

ECN option mathématiques Parcours S2D

Statistique Bayésienne.

Anne PHILIPPE  
Université de Nantes  
Laboratoire de Mathématiques Jean Leray

EXERCICE 1. ESTIMATION D'UN PROPORTION

On veut estimer  $p$  la proportion des étudiants qui dorment plus de 8 heures par nuit. Les observations sur un échantillon de 27 étudiants sont :

$s= 11$  étudiants dorment plus de 8 heures

$f=16$  étudiants dorment moins de 8 heures.

On note  $S$  le nombre d'étudiants qui dorment plus de 8 heures dans un échantillon de taille  $n = 27$ .

On envisage trois lois a priori sur le paramètre  $p \in ]0, 1[$  :

$i$	$b_i$	$P(p = b_i)$
1	0.05	0.03
2	0.15	0.18
3	0.25	0.28
4	0.35	0.25
5	0.45	0.16
6	0.55	0.07
7	0.65	0.03

A- La loi discrète définie par

B- Un mélange de loi uniforme (loi a priori de type histogramme) qui admet pour densité

$$h(p) \propto \sum_{i=0}^9 q_i \mathbb{I}_{[a_i, a_{i+1}]}(p)$$

avec  $a_i = i/10$  et

$i$	0	1	2	3	4	5	6	7	8	9
$q_i$	2	4	8	8	4	2	1	1	1	1

C- La loi Beta de paramètres  $a = 3.4$  and  $b = 7.4$ .

*Comparaison des modèles a priori*

- I-1) Représenter graphiquement les trois lois a priori, calculer la moyenne et la variance de ces lois a priori
- I-2) Pour les trois lois a priori proposées, construire une fonction qui retourne la densité de la loi a posteriori. Calculer la moyenne et la variance des 3 lois a posteriori.
- I-3) Représenter graphiquement les trois lois a posteriori (superposer avec les lois a priori).
- I-4) Commenter les résultats obtenus

## Générateur de nombres aléatoires suivant la loi a posteriori

- II-1) Pour les modèles A et C, écrire une fonction qui retourne un échantillon de nombres aléatoires simulés suivant la loi a posteriori

Indications Utiliser les fonctions `sample` et `rgamma`.

## Résultat du cours .

**Mélange de lois** Soit  $\{f_i, i \in I\}$  une famille de densités et  $Z$  une variable discrète à valeurs dans  $I$ . Pour tout  $i \in I$ , on note  $P(Z = i) = p_i$ . On considère  $X$  une variable aléatoire dont la loi conditionnellement à  $Z$  admet pour densité  $f_Z$

$$P(X \in A | Z = i) = \int_A f_i(x) dx \quad \forall i \in I.$$

La loi de la variable aléatoire  $X$  admet pour densité

$$\sum_{i \in I} p_i f_i(x).$$

On dit que la loi de  $X$  est un mélange de lois  $\{f_i, i \in I\}$ .

- II-2) En utilisant le résultat précédent sur les mélanges, construire un générateur de nombres aléatoires suivant la loi a priori du modèle B.

## Résultat du cours .

**Algorithme d'acceptation rejet [AR]** : Soit  $f$  et  $g$  deux densités de même support. On suppose qu'il existe un réel  $M$  tel que  $f(x) \leq Mg(x)$ .

Soit  $(X_n)$  une suite de variables aléatoires réelles iid suivant la loi de densité  $g$  et  $(U_n)$  une suite de variables aléatoires iid suivant la loi uniforme sur  $[0, 1]$ . On suppose que les deux suites sont indépendantes.

On définit

$$N = \inf\{j : U_j \leq f(X_j)/(Mg(X_j))\}$$

La loi de  $X_T$  admet pour densité  $f$ .

Ce résultat fournit une méthode pour simuler un échantillon suivant la loi de densité  $f$  à partir de nombres aléatoires simulés suivant la loi dite instrumentale de densité  $g$  et la loi uniforme.

La moyenne de la variable aléatoire  $N$  est indicateur de la performance de l'algorithme.

- II-3) Justifier que l'on peut simuler la loi a posteriori du modèle B en utilisant un algorithme [AR] avec les lois instrumentales ( $g$ ) suivantes
- la loi a priori du modèle
  - la loi beta de paramètre (12,17)
- Programmer les deux algorithmes. Comparer les performances des deux algorithmes.
- II-4) En utilisant une méthode de Monte Carlo, donner une estimation de la moyenne et la variance des trois lois a posteriori. Evaluer à l'aide d'un intervalle de confiance la précision de votre estimation. Comparer avec les résultats obtenus dans la partie I.
- II-5) Donner une estimation de la densité de la loi a posteriori à partir d'un échantillon de nombres aléatoires simulés suivant la loi a posteriori. Comparer graphiquement l'estimateur avec la densité calculée dans la partie I.

- III-1) Construire une fonction qui retourne le plus court intervalle de crédibilité de niveau 95% à partir d'un échantillon de nombres aléatoires simulés suivant la loi a posteriori.
- III-2) Calculer ces intervalles pour les trois modèles.
- III-3) Pour chacun des modèles construire une fonction qui retourne une approximation de la région HPD de niveau 95% à partir d'un échantillon de nombres aléatoires simulés suivant la loi a posteriori.
- III-4) Calculer les régions HPD de niveau 95% pour les trois modèles.
- III-5) Comparer les intervalles de crédibilité et les régions HPD.

### *Prévision*

On veut prévoir  $S^*$  le nombre d'étudiants qui dorment plus de 8 heures dans un groupe de taille 20.

#### 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  $x$

- IV-1) Pour les trois modèles, simuler un échantillon suivant la loi prédictive de  $S^*$  (loi conditionnelle de  $S^*$  sachant  $S$ ).
- IV-2) A partir des échantillons simulés, donner
  - (a) une approximation de la densité de la loi prédictive,
  - (b) un intervalle de prévision de niveau 95 %,
  - (c) un prédicteur ponctuel.