

Méthodes statistiques de l'économétrie I, TD 3

1. **Modèle logit conditionnel** On considère le modèle latent à double indice

$$y_{it}^* = x_{it}b + u_i + v_{it}, i = 1, \dots, n, \quad t = 1, 2,$$

pouvant servir à décrire des données individuelles temporelles, ou données de panel: pour chaque individu i d'un échantillon au hasard (tirages indépendants) on observe le couple (y_i^*, x_i) sur un nombre de périodes ici restreint à 2 (en principe – en fait on observera ici seulement une fonction de y_i^*).

Le terme d'erreur aléatoire v_{it} est supposé indépendant de x_{i1} et x_{i2} ainsi que de v_{is} pour $s \neq t$, et suit la loi logistique, de fonction de répartition

$$F(v) = \frac{1}{1 + \exp(-v)}.$$

Le modèle comporte, outre ce terme d'erreur, un *terme d'hétérogénéité* u_i considéré comme déterministe, souvent qualifié d'*effet fixe*.

Enfin le modèle observable est défini par $y_{it} = \mathbf{1}[y_{it}^*]$.

- (a) Montrer que la statistique

$$S(y_{i1}, y_{i2}) = y_{i1} + y_{i2}$$

est (partiellement) exhaustive pour le paramètre u_i . [Indication: montrer que $P[y_{i1} = 1 | y_{i1} + y_{i2} = 1]$ ne dépend pas de u_i .]

- (b) Seule une partie des observations sera informative dans le modèle conditionnel: laquelle? [Indication: que valent $P[y_{i1} = 1 | y_{i1} + y_{i2} = 2]$ et $P[y_{i1} = 0 | y_{i1} + y_{i2} = 0]$?]

2. **Statistique exhaustive minimale** Soient Y_1, \dots, Y_n indépendantes et identiquement distribuées selon la loi de Poisson $\mathcal{P}(\lambda)$.
- Quelle est la loi de la statistique $S(Y) = \sum_{i=1}^n Y_i$?
 - Montrer que la loi conditionnelle de Y sachant $S(Y) = s$ est la loi multinomiale $\mathcal{M}(s; \frac{1}{n}, \dots, \frac{1}{n})$. En déduire que $S(Y)$ est exhaustive.
 - Utiliser les résultats généraux concernant les familles exponentielles pour montrer que $S(Y)$ est exhaustive *minimale*.
3. **Identification** Montrer que toute fonction d'une fonction identifiable du paramètre θ d'un modèle est elle-même identifiable. [Indication: revenir à la définition d'une fonction identifiable du paramètre].
4. **Modèle probit** On considère le modèle latent linéaire à erreurs normales indépendantes $Y_i^* \sim N(x_i\beta, \sigma^2)$ et le modèle observable $Y_i = \mathbf{1}[Y_i^* \geq 0]$. Ce modèle observable est appelé *modèle probit*.
- Écrire la vraisemblance et le score pour le modèle probit, et vérifier que l'espérance du score est bien nulle.
 - Même exercice pour le *modèle logit* obtenu comme ci-dessus, mais sous l'hypothèse d'erreurs indépendantes suivant la loi logistique d'espérance nulle, de fonction de répartition $F(u) = 1/[1 + \exp(-u)]$.
5. **Décomposition de l'information et décomposition de la variance**
- Montrer qu'étant donné un modèle paramétrique et une statistique S , le score dans le modèle image par S coïncide avec l'espérance conditionnelle du score dans le modèle initial sachant $S(Y)$, c'est à dire:

$$\frac{\partial \ln \ell [S(Y); \theta]}{\partial \theta} = E_{\theta} \left[\frac{\partial \ln \ell (Y; \theta)}{\partial \theta} | S(Y) \right].$$
 [Indication: ce résultat d'apparence formidable se démontre en trois lignes; il suffit de dériver par rapport à θ le logarithme de la factorisation de $\ell(Y; \theta)$ faisant intervenir le conditionnement par $S(Y)$, de prendre l'espérance conditionnelle sachant $S(Y)$ de la somme obtenue, et d'utiliser le fait que l'espérance conditionnelle sachant $S(Y)$ du score dans le modèle conditionnel est nulle.]
 - Montrer que dans l'identité $I(\theta) = I^S(\theta) + E_{\theta} I^{Y|S}(\theta)$ la quantité $E_{\theta} I^{Y|S}(\theta)$ peut encore s'écrire

$$E_{\theta} I^{Y|S}(\theta) = V_{\theta} \left[\frac{\partial \ln \ell (Y|S; \theta)}{\partial \theta} \right].$$