

## Master professionnel II : Ingénierie mathématique : Option Statistique

Statistique Bayésienne.

Anne PHILIPPE  
Université de Nantes  
Laboratoire de Mathématiques Jean Leray

### Fiche 6. Prédiction bayésienne

#### EXERCICE 1. ( Suite de l'exercice 1 de la fiche 3)

On veut prévoir  $S^*$  le nombre d'étudiants qui dorment plus de 8 heures dans un groupe de taille  $N^*$ .

Données : on a observé  $S$  le nombre d'étudiants qui dorment plus de 8 heures dans un échantillon de taille  $N = 28$ . La valeur observée est  $s = 11$ .

On suppose que conditionnellement à  $p$  ( la proportion des étudiants qui dorment plus de 8 heures par nuit ), les deux échantillons sont indépendants

On suppose que la loi a priori sur le paramètre  $p$  est la loi beta de paramètres  $a = 3.4$  et  $b = 7.4$ .

- 1) Quelle est la loi a posteriori de  $p$  ?
- 2) Quelle est la loi de  $S^*$  conditionnellement à  $(S, p)$
- 3) En déduire la loi prédictive de  $S^*$  (autrement dit la loi conditionnelle de  $S^*$  sachant  $S$ ).
- 4) Donner une prévision ponctuelle de  $S^*$  (optimale au sens  $L^2$ )
- 5) Donner pour  $S^*$  un intervalle de prévision de niveau de confiance 95%.
- 6) Comparaison avec l'approche non bayésienne :
  - a - Quelle est la prévision ponctuelle optimale au sens  $L^2$  de  $S^*$  dans un contexte non bayésien ?
  - b - Quel prédicteur proposez-vous en pratique ?
  - c - Comparer avec le prédicteur obtenu à la question 4.
- 7) Représenter graphiquement
  - a- le prédicteur bayésien de  $S^*$  en fonction de  $N^*$
  - b- ajouter les bornes du plus court l'intervalle de prévision de niveau de confiance 80%, 90%, 95% et 99%

#### EXERCICE 2.

Soit  $X_1, \dots, X_n$   $n$  variables aléatoires définies par

$$\begin{aligned} X_0 &= 0 \\ \text{pour tout } i &= 1, \dots, n, \quad X_i = aX_{i-1} + \varepsilon_i \end{aligned} \tag{1}$$

où  $\varepsilon_1, \dots, \varepsilon_n$  sont des variables aléatoires iid suivant la loi gaussienne  $\mathcal{N}(0, 1)$  et  $a$  est un paramètre réel inconnu.

- Calcul de la vraisemblance :

- 1) Soit  $U$  et  $V$  deux variables aléatoires indépendantes. On suppose que la loi de  $U$  (respectivement de  $V$ ) admet une densité  $f_U$  (respectivement  $f_V$ ). Montrer que la loi conditionnelle de  $W = g(U) + V$  sachant  $U$  admet pour densité

$$f_{W|U}(w|u) = f_V(w - g(u)).$$

- 2) Justifier que les variables aléatoires  $X_i$  et  $\varepsilon_{i+1}$  sont indépendantes.  
 3) En déduire que la loi de  $X_i$  sachant  $X_{i-1}$  est la loi normale de moyenne  $aX_{i-1}$  et de variance 1.  
 4) En déduire la densité  $f_a^{(n)}$  de la loi des observations  $X_1, \dots, X_n$ .  
 • Modèle bayésien. On suppose que la loi a priori sur  $a$  est la loi gaussienne  $\mathcal{N}(0, 1)$ .  
 5) Calculer la loi a posteriori de  $a$ .  
 6) Quelle est la loi conditionnelle de  $X_{n+1}$  sachant  $(X_1, \dots, X_n, a)$ ?  
 7) Récupérer le fichier de données *ARmodel.txt*. Il contient  $n = 55$  observations.

### Résultat du cours .

**Mélange continu de lois** Soit  $X$  une variable aléatoire dont la loi admet une densité  $f$  par rapport à la mesure de Lebesgue. On suppose que

$$f(x) = \int_{\mathbb{R}^p} h(x|y)g(y) dy$$

où  $g$  et  $h(\cdot|y)$ , pour tout  $y \in \mathbb{R}^p$ , sont des densités de probabilité.

Pour simuler un nombre aléatoire  $x$  suivant la loi de densité  $f$  :

1. on simule  $y$  suivant la loi de densité  $g$
2. on simule  $x$  suivant la loi de densité  $h(\cdot|y)$
3. on retourne  $x$

- 8) Programmer une fonction qui retourne un échantillon suivant la loi prédictive de  $X_{n+1}$  sachant  $X_1, \dots, X_n$ .  
 9) Simuler un échantillon suivant la loi prédictive pour  $n = 50$   
 10) A partir de l'échantillon simulé, donner  
 -a- une approximation de la densité de la loi prédictive,  
 -b- le plus court intervalle de prévision de niveau de confiance 95 %,  
 -c- un prédicteur ponctuel.  
 11) Comparer avec le vraie valeurs de  $X_{51}$ .  
 12) Reprendre les questions précédentes pour  $n = 51, \dots, 54$