

Université d'Orléans - Master Econométrie et Statistique
 Appliquée
 Econométrie des Variables Qualitatives

Christophe HURLIN

Correction Examen Mai 2011. C. Hurlin

Exercice 1 (15 points) : Modèle Tobit

Question 1 (1 point) : On sait que l'on a :

$$\Pr(y_i = 0) = \Pr(y_i^* < 0) = 1 - \Phi\left(\frac{\alpha + x_i\beta}{\sigma_\varepsilon}\right) \quad 1 \text{ point} \quad (1)$$

Question 2 (2 points) : Compte tenu de l'échantillon, les contributions à la vraisemblance sont les suivantes de chaque type d'individus sont les suivantes :

Nombre d'Observations	y_i	x_i	Contribution
9 observations	$y_i = 0$	$x_i = 1$	$1 - \Phi\left(\frac{\alpha + \beta}{\sigma_\varepsilon}\right)$
3 observations	$y_i = 0$	$x_i = 0$	$1 - \Phi\left(\frac{\alpha}{\sigma_\varepsilon}\right)$
1 observation	$y_i = \sqrt{4}$	$x_i = 0$	$\frac{1}{\sigma_\varepsilon} \phi\left(\frac{\sqrt{4}}{\sigma_\varepsilon}\right)$
1 observation	$y_i = \sqrt{2}$	$x_i = 0$	$\frac{1}{\sigma_\varepsilon} \phi\left(\frac{\sqrt{2}}{\sigma_\varepsilon}\right)$
1 observation	$y_i = 1$	$x_i = 1$	$\frac{1}{\sigma_\varepsilon} \phi\left(\frac{-1 - \beta}{\sigma_\varepsilon}\right)$

Dès lors, la vraisemblance s'écrit

$$\begin{aligned}
 \log L(y; \alpha, \beta, \sigma_\varepsilon^2) &= \sum_{i: y_i=0} \log \left[1 - \Phi \left(\frac{x_i \beta}{\sigma_\varepsilon} \right) \right] + \sum_{i: y_i>0} \log \left[\left(\frac{1}{\sigma_\varepsilon} \right) \phi \left(\frac{y_i - x_i \beta}{\sigma_\varepsilon} \right) \right] \\
 &= 9 \log \left[1 - \Phi \left(\frac{\alpha + \beta}{\sigma_\varepsilon} \right) \right] + 3 \log \left[1 - \Phi \left(\frac{\alpha}{\sigma_\varepsilon} \right) \right] \\
 &\quad + \log \left[\frac{1}{\sigma_\varepsilon} \phi \left(\frac{\alpha + \sqrt{4}}{\sigma_\varepsilon} \right) \right] + \log \left[\frac{1}{\sigma_\varepsilon} \phi \left(\frac{\alpha + \sqrt{2}}{\sigma_\varepsilon} \right) \right] + \log \left[\frac{1}{\sigma_\varepsilon} \phi \left(\frac{\alpha + 1 - \beta}{\sigma_\varepsilon} \right) \right] \\
 &= 9 \log \left[1 - \Phi \left(\frac{\alpha + \beta}{\sigma_\varepsilon} \right) \right] + 3 \log \left[1 - \Phi \left(\frac{\alpha}{\sigma_\varepsilon} \right) \right] - \frac{3}{2} \log (\sigma_\varepsilon^2) \\
 &\quad + \log \left[\phi \left(\frac{\alpha + \sqrt{4}}{\sigma_\varepsilon} \right) \right] + \log \left[\phi \left(\frac{\alpha + \sqrt{2}}{\sigma_\varepsilon} \right) \right] + \log \left[\phi \left(\frac{\alpha + 1 - \beta}{\sigma_\varepsilon} \right) \right]
 \end{aligned}$$

En simplifiant, il vient :

$$\begin{aligned}
 \log L(y; \alpha, \beta, \sigma_\varepsilon^2) &= 9 \log \left[1 - \Phi \left(\frac{\alpha + \beta}{\sigma_\varepsilon} \right) \right] + 3 \log \left[1 - \Phi \left(\frac{\alpha}{\sigma_\varepsilon} \right) \right] - \frac{3}{2} \log (\sigma_\varepsilon^2) \\
 &\quad - \frac{3}{2} \log (2\pi) - \frac{1}{2\sigma_\varepsilon^2} \left[(\alpha + \sqrt{4})^2 + (\alpha + \sqrt{2})^2 + (1 + \alpha - \beta)^2 \right] \quad (2)
 \end{aligned}$$

ou encore

$$\begin{aligned}
 \log L(y; \alpha, \beta, \sigma_\varepsilon^2) &= 9 \log \left[1 - \Phi \left(\frac{\alpha + \beta}{\sigma_\varepsilon} \right) \right] + 3 \log \left[1 - \Phi \left(\frac{\alpha}{\sigma_\varepsilon} \right) \right] - \frac{3}{2} \log (\sigma_\varepsilon^2) \\
 &\quad - \frac{3}{2} \log (2\pi) - \frac{1}{2\sigma_\varepsilon^2} (7 + 2\beta + \beta^2) \quad (3)
 \end{aligned}$$

Question 3 (2 points) : On pose z_i une variable dichotomique telle que :

$$z_i = \begin{cases} 1 & \text{si } y_i > 0 \\ 0 & \text{sinon} \end{cases} \quad \forall i = 1, \dots, N \quad (4)$$

La vraisemblance du modèle probit associé à z_i s'écrit :

$$\begin{aligned}
 \log L \left(z; \frac{\alpha}{\sigma_\varepsilon}, \frac{\beta}{\sigma_\varepsilon} \right) &= \sum_{i=1}^N z_i \log \left[\Phi \left(\frac{\alpha + x_i \beta}{\sigma_\varepsilon} \right) \right] + (1 - z_i) \log \left[1 - \Phi \left(\frac{\alpha + x_i \beta}{\sigma_\varepsilon} \right) \right] \\
 &= 2 \log \left[\Phi \left(\frac{\alpha}{\sigma_\varepsilon} \right) \right] + \log \left[\Phi \left(\frac{\alpha + \beta}{\sigma_\varepsilon} \right) \right] \\
 &\quad + 9 \log \left[1 - \Phi \left(\frac{\alpha + \beta}{\sigma_\varepsilon} \right) \right] + 3 \log \left[1 - \Phi \left(\frac{\alpha}{\sigma_\varepsilon} \right) \right]
 \end{aligned}$$

Question 4 (2 points) : On cherche les estimateurs du MV $(\hat{\alpha}/\hat{\sigma}_\varepsilon, \hat{\beta}/\hat{\sigma}_\varepsilon)$ tels que :

$$\left(\hat{\alpha}/\hat{\sigma}_\varepsilon, \hat{\beta}/\hat{\sigma}_\varepsilon \right) = \arg \max_{\left\{ \frac{\alpha}{\sigma_\varepsilon}, \frac{\beta}{\sigma_\varepsilon} \right\}} \left[\log L \left(z; \frac{\alpha}{\sigma_\varepsilon}, \frac{\beta}{\sigma_\varepsilon} \right) \right] \quad (5)$$

Considérons le changement de variable suivant :

$$z_1 = \Phi \left(\frac{\alpha + \beta}{\sigma_\varepsilon} \right) \quad z_2 = \Phi \left(\frac{\alpha}{\sigma_\varepsilon} \right) \quad (6)$$

La log-vraisemblance s'écrit alors :

$$\begin{aligned} \log L(z; z_1, z_2) &= 2 \times \log(z_2) + \log(z_1) \\ &\quad + 9 \times \log(1 - z_1) + 3 \times \log(1 - z_2) \end{aligned} \quad (7)$$

On cherche alors le couple (\hat{z}_1, \hat{z}_2) tel que :

$$(\hat{z}_1, \hat{z}_2) = \underset{\{z_1, z_2\}}{\arg \max} \log L(z; z_1, z_2) \quad (8)$$

Les conditions nécessaires s'écrivent :

$$\left. \frac{\partial L(z; z_1, z_2)}{\partial z_1} \right|_{\hat{z}_1} = \frac{1}{\hat{z}_1} - \frac{9}{1 - \hat{z}_1} = 0 \quad (9)$$

$$\left. \frac{\partial L(z; z_1, z_2)}{\partial z_2} \right|_{\hat{z}_2} = \frac{2}{\hat{z}_2} - \frac{3}{1 - \hat{z}_2} = 0 \quad (10)$$

D'où l'on tire que :

$$\hat{z}_1 = \frac{1}{10} \quad \hat{z}_2 = \frac{2}{5} \quad (11)$$

On en déduit alors les estimateurs de MV $\hat{\alpha}$ et $\hat{\beta}$ puisque :

$$\frac{\hat{\alpha}}{\hat{\sigma}_\varepsilon} = \Phi^{-1}(\hat{z}_2) = \Phi^{-1}\left(\frac{2}{5}\right) = -0.2533 \quad (12)$$

$$\frac{\hat{\beta}}{\hat{\sigma}_\varepsilon} = \Phi^{-1}(\hat{z}_1) - \Phi^{-1}(\hat{z}_2) = \Phi^{-1}\left(\frac{1}{10}\right) - \Phi^{-1}\left(\frac{2}{5}\right) = -1.0282 \quad (13)$$

Question 5 (2 points) : Déterminons la valeur du ratio de Mills pour les trois individus non censurés. Par définition :

$$\lambda\left(\frac{\hat{\alpha} + x_i \hat{\beta}}{\hat{\sigma}_\varepsilon}\right) = \phi\left(\frac{\hat{\alpha} + x_i \hat{\beta}}{\hat{\sigma}_\varepsilon}\right) \left[\Phi\left(\frac{\hat{\alpha} + x_i \hat{\beta}}{\hat{\sigma}_\varepsilon}\right) \right]^{-1} \quad (14)$$

Il vient donc pour les deux individus non censurés pour lesquels $x_i = 0$, on a :

$$\begin{aligned} \lambda\left(\frac{\hat{\alpha}}{\hat{\sigma}_\varepsilon}\right) &= \phi\left(\frac{\hat{\alpha}}{\hat{\sigma}_\varepsilon}\right) \left[\Phi\left(\frac{\hat{\alpha}}{\hat{\sigma}_\varepsilon}\right) \right]^{-1} \\ &= \phi(-0.2533) [\Phi(-0.2533)]^{-1} \\ &= 0.9658 \end{aligned} \quad (15)$$

Pour l'individu non censuré pour lesquels $x_i = 1$, on a :

$$\begin{aligned} \lambda\left(\frac{\hat{\alpha}}{\hat{\sigma}_\varepsilon}\right) &= \phi\left(\frac{\hat{\alpha}}{\hat{\sigma}_\varepsilon}\right) \left[\Phi\left(\frac{\hat{\alpha}}{\hat{\sigma}_\varepsilon}\right) \right]^{-1} \\ &= \phi(-0.2533 - 1.0282) [\Phi(-0.2533 - 1.0282)]^{-1} \\ &= 1.7549 \end{aligned} \quad (16)$$

Question 6 (2 points) : La régression de la deuxième étape d'Heckman ne porte que sur les trois individus non censurés et s'écrirait sous la forme :

$$y_i = x_i \beta + \sigma_\varepsilon \lambda\left(\frac{\hat{\alpha} + x_i \hat{\beta}}{\hat{\sigma}_\varepsilon}\right) + v_i \quad (17)$$

On a donc ici :

$$\begin{pmatrix} \sqrt{4} \\ \sqrt{2} \\ -1 \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0.9658 \\ 1 & 0 & 0.9658 \\ 1 & 1 & 1.7549 \end{pmatrix} \begin{pmatrix} \alpha \\ \beta \\ \sigma_\varepsilon \end{pmatrix} + \begin{pmatrix} v_1 \\ v_2 \\ v_3 \end{pmatrix} \quad (18)$$

L'estimateur des MCO des paramètres α , β et σ est donc défini par :

$$\begin{pmatrix} \hat{\alpha} \\ \hat{\beta} \\ \hat{\sigma}_\varepsilon \end{pmatrix} = \left[\begin{pmatrix} 1 & 1 & 1 \\ 0 & 0 & 1 \\ 0.9658 & 0.9658 & 1.7549 \end{pmatrix} \times \begin{pmatrix} 1 & 0 & 0.9658 \\ 1 & 0 & 0.9658 \\ 1 & 1 & 1.7549 \end{pmatrix} \right]^{-1} \\ \times \left[\begin{pmatrix} 1 & 1 & 1 \\ 0 & 0 & 1 \\ 0.9658 & 0.9658 & 1.7549 \end{pmatrix} \times \begin{pmatrix} \sqrt{4} \\ \sqrt{2} \\ 1 \end{pmatrix} \right] \quad (19)$$

On obtient $\hat{\alpha} = 0.9696$, $\hat{\beta} = -3.1544$ et $\hat{\sigma}_\varepsilon = 0.5353$.

Question 7 (2 points) : On admet que les estimateurs OLS des paramètres de la regression linéaire suivante :

$$y_i = \alpha + x_i\beta + \mu_i \quad (20)$$

obtenus à partir des données portant **sur l'ensemble** des 15 individus de l'échantillon, sont $\hat{\alpha} = 0.3104$ et $\hat{\beta} = -0.5604$. On sait que ces estimateurs OLS sont biaisés et que sous les hypothèses de Goldberger, on a :

$$\hat{\beta}_{LS} \xrightarrow[N \rightarrow \infty]{p} \beta \times \Phi \left(\frac{\alpha}{\sigma_y} \right) \quad (21)$$

où α correspond à la constante de l'équation $y_i^* = \alpha + x_i\beta + \varepsilon_i$ et $\sigma_y^2 = \sigma_\varepsilon^2 + \beta'\Omega\beta$, où Ω désigne la matrice de variance covariance des variables explicatives x_i . Un estimateur non biaisé de β (idem pour α) est donc défini par la quantité $\hat{\beta}_{LS}^c = (N/N_1) \times \hat{\beta}_{LS}$, où N_1 est le nombre d'observations pour lesquelles $y_i^* > 0$, est un estimateur convergent de β .

$$\hat{\beta}_{LS}^c = \frac{N}{N_1} \hat{\beta}_{LS} \xrightarrow[N \rightarrow \infty]{p} \beta \quad (22)$$

Ici $N_1 = 3$ et $N = 15$, on a donc :

$$\hat{\beta}_{LS}^c = -0.5604 \times \frac{15}{3} = -2.801 \quad (23)$$

$$\hat{\alpha}_{LS}^c = 0.3104 \times \frac{15}{3} = 1.5519 \quad (24)$$

Ces valeurs sont sensiblement éloignées de celles obtenus par la méthode d'Heckman, puisque les hypothèses de Goldberger ne sont pas satisfaites dans notre cas, x_i étant une variable dichotomique, qui ne peut être normalement distribuée (point bonus + 1).

Question 8 (2 points) : Dans notre cas, on a :

$$\frac{\partial E(y_i/x_i)}{\partial x_i} = \Phi \left(\frac{\alpha + x_i\beta}{\sigma_\varepsilon} \right) \beta \quad \forall i = 1, \dots, N \quad (25)$$

Pour les individus tels que $x_i = 0$, on a :

$$\begin{aligned} \frac{\partial E(y_i/x_i)}{\partial x_i} &= \Phi \left(\frac{\alpha}{\sigma_\varepsilon} \right) \beta \\ &= \Phi \left(\frac{0.9696}{0.5353} \right) \times (-3.1544) \\ &= -3.0439 \end{aligned} \quad (26)$$

Pour les individus tels que $x_i = 1$, on a :

$$\begin{aligned} \frac{\partial E(y_i/x_i)}{\partial x_i} &= \Phi\left(\frac{\alpha + \beta}{\sigma_\varepsilon}\right)\beta \\ &= \Phi\left(\frac{0.9696 - 3.1544}{0.5353}\right) \times (-3.1544) \\ &= -0.000007 \end{aligned} \tag{27}$$

Exercice 2 (6 points) : Modele Logit Indépendant

Question 1 (2 points) : cf. cours.

Question 2 (2 points) : Pour chaque variable, y compris le terme constant nommé intercept, ne figurent que trois paramètres. Celui relatif à la catégorie de référence a été omis puisqu'on sait qu'il vaut 0. La catégorie de référence est ici les ouvriers ($cs = 4$). Les trois paramètres de chaque variable sont associés aux trois catégories cs , hors la catégorie de référence, classées dans l'ordre croissant des modalités de la variable cs . Par exemple, le paramètre age_1 (0.0873) mesure l'effet de âge sur l'appartenance à la catégorie des cadres (plutôt qu'à celle des ouvriers). De façon générale, on a :

$$\Pr(y_i = j) = \frac{\exp(x_i\beta_j)}{1 + \sum_{k=1}^3 \exp(x_i\beta_k)} \tag{28}$$

où le vecteur β_4 est normalisé à zéro : $\beta_4 = 0$. Puisque le modèle logit indépendant satisfait l'hypothèse IIA, on a pour deux modalités j et k distinctes:

$$\frac{\Pr(y_i = j)}{\Pr(y_i = k)} = \frac{\exp(x_i\beta_j)}{\exp(x_i\beta_k)} = \exp[x_i(\beta_j - \beta_k)] \tag{29}$$

En particulier pour les modalités cadre ($j = 1$) et ouvrier ($k = 4$), on a :

$$\frac{\Pr(y_i = 1)}{\Pr(y_i = 4)} = \frac{\exp(x_i\beta_1)}{\exp(x_i\beta_4)} = \exp[x_i(\beta_1 - \beta_4)] = \exp(x_i\beta_1) \tag{30}$$

Dès lors pour une femme ($sexe = 1$), de nationalité française ($etr = 0$), de 30 ans ($age = 30$), ayant fini ses études à 22 ans ($afinet = 22$), on a :

$$\begin{aligned} \frac{\Pr(y_i = 1)}{\Pr(y_i = 4)} &= \exp(-15.3794 + 0.0873 * age - 0.2628 * fem + 0.6157 * afnet - 1.5111 * etr) \\ &= \exp(-15.3794 + 0.0873 * 30 - 0.2628 * 1 + 0.6157 * 22 - 1.5111 * 0) \\ &= 1.6857 \end{aligned} \tag{31}$$

Cette femme a 1.68 fois plus de chances d'être cadre qu'ouvrière.

Question 3 (2 points) : L'effet marginal de l'âge sur la probabilité que l'individu i choisisse la $j^{ème}$ modalité, $\forall j = 1, \dots, 4$, est :

$$\frac{\partial p_{i,j}}{\partial age_i} = p_{i,j} \left[\beta_j^{age} - \sum_{z=1}^4 p_{i,z} \beta_z^{age} \right] \tag{32}$$

On sait que pour cet individu :

$$\Pr(y_i = 1) = 0.1380 \quad (33)$$

$$\Pr(y_i = 2) = 0.2297 \quad (34)$$

$$\Pr(y_i = 3) = 0.2209 \quad (35)$$

$$\Pr(y_i = 4) = 0.4114 \quad (36)$$

Dès lors, il vient :

$$\begin{aligned} \frac{\Pr(y_i = 1)}{\partial age_i} &= \Pr(y_i = 1) \times \left[0.0873 - \sum_{z=1}^4 \Pr(y_i = z) \times \beta_z^{age} \right] \\ &= 0.1380 \times [0.0873 - 0.1380 \times 0.0873 - 0.2297 \times 0.0595 \\ &\quad - 0.2209 \times 0.0375 - 0.4114 \times 0] \\ &= 0.0074 \end{aligned} \quad (37)$$

$$\begin{aligned} \frac{\Pr(y_i = 4)}{\partial age_i} &= \Pr(y_i = 4) \times \left[0 - \sum_{z=1}^4 \Pr(y_i = z) \times \beta_z^{age} \right] \\ &= 0.4114 \times [0 - 0.1380 \times 0.0873 - 0.2297 \times 0.0595 \\ &\quad - 0.2209 \times 0.0375 - 0.4114 \times 0] \\ &= -0.0140 \end{aligned} \quad (38)$$

Pour cet individu, lorsque l'âge augmente, la probabilité d'être cadre augmente et celle d'être ouvrier diminue.