

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

Christophe HURLIN

Correction Examen Mai 2009. C. Hurlin

Exercice 1 (13 points) : Modèle Probit¹

Question 1 (1 point) : Sous ces hypothèses, la probabilité d'apparition de l'événement $y_i = 1$ s'écrit :

$$\begin{aligned}\Pr(y_i = 1) &= \Pr(y_i^* \geq 0) \\ &= \Pr(\varepsilon_i \geq -\alpha - \beta x_i) \\ &= 1 - \Pr(\varepsilon_i < -\alpha - \beta x_i)\end{aligned}\tag{1}$$

Sachant que ε_i *N.i.d.* $(0, 1)$, et que la loi normale est symétrique, on obtient finalement :

$$\Pr(y_i = 1) = \Pr(\varepsilon_i < \alpha + \beta x_i)\tag{2}$$

ou encore

$$\Pr(y_i = 1) = \Phi(\alpha + \beta x_i) \quad (1 \text{ point})\tag{3}$$

où $\Phi(\cdot)$ désigne la fonction de répartition de la loi normale centrée réduite.

Question 2 (2 points) : La log-vraisemblance de ce modèle probit s'écrit de la façon habituelle :

$$\log L(y; \alpha, \beta) = \sum_{i=1}^N y_i \log [\Phi(\alpha + x_i \beta)] + (1 - y_i) \log [1 - \Phi(\alpha + x_i \beta)]\tag{4}$$

Dans le cadre de cette application, on obtient alors :

$$\begin{aligned}\log L(y; \alpha, \beta) &= 16 \times \log [\Phi(\alpha + \beta)] + 26 \times \log [\Phi(\alpha)] \\ &\quad + 32 \times \log [1 - \Phi(\alpha + \beta)] + 26 \times \log [1 - \Phi(\alpha)]\end{aligned}\tag{5}$$

Question 3 (2 points) : On cherche les estimateurs du MV $(\hat{\alpha}, \hat{\beta})$ tels que :

$$(\hat{\alpha}, \hat{\beta}) = \arg \max_{\{\alpha, \beta\}} [\log L(y; \alpha, \beta)]\tag{6}$$

¹D'après l'exemple donné dans le polycopié de cours de Jean Marc Robin "Econométrie des Variables Qualitatives", Université Paris 1.

Considérons le changement de variable suivant :

$$z_1 = \Phi(\alpha + \beta) \quad z_2 = \Phi(\alpha) \quad (7)$$

La log-vraisemblance s'écrit alors :

$$\begin{aligned} \log L(y; z_1, z_2) &= 16 \times \log(z_1) + 26 \times \log(z_2) \\ &\quad + 32 \times \log(1 - z_1) + 26 \times \log(1 - z_2) \end{aligned} \quad (8)$$

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

$$(\hat{z}_1, \hat{z}_2) = \arg \max_{\{z_1, z_2\}} [\log L(y; z_1, z_2)] \quad (9)$$

Les conditions nécessaires s'écrivent :

$$\left. \frac{\partial L(y; z_1, z_2)}{\partial z_1} \right|_{\hat{z}_1} = \frac{16}{\hat{z}_1} - \frac{32}{1 - \hat{z}_1} = 0 \quad (10)$$

$$\left. \frac{\partial L(y; z_1, z_2)}{\partial z_2} \right|_{\hat{z}_2} = \frac{26}{\hat{z}_2} - \frac{26}{1 - \hat{z}_2} = 0 \quad (11)$$

D'où l'on tire que :

$$\hat{z}_1 = \frac{1}{3} \quad \hat{z}_2 = \frac{1}{2} \quad (12)$$

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

$$\hat{\alpha} = \Phi^{-1}(\hat{z}_2) = \Phi^{-1}(0.5) = 0 \quad (13)$$

$$\hat{\beta} = \Phi^{-1}(\hat{z}_1) - \Phi^{-1}(\hat{z}_2) = \Phi^{-1}(1/3) - \Phi^{-1}(0.5) = -0.43 \quad (14)$$

Bonus : condition nécessaire (+ 1 point). La matrice jacobienne dans le système (z_1, z_2) est définie négative, puisque :

$$\begin{aligned} \left(\begin{array}{cc} \frac{\partial^2 L(y; z_1, z_2)}{\partial z_1^2} & \frac{\partial^2 L(y; z_1, z_2)}{\partial z_1 \partial z_2} \\ \frac{\partial^2 L(y; z_1, z_2)}{\partial z_1 \partial z_2} & \frac{\partial^2 L(y; z_1, z_2)}{\partial z_2^2} \end{array} \right) \bigg|_{(\hat{z}_1, \hat{z}_2)} &= \begin{pmatrix} -\frac{16}{\hat{z}_1^2} - \frac{32}{(1-\hat{z}_1)^2} & 0 \\ 0 & -\frac{26}{\hat{z}_2^2} - \frac{26}{(1-\hat{z}_2)^2} \end{pmatrix} \\ &= \begin{pmatrix} -216 & 0 \\ 0 & -208 \end{pmatrix} \end{aligned} \quad (15)$$

Question 4 (2 points) : Déterminons l'effet marginal associé à la variable x . Sachant que la variable x_i est dichotomique, cet effet marginal s'écrit sous la forme suivante :

$$\varepsilon_{p_i|x_i} = \Pr(y_i = 1 | x_i = 1) - \Pr(y_i = 1 | x_i = 0) \quad (16)$$

ou encore

$$\varepsilon_{p_i|x_i} = \Phi(\alpha + \beta) - \Phi(\alpha) \quad (17)$$

On vérifie d'ores et déjà, qu'étant donné la nature dichotomique de la variable x_i et la spécification du modèle, l'effet marginal de la variable x_i est le même pour tous les individus $i = 1, \dots, N$ de l'échantillon. L'estimation de l'effet marginal vaut :

$$\begin{aligned} \hat{\varepsilon}_{p_i|x_i} &= \Phi(\hat{\alpha} + \hat{\beta}) - \Phi(\hat{\alpha}) \\ &= \hat{z}_1 - \hat{z}_2 \\ &= \frac{1}{3} - \frac{1}{2} \\ &= -\frac{1}{6} \end{aligned} \quad (18)$$

Question 5 (2 points) : On cherche à l'hypothèse nulle $H_0 : \beta = 0$ en utilisant un test de ratio de vraisemblance. On doit donc considérer la statistique suivante :-où $L(y; \hat{\alpha}, 0)$ désigne la log-vraisemblance du modèle probit obtenue sous l'hypothèse nulle $H_0 : \beta = 0$. On sait que sous l'hypothèse alternative, on a :

$$\hat{\alpha} = 0 \quad \hat{\beta} = \Phi^{-1}(1/3) = -0.43 \quad (19)$$

Dès lors la valeur de la log-vraisemblance sous l'hypothèse alternative est :

$$\begin{aligned} \log L(y; \hat{\alpha}, \hat{\beta}) &= \log L(y; \hat{z}_1, \hat{z}_2) \\ &= 16 \times \log(\hat{z}_1) + 26 \times \log(\hat{z}_2) \\ &\quad + 32 \times \log(1 - \hat{z}_1) + 26 \times \log(1 - \hat{z}_2) \\ &= 16 \times \log(1/3) + 32 \times \log(2/3) + 2 \times 26 \times \log(1/2) \quad (20) \\ &= -66.59 \quad (21) \end{aligned}$$

Sous l'hypothèse nulle la log-vraisemblance s'écrit de la façon suivante :

$$\begin{aligned} \log L(y; \alpha, 0) &= 16 \times \log[\Phi(\alpha)] + 26 \times \log[\Phi(\alpha)] \\ &\quad + 32 \times \log[1 - \Phi(\alpha)] + 26 \times \log[1 - \Phi(\alpha)] \\ &= 42 \times \log[\Phi(\alpha)] + 58 \times \log[1 - \Phi(\alpha)] \quad (22) \end{aligned}$$

On pose $z = \Phi(\alpha)$, il vient :

$$\log L(y; z, 0) = 42 \times \log(z) + 58 \times \log(1 - z)$$

Dès lors la maximisation de la vraisemblance donne :

$$\left. \frac{\partial \log L(y; z, 0)}{\partial z} \right|_{\hat{z}} = \frac{42}{\hat{z}} - \frac{58}{1 - \hat{z}} = 0 \quad (23)$$

D'om l'on tire que :

$$\hat{z} = \frac{42}{100} = 0.42 \quad (24)$$

Par conséquent, la valeur de la log-vraisemblance sous l'hypothèse nulle est :

$$\begin{aligned} \log L(y; \hat{z}, 0) &= 42 \times \log(\hat{z}) + 58 \times \log(1 - \hat{z}) \\ &= 42 \times \log(0.42) + 58 \times \log(1 - 0.42) \\ &= -68.02 \quad (25) \end{aligned}$$

On en déduit la valeur de la statistique LRT :

$$\begin{aligned} LRT &= -2 \times \left[\log L(y; \hat{\alpha}, 0) - \log L(y; \hat{\alpha}, \hat{\beta}) \right] \\ &= -2 \times (-68.02 - 66.59) \\ &= 2.86 \quad (26) \end{aligned}$$

Sous H_0 , cette statistique suit une loi du chi-deux à 1 degré de liberté. Pour un risque de première espèce, le seuil critique est égal à 3.84, donc on ne peut rejeter $H_0 : \beta = 0$.

Question 6 (2 point) : Par définition, on a :

$$R^2 \text{ de McFadden (1974)} = 1 - \frac{\log L(y; \hat{\alpha}, \hat{\beta})}{\log L(y; \alpha, 0)} \quad (27)$$

Donc ici, on a :

$$R^2 \text{ de McFadden (1974)} = 1 - \frac{-66.59}{-68.02} = 0.021 \quad (28)$$

Question 7 (2 points) : Calculons les probabilités estimées de réalisation de l'événement $y_i = 1$ à partir de la formule suivante :

$$\widehat{\Pr}(y_i = 1) = \Phi(\widehat{\alpha} + \widehat{\beta}x_i) = \Phi(-0.43x_i)$$

Nombre d'Observations	y_i	x_i	$\widehat{\Pr}(y_i = 1)$
16 observations	$y_i = 1$	$x_i = 1$	$\frac{1}{3}$
26 observations	$y_i = 1$	$x_i = 0$	$\frac{1}{2}$
32 observations	$y_i = 0$	$x_i = 1$	$\frac{1}{3}$
26 observations	$y_i = 0$	$x_i = 0$	$\frac{1}{2}$

ROC Curve cf. cours

Exercice 2 (8 points) : Modele Logit Conditionnel

Question 1 (0.5 point) : Modèle logit conditionnel. cf. cours

Question 2 (0.5 point) : En supposant qu'il n'existe pas de données manquantes, pour chaque individu et pour chaque variable explicative, sont reportées quatre valeurs correspondant aux quatre modalités (avion, train, bus et voiture). Sachant qu'il y a 210 individus dans la base, on doit donc avoir pour chaque variable explicative un total de 840 observations.

Question 3 (1 point). Dans cette spécification on observe que $\beta_4 = 0$. Si $\beta_j > 0$, cela signifie que toutes choses égales par ailleurs, la probabilité de prendre la modalité de transport j est supérieure la probabilité de prendre la voiture.

Question 4 (1 point) : Dans le cadre du modèle logit conditionnel, on montre que pour l'individu n°2 :

$$x_{2,1}\widehat{\beta} = -2.540 \quad x_{2,2}\widehat{\beta} = -2.155 \quad x_{2,3}\widehat{\beta} = -3.771 \quad x_{2,4}\widehat{\beta} = -1.171 \quad (29)$$

avec

$$x_{2,1}\widehat{\beta} = \widehat{\beta}_1 * \mathbb{I}_{(j=1)} + \widehat{\beta}_2 * \mathbb{I}_{(j=2)} + \widehat{\beta}_3 * \mathbb{I}_{(j=3)} + \widehat{\beta}_4 * tps_trans_{2,j} + \widehat{\beta}_5 * tps_trajet_{2,j} + \widehat{\beta}_6 * cout_{2,j}, \quad (30)$$

Les probabilités estimées sont définies par :

$$\widehat{\Pr}(y_2 = j) = \frac{\exp(x_{2,j}\widehat{\beta})}{\sum_{k=1}^4 \exp(x_{2,k}\widehat{\beta})} \quad (31)$$

On montre alors que :

$$\widehat{\Pr}(y_2 = 1) = 0.1495 \quad \widehat{\Pr}(y_2 = 2) = 0.2196 \quad \widehat{\Pr}(y_2 = 3) = 0.0436 \quad \widehat{\Pr}(y_2 = 4) = 0.5873 \quad (32)$$

Question 5 (2 points) : L'EM associé au coût de transport (noté par simplification $w_{i,j}$) est défini par :

$$\begin{aligned} \frac{\partial \Pr(y_i = j)}{\partial w_{i,j}} &= \frac{\partial}{\partial w_{i,j}} \left(\frac{\exp(x_{i,j}\beta)}{\sum_{k=1}^4 \exp(x_{i,k}\beta)} \right) \\ &= \left[\beta_6 * \exp(x_{i,j}\beta) * \sum_{k=1}^4 \exp(x_{i,k}\beta) - \beta_6 * \exp(x_{i,j}\beta) * \exp(x_{i,j}\beta) \right] \\ &\quad * \left[\sum_{k=1}^4 \exp(x_{i,k}\beta) \right]^{-2} \end{aligned} \quad (33)$$

On obtient alors :

$$\frac{\partial \Pr(y_i = j)}{\partial w_{i,j}} = \beta_6 * \left\{ \frac{\exp(x_{i,j}\beta)}{\left[\sum_{k=1}^4 \exp(x_{i,k}\beta) \right]^{-2}} \right\} * [1 - \exp(x_{i,j}\beta)] \quad (34)$$

$$= \quad (35)$$

Pour l'individu 2, la modalité voiture ($j = 4$), l'effet marginal du coût de transport vaut :

$$\frac{\partial \Pr(y_i = 4)}{\partial w_{i,j}} = -0.0139 * \left\{ \frac{\exp(-1.171)}{\left[\sum_{k=1}^4 \exp(x_{i,k}\beta) \right]^{-2}} \right\} * [1 - \exp(-1.171)] \quad (36)$$

$$= -0.0056 \quad (37)$$

On vérifie que dans ce cas, une hausse du coût du voyage diminue la probabilité de prendre la voiture.

Question 6 (2 points) : Pour un individu i , la log vraisemblance associée à un modèle logit conditionnel s'écrit alors :

$$\log L(y, \beta) = \sum_{j=1}^4 y_{i,j} x_{i,j} \beta - \log \left[\sum_{k=1}^4 \exp(x_{i,k}\beta) \right] \quad (38)$$

Ici on a donc pour l'individu 2 :

$$\log L(y, \beta) = \sum_{j=1}^4 y_{2,j} x_{2,j} \beta - \log \left[\sum_{k=1}^4 \exp(x_{2,j}\beta) \right] \quad (39)$$

$$= x_{2,4}\beta - \log \left[\sum_{k=1}^4 \exp(x_{2,j}\beta) \right] \quad (40)$$

puisque l'individu 2 a choisit au final de prendre la voiture ($y_{2,4} = 1, y_{2,j} = 0$, pour $j \neq 4$). Dès lors, pour la valeur estimée des paramètres on obtient :

$$\log L(y, \hat{\beta}) = x_{2,4}\hat{\beta} - \log \left[\sum_{k=1}^4 \exp(x_{2,j}\hat{\beta}) \right] \quad (41)$$

$$= -1.171 - \log \left[\sum_{k=1}^4 \exp(x_{2,j}\hat{\beta}) \right] \quad (42)$$

$$= -0.532 \quad (43)$$