k$  variant de 1 à  $n$  par pas de  $d$ .
- 6) Superposer les courbes  $(k, \widehat{\text{Var}}(\eta_k))$  des 5 estimateurs
- 7) Superposer les courbes  $(\log(k), \log(\widehat{\text{Var}}(\eta_k)))$  des 5 estimateurs
- 8) Superposer les courbes  $(k, k * \widehat{\text{Var}}(\eta_k))$  des 5 estimateurs
- 9) Les résultats des simulations sont-ils en accord avec la théorie ?