

Feuille de Travaux Dirigés 2

Modèles linéaires généralisés

Exercice 1

On considère n variables aléatoires indépendantes y_1, \dots, y_n telles que $y_i \sim \mathcal{N}(\exp(\beta_0 + \beta_1 x_i), \sigma^2)$.

- 1 Montrer qu'il s'agit d'un modèle linéaire généralisé. En suivant les notations du cours quant aux familles exponentielles à un paramètre de nuisance, on explicitera les paramètres ϕ , θ , les fonctions γ et b ainsi que les régresseurs à considérer.
- 2 Montrer que ce n'est pas le lien canonique qui a été choisi.
- 3 On suppose dans la suite que $\sigma^2 = 1$, donner la log-vraisemblance et les équations de vraisemblance. Pouvons-nous calculer les expressions analytiques des estimateurs du maximum de vraisemblance de β_0 et β_1 ?

Exercice 2

On considère n variables aléatoires indépendantes de loi de Poisson de paramètre $\mu_i = \mathbb{E}(y_i)$. Nous supposons que $\log(\mu_i) = \beta_0 + \beta_1 x_i$ où β_0 et β_1 sont des paramètres inconnus.

- 1 Montrer qu'il s'agit d'un modèle linéaire généralisé. Est-ce le lien canonique qui a été choisi ?
- 2 Donner la log-vraisemblance et les équations de vraisemblance. Pouvons-nous calculer les expressions analytiques des estimateurs du maximum de vraisemblance de β_0 et β_1 ?

Exercice 3

On considère n variables aléatoires indépendantes y_1, \dots, y_n telles que y_i est distribué suivant une loi négative binomiale de paramètres (h, π_i) . Nous supposons que h est fixé. La loi négative binomiale modélise, dans le contexte d'une suite d'épreuves de Bernoulli indépendantes, le nombre d'essais nécessaires pour obtenir h succès, π_i représente la probabilité de succès. Nous avons

$$f(y_i; \pi_i) = C_{y_i-1}^{h-1} \pi_i^h (1 - \pi_i)^{y_i-h} \mathbf{1}_{\{h, h+1, \dots\}}(y_i).$$

Pour tout $i = 1, \dots, n$, on suppose que $\log(\pi_i/(1 - \pi_i)) = \beta_0 + \beta_1 x_i$ où $x_i \in \mathbb{R}$ est supposé connu, β_0 et β_1 sont des paramètres inconnus.

- 1 Montrer qu'il s'agit d'un modèle linéaire généralisé. La fonction de lien canonique a-t-elle été utilisée ?

2 Donner la log-vraisemblance et les équations de vraisemblance. Pouvons-nous calculer les expressions analytique des estimateurs du maximum de vraisemblance de β_0 et β_1 ?

3 Modifier le modèle en utilisant le lien canonique et donner les équations de vraisemblance.

Exercice 4

On considère un n -échantillons $(y_1, x_1), \dots, (y_n, x_n)$ du couple (y, x) où y est une variable aléatoire à valeurs dans $\{0, 1\}$ et x est une variable fixée prenant également les valeurs $\{0, 1\}$. On suppose qu'il existe une variable latente y_i^* telle que $y_i^* | x_i \sim \mathcal{N}(\beta_0 + \beta_1 x_i, 1)$ et

$$y_i = \begin{cases} 1 & \text{si } y_i^* \leq 0 \\ 0 & \text{si } y_i^* > 0 \end{cases} .$$

On note $\Phi(\cdot)$ la fonction de répartition de la loi normale centrée réduite ($\Phi(u) = \mathbb{P}(\mathcal{N}(0, 1) \leq u)$).

1 Montrer qu'il s'agit d'un modèle linéaire généralisée. En suivant les notations du cours quant aux familles exponentielles à un paramètre de nuisance, on explicitera les paramètres ϕ , θ , les fonctions b et c ainsi que la fonction γ et les régresseurs à considérer.

2 Est-ce le lien canonique qui a été choisi ?

3 Nous disposons de 100 observations (y_i, x_i) décrites dans la table de contingence suivante

	$y = 0$	$y = 1$	
$x = 0$	10	30	.
$x = 1$	20	40	

On note $\alpha_0 = \Phi(\beta_0)$ et $\alpha_1 = \Phi(\beta_0 + \beta_1)$ donner la log-vraisemblance en fonction de β_0 et β_1 .

4 Calculer l'estimateur du maximum de vraisemblance du couple (α_0, α_1) .