

Statistiques Mathématiques, Feuille 1

Modèles statistiques

Les modèles statistiques sont faciles à poser lorsqu'on dispose d'observations *iid*. Les difficultés apparaissent lorsque la donnée \mathbf{x} possède une structure plus complexe et qu'il faut « modéliser » la loi \mathbb{P}_θ de \mathbf{X} .

1) Considérer le cas d'un modèle statistique où les observations X_i , $i = 1, \dots, n$, sont indépendantes, chacune de loi $N(\alpha + \beta z_i, \sigma^2)$ où les z_i sont des constantes données. Dans ce contexte, les paramètres α , β et σ sont inconnus.

a) Déterminer l'espace paramétrique Θ et la vraisemblance $L(\mathbf{x}, \theta)$.

b) Supposer que les données X_i , $i = 1, \dots, n$, sont indépendantes mais proviennent maintenant de la loi $N(\alpha_i + \beta z_i, \sigma^2)$, $i = 1, \dots, n$ où le vecteur inconnu $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_n)^T \in S$, un sous-espace vectoriel de dimension $s < n$ de \mathbb{R}^n . On modélise cette situation en choisissant une base « intéressante » (b_1, \dots, b_s) de S et en écrivant

$$\boldsymbol{\alpha} = \sum_{j=1}^s a_j b_j.$$

Déterminer alors l'espace paramétrique Θ et la vraisemblance $L(\mathbf{x}, \theta)$.

c) Application de a) : On s'intéresse au rendement X_i de plants de tomate (en kg de tomates produites). Le i -ème plant reçoit une dose de z_i grammes d'engrais ($i = 1, \dots, n$) et, pour chaque dose, on suppose que la relation entre z et X est constante et, en moyenne, linéaire. Si par ailleurs, les X_i sont indépendants, de loi normale avec variance σ^2 , déterminer la vraisemblance du modèle statistique de cette expérience.

d) Application de b) : Considérer $J (< n)$ groupes de n_j plants de tomate chacun ($n_1 + \dots + n_J = n$). La variété des plants de tomate est la même à l'intérieur de chacun des groupes mais varie d'un groupe à l'autre en donnant des rendements différents. Le i -ème plant du j -ème groupe reçoit la dose z_{ij} grammes d'engrais et on mesure son rendement X_{ij} . On suppose que tous les plants sont indépendants et que, par ailleurs, les X_{ij} sont de loi normale de variance σ^2 . Si la relation entre z et X est en moyenne linéaire de paramètres constants à l'intérieur de chaque groupe et avec une pente identique d'un groupe à l'autre, déterminer la vraisemblance du modèle statistique de cette expérience.

2) Une action est cotée en bourse au jours J_0 . A la fin de cette journée, elle vaut X_0 € que l'on suppose de loi $N(\mu, 1)$. On suppose qu'à partir de ce moment, sa valeur à la fin de la journée J_i est donnée par $X_i = \mu + \rho(X_{i-1} - \mu) + \varepsilon_i$, où les ε_i sont *iid* de loi $N(0, 1)$ et où $|\rho| < 1$. Déterminer la vraisemblance de la donnée $\mathbf{x} = (x_0, x_1, \dots, x_n)$.

Information de Fisher

3) Déterminer l'information de Fisher pour les modèles suivants :

a) $X_1, X_2, \dots, X_n \text{ iid} \sim E(\theta)$.

b) $X_1, X_2, \dots, X_n \text{ iid}$ de densité $f(x; \theta) = \theta x^{\theta-1}$ où $0 < x < 1$ et $\theta > 0$.

c) $X_1, X_2, \dots, X_n \text{ iid} \sim \Gamma(\alpha, \beta)$.

d) $X_1, X_2, \dots, X_n \text{ iid} \sim C(\mu, \sigma)$.

e) $X_1, X_2, \dots, X_n \text{ iid} \sim B(\alpha, \beta)$.

f) $X_1, X_2, \dots, X_n \text{ iid}$ de densité $f(x; \mu, \lambda) = \frac{\sqrt{\lambda}}{\sqrt{2\pi x^3}} \exp\left\{-\frac{\lambda(x-\mu)^2}{2\mu^2 x}\right\}$ si $x > 0$ avec $\mu, \lambda > 0$. On

donne que $\mathbb{E}(X) = \mu$ et $\mathbb{V}(X) = \mu^3/\lambda$.

g) Pour le modèle de l'exercice 1 a).

4) L'information de Fisher existe-elle pour la loi $U[0, \theta]$?

5) Considérer le modèle d'échantillonnage de n observation $X_1, X_2, \dots, X_n \text{ iid} \sim \text{Ber}(\theta)$ et d'information de Fisher $\mathcal{I}_{\mathcal{M}_n}(\theta)$. Supposons que l'on reparamétrise la densité en posant $\lambda = g(\theta) = \log(\theta/(1-\theta))$.

a) Écrire la vraisemblance des données en fonction du « nouveau » paramètre λ .

b) Déterminer l'information de Fisher $\mathcal{J}_{\mathcal{M}_n}(\theta)$ pour λ .

c) Montrer que $\mathcal{J}_{\mathcal{M}_n}(\theta) = [h'(\lambda)]^2 \mathcal{I}_{\mathcal{M}_n}(h(\lambda))$ où $h(\bullet) = g^{-1}(\bullet)$.

6) Généraliser le résultat 5-c) à des lois et des reparamétrisations quelconques. A titre de cas particulier, considérer le cas d'observations $X_1, X_2, \dots, X_n \text{ iid} \sim N(\theta_1, \theta_2)$ et d'information de Fisher $\mathcal{I}_{\mathcal{M}_n}(\theta)$. On reparamétrise la vraisemblance des observations en posant

$$\lambda_1 = \frac{\theta_1}{\theta_2} \text{ et } \lambda_2 = -\frac{1}{2\theta_2}.$$

Déterminer $\mathcal{J}_{\mathcal{M}_n}(\theta)$