

Feuille de Travaux Dirigés 5

Modèles linéaires généralisés

Exercice 1 Nous disposons de deux qualités de papier. Le papier de type 1 a un poids de β_1 grammes par feuille et le papier de type 2 a un poids de β_2 grammes par feuille. Les feuilles arrivent par paquet de 100 et ne doivent pas être séparées. Nous recevons 3 paquets. Dans le premier, il y a 50 feuilles de chaque type. Dans le second, il y a 40 feuilles de type 1 et 60 feuilles de type 2, et dans le troisième 60 de type 1 et 40 de type 2. Nous pesons les paquets sur une balance l'un après l'autre. Nous admettons que les erreurs de la balance sont indépendantes et distribuées comme $N(0, \sigma^2)$. Les poids observés sont y_1 , y_2 et y_3 . Ils sont la réalisation des variables aléatoires Y_1 , Y_2 et Y_3 correspondant au poids réel plus une erreur aléatoire.

- 1 Écrire, sous forme matricielle, le modèle linéaire décrivant ces données.
- 2 Donner l'estimateur MCO du paramètre inconnu β_1 .

Exercice 2 Les modèles catalogués dans la classe des modèles linéaires généralisés sont caractérisés par trois composantes.

La composante aléatoire identifie la distribution de probabilités de la variable à expliquer.

Nous supposons ici que l'échantillon statistique est constitué de n variables aléatoires Y_i indépendantes admettant des distributions issues d'une structure exponentielle particulière. Les lois de ces variables aléatoires sont dominées par une même mesure dite de référence et la famille de leurs densités par rapport à cette mesure se met sous la forme :

$$f(y_i; \theta_i, \phi) = \exp \left\{ \frac{y_i \theta_i - v(\theta_i)}{\phi} + w(y_i, \phi) \right\}.$$

ϕ est appelé paramètre de dispersion et θ_i est appelé paramètre naturel. L'expression de la structure exponentielle précédente peut se mettre sous la forme canonique. En posant, $Q(\theta_i) = \left(\frac{\theta_i}{\phi}\right)$, $a(\theta_i) = \exp\left\{\frac{-v(\theta_i)}{\phi}\right\}$, $b(y_i) = \exp\{w(y_i, \phi)\}$. Nous obtenons $f(y_i, \theta_i) = a(\theta_i) b(y_i) \exp\{y_i Q(\theta_i)\}$.

La deuxième composante d'un modèle linéaire généralisé est constituée pour chaque Y_i d'une observation planifiée x_i de p variables explicatives. x_i est un vecteur de dimension p .

La dernière composante exprime une relation fonctionnelle entre Y_i et x_i . Soit $\mathbb{E}(Y_i) = \mu_i$ et β un vecteur de p paramètres inconnus. Nous supposons que

$$g(\mu_i) = x_i' \beta = \eta_i, \quad \forall i \in \{1, \dots, n\}$$

où g , appelée fonction de lien, est supposée monotone et différentiable. Ceci revient alors à écrire un modèle dans lequel une fonction de l'espérance mathématique μ_i appartient au sous-espace vectoriel engendré par les variables explicatives.

La fonction de lien qui associe la moyenne μ_i au paramètre naturel θ_i est appelée fonction de lien canonique, soit $g(\mu_i) = \theta_i = x_i' \beta$.

1 Donner la fonction de lien canonique lorsque, pour tout $i \in \{1, \dots, n\}$, $Y_i \sim N(\mu_i, \sigma^2)$, $Y_i \sim \mathcal{B}(\pi_i)$ et $Y_i \sim \mathcal{P}(\mu_i)$.

L'estimation des paramètres β_j est calculée en maximisant la log-vraisemblance du modèle linéaire généralisé.

2 Dans le cas général, donner la log-vraisemblance ainsi que ses dérivées premières et secondes par rapport à θ_i . En déduire de nouvelles écritures $\mathbb{E}(Y_i)$ et $\mathbb{V}(Y_i)$.

3 Donner les équations de vraisemblance. Que donnent-elles lorsque la fonction de lien est la fonction de lien canonique ?

4 Appliquer au cas où $Y_i \sim \mathcal{B}(\pi_i)$.

Exercice 3 Nous avons exposé des insectes à différentes concentrations d'un gaz nouveau. Le tableau donné ci-dessous présente les résultats de l'expérience.

| Dose x_i | Nombre d'insectes exposés, n_i | Nombre d'insectes morts, y_i |
|------------|-------------------------------------|-----------------------------------|
| 1.6907 | 59 | 6 |
| 1.7242 | 60 | 13 |
| 1.7552 | 62 | 18 |
| 1.7842 | 56 | 28 |
| 1.8113 | 63 | 52 |
| 1.8369 | 59 | 53 |
| 1.8610 | 62 | 61 |
| 1.8839 | 60 | 59 |

Pour tout $i \in \{1, \dots, 8\}$, y_i est la réalisation de la variable aléatoire Y_i suivant une loi binomiale $\mathcal{B}(n_i, \pi_i)$. Les variables aléatoires Y_i sont supposées indépendantes. Par ailleurs, nous supposons que $\log\left(\frac{\pi_i}{1 - \pi_i}\right) = \beta_0 + \beta_1 x_i$ où β_0 et β_1 sont des paramètres réels inconnus.

- 1 Calculer la log-vraisemblance de y_1, \dots, y_8 .
- 2 Donner les équations de vraisemblance. Pouvons-nous calculer les expressions analytiques des estimateurs du maximum de vraisemblance des paramètres β_0 et β_1 ?
- 3 Montrer que la matrice d'information de Fisher peut s'écrire

$$I(\beta_0, \beta_1) = \begin{pmatrix} \sum_{i=1}^8 n_i \pi_i (1 - \pi_i) & \sum_{i=1}^8 n_i x_i \pi_i (1 - \pi_i) \\ \sum_{i=1}^8 n_i x_i \pi_i (1 - \pi_i) & \sum_{i=1}^8 n_i x_i^2 \pi_i (1 - \pi_i) \end{pmatrix}.$$

- 2 Commenter la sortie SAS donnée ci-dessous.

The GENMOD Procedure

Model Information

| | |
|---------------|---------------|
| Data Set | WORK.INSECTES |
| Distribution | Binomial |
| Link Function | Logit |

| | |
|----------------------------|---------|
| Response Variable (Events) | Tues |
| Response Variable (Trials) | Exposes |
| Observations Used | 8 |
| Number Of Events | 291 |
| Number Of Trials | 481 |

Criteria For Assessing Goodness Of Fit

| Criterion | DF | Value | Value/DF |
|--------------------|----|-----------|----------|
| Deviance | 6 | 11.2322 | 1.8720 |
| Scaled Deviance | 6 | 11.2322 | 1.8720 |
| Pearson Chi-Square | 6 | 10.0268 | 1.6711 |
| Scaled Pearson X2 | 6 | 10.0268 | 1.6711 |
| Log Likelihood | | -186.2354 | |

Algorithm converged.

Analysis Of Parameter Estimates

| Parameter | DF | Estimate | Standard Error | Wald 95 % Confidence Limits | |
|-----------|----|----------|----------------|-----------------------------|----------|
| Intercept | 1 | -60.7175 | 5.1807 | -70.8715 | -50.5634 |
| Dose | 1 | 34.2703 | 2.9121 | 28.5626 | 39.9780 |
| Scale | 0 | 1.0000 | 0.0000 | 1.0000 | 1.0000 |

NOTE: The scale parameter was held fixed.

Observation Statistics

| Obs. | Tues | Expo. | dose | Pred | Xbeta | Std |
|------|------|-------|--------|-----------|-----------|-----------|
| 1 | 6 | 59 | 1.6907 | 0.058601 | -2.776615 | 0.2870224 |
| 2 | 13 | 60 | 1.7242 | 0.1640279 | -1.628559 | 0.2050525 |
| 3 | 18 | 62 | 1.7552 | 0.362119 | -0.566179 | 0.1472353 |
| 4 | 28 | 56 | 1.7842 | 0.6053149 | 0.4276606 | 0.1318339 |
| 5 | 52 | 63 | 1.8113 | 0.7951718 | 1.3563864 | 0.1620395 |
| 6 | 53 | 59 | 1.8369 | 0.9032358 | 2.2337068 | 0.2146704 |
| 7 | 61 | 62 | 1.861 | 0.9551961 | 3.0596216 | 0.2736897 |
| 8 | 60 | 60 | 1.8839 | 0.9790493 | 3.8444121 | 0.3337981 |