

Modelli a variabili dipendenti qualitative

Giulio Palomba

Agosto 2008

Modelli con variabili dipendenti discrete (qualitative):

Binomiali (Scelte binarie): $y = 1$ oppure $y = 0$ (Logit, Probit)

Multinomiali (Risultati ordinati):

a. Count data: $y = 0, 1, 2, \dots$ (modello di Poisson, modello binomiale)

b. Modelli gerarchici: $y = 0, 1, 2, \dots$. A ciascun valore è assegnata una posizione gerarchica, ma non è detto che la differenza tra $y = 0$ e $y = 1$ sia ad esempio la stessa che intercorre tra $y = 2$ e $y = 3$. La numerazione serve solamente a stilare una gerarchia.

Multinomiali (Risultati non ordinati):

a. Modelli multinomiali: $y = 0, 1, 2, \dots$, ma non c'è gerarchia.

b. Modelli annidati

1 Modelli di scelta binaria

I modelli di scelta binaria hanno la caratteristica peculiare di avere la variabile dipendente discreta che può assumere solamente i valori 1 oppure 0; tale variabile dipendente è perciò dicotomica e si configura come una variabile dummy. Il problema principale che si cerca di risolvere attraverso l'utilizzo di questi modelli è quindi quello di spiegare i valori assunti dalla variabile dipendente dicotomica attraverso un insieme di variabili esplicative.

I modelli a scelta binaria sono stati concepiti per l'analisi delle scelte individuali in quanto spesso, nella realtà economica, l'individuo deve effettuare la scelta tra due distinte alternative; in quest'approccio la sfera individuale diventa perciò preponderante rispetto alla dimensione temporale nella quale le scelte vengono compiute.

L'innovazione apportata da questa classe di modelli investe soprattutto l'obiettivo della stima: se nei modelli con variabili dipendenti continue si cercava di spiegare il "quanto", attraverso i modelli con variabili dipendenti discrete si tenta di spiegare il "se", quindi il modello di regressione deve giocoforza analizzare le probabilità delle scelte individuali.

Introducendo la notazione matematica, lo scopo è quello di costruire un modello del tipo

$$p_i = Pr(y_i = j) = F(x_i' \beta), \quad (1)$$

dove y_i è la variabile dipendente dicotomica, x_i è un vettore colonna contenente le k variabili esplicative, β è il vettore k -dimensionale contenente i parametri incogniti, p_i rappresenta la probabilità che l' i -esimo individuo effettui la j -esima scelta¹. Tutta l'equazione (1) è riferita al generico individuo i -esimo, con $i = 1, 2, \dots, N$. La funzione $F(x_i' \beta)$ svolge il ruolo decisivo nel modello

$$y_i = F(x_i' \beta) + \varepsilon_i \quad (2)$$

¹Nei modelli a scelta binaria le alternative per j sono soltanto $j = 0$ oppure $j = 1$.

poiché è quella relativa alla media condizionale $E(y_i | x_i)$. Si tenga presente che l'argomento $x_i'\beta$ della funzione ritorna uno scalare perché è il prodotto di due vettori conformabili di dimensione rispettivamente $(1 \times k)$ e $(k \times 1)$: in questo modo il dominio di $F(x_i'\beta)$ è l'insieme dei numeri reali \mathbb{R} . Dato che y_i può assumere solamente i valori 1 e 0, da questo approccio emerge che:

- le variabili esplicative x_i colgono le caratteristiche individuali (gli individui scelgono),
- i parametri contenuti nel vettore β determinano l'impatto delle variabili esplicative nelle scelte individuali,
- il metodo OLS è difficilmente applicabile; generalmente si ricorre perciò alla stima MLE.

Analiticamente si ha

$$\begin{aligned} E(y_i | x_i) &= 1 \cdot p_i + 0 \cdot (1 - p_i) \\ &= p_i \\ &= F(x_i'\beta). \end{aligned}$$

1.1 Modello di probabilità lineare

Nel modello di probabilità lineare la funzione di regressione è lineare quindi risulta $E(y_i | x_i) = F(x_i'\beta) = x_i'\beta$; l'equazione (2) diventa perciò

$$y_i = x_i'\beta + \varepsilon_i \quad (3)$$

nel quale tutte le ipotesi classiche sono rispettate. Dato che la variabile dipendente è una dummy, l'unica ipotesi che non è rispettata è quella di omoschedasticità, in quanto:

$$\begin{aligned} - \text{ se } y_i = 1 &\Rightarrow \varepsilon_i = 1 - x_i'\beta &\Rightarrow Pr(\varepsilon_i = 1 - x_i'\beta) = p_i, \\ - \text{ se } y_i = 0 &\Rightarrow \varepsilon_i = -x_i'\beta &\Rightarrow Pr(\varepsilon_i = -x_i'\beta) = 1 - p_i. \end{aligned}$$

Questa relazione genera eteroschedasticità, infatti

$$\begin{aligned} Var(\varepsilon_i) &= [(\varepsilon_i | y_i = 1) - E(\varepsilon_i)]^2 Pr(\varepsilon_i | y_i = 1) + [(\varepsilon_i | y_i = 0) - E(\varepsilon_i)]^2 Pr(\varepsilon_i | y_i = 0) \\ &= [1 - x_i'\beta]^2 p_i + [-x_i'\beta]^2 (1 - p_i) \\ &= x_i'\beta(1 - x_i'\beta) \\ &= p_i(1 - p_i) \end{aligned} \quad (4)$$

L'equazione (4) è quella della varianza di una variabile casuale bernoulliana² nella quale la probabilità che $y_i = 1$ sia p_i . L'errore non è omoschedastico in quanto dipende dai valori di x_i e del vettore dei parametri β , quindi lo stimatore OLS non rispetta il Teorema di Gauss-Markov³. Per ottenere una stima efficiente occorre perciò stimare un modello GLS con matrice dei pesi data da

$$\Omega = \text{diag}(\omega_i),$$

con $\omega_i = [x_i'\beta(1 - x_i'\beta)]^{1/2}$ e $i = 1, 2, \dots, N$.

Il modello di probabilità lineare soffre di due problemi:

1. può accadere che $x_i'\beta(1 - x_i'\beta) < 0$, cosa non ammissibile per una varianza,
2. può accadere che $x_i'\beta \notin [0, 1]$, cosa non ammissibile per una probabilità.

²Si ricorda che la varianza della variabile casuale bernoulliana con funzione di probabilità $p(x) = p^x(1 - p)^{1-x}$ è data da $Var(X) = p(1 - p)$.

³In particolare lo stimatore OLS non è BLUE.

1.2 Modelli Logit e Probit

Per ovviare ai due problemi che affliggono il modello di probabilità lineare occorre trovare una forma funzionale per $F(x'_i\beta)$ tale per cui

$$\begin{cases} \lim_{x'_i\beta \rightarrow -\infty} F(x'_i\beta) = 0 \\ \lim_{x'_i\beta \rightarrow +\infty} F(x'_i\beta) = 1. \end{cases} \quad (5)$$

La naturale candidata a svolgere questo ruolo è la funzione di ripartizione poiché $F(x'_i\beta) : \mathbb{R} \rightarrow [0, 1]$: ciò garantisce che $p_i = F(x'_i\beta) \in [0, 1]$, quindi anche che $Var(\varepsilon_i) \geq 0$ per ogni i .

La scelta di $F(x'_i\beta)$ è decisiva in questo contesto e le due specificazioni principali introdotte in letteratura utilizzano la funzione di ripartizione di due variabili casuali continue con funzione di densità simmetrica e funzioni di ripartizioni non molto “differenti” (si vedano le Figura 1 e 2). In particolare si hanno:

- **Modello Probit:** distribuzione normale con $F(x'_i\beta) = \Phi(x'_i\beta)$

$$p_i = Pr(y_i = 1) = \Phi(x'_i\beta) = \int_{-\infty}^{x'_i\beta/\sigma} \frac{1}{2\pi} e^{-\frac{z^2}{2}} dz \quad (6)$$

- **Modello Logit:** distribuzione logistica con $F(x'_i\beta) = \Lambda(x'_i\beta)$

$$p_i = Pr(y_i = 1) = \Lambda(x'_i\beta) = \int_{-\infty}^{x'_i\beta/\sigma} \frac{e^z}{[1 + e^z]^2} dz = \frac{e^{x'_i\beta}}{1 + e^{x'_i\beta}} \quad (7)$$

dove il parametro (scalare) σ è inserito per ovviare al problema dell'identificazione⁴ durante la fase della stima. In entrambe le formulazioni $x'_i\beta \in (-\infty, +\infty)$ e le funzioni di media condizionale non sono lineari nelle variabili esplicative x_i .

Le variabili casuali normale standardizzata e logistica hanno rispettivamente funzione di densità $\phi(x'_i\beta)$ e $\lambda(x'_i\beta)$ simmetriche (si veda la Figura 1); da questa caratteristica deriva che

$$\begin{cases} \Phi(x'_i\beta) = 1 - \Phi(-x'_i\beta) \\ \Lambda(x'_i\beta) = 1 - \Lambda(-x'_i\beta) = \frac{1}{1 - e^{-x'_i\beta}}. \end{cases} \quad (8)$$

Inoltre, per la variabile casuale logistica, valgono le seguenti proprietà:

1. distribuzione molto simile alla distribuzione normale standardizzata, soprattutto per $x'_i\beta \in [-1.2, 1.2]$ (cfr. Greene),
2. la distribuzione è leptocurtica, cioè comprende una massa di probabilità lungo le code maggiore di quella che si ha per la variabile casuale normale (si veda la Figura 1): la probabilità associata agli eventi “estremi” ($y_i = 0$ oppure $y_i = 1$) è perciò maggiore nel Logit rispetto al Probit,
3. la varianza della variabile casuale logistica è pari a $\pi^2/3$,
4. è sempre possibile determinare analiticamente la primitiva nell'integrale della curva di densità, cosa non possibile per a variabile casuale normale⁵,
5. la funzione di densità è data da

$$\lambda(x'_i\beta) = \Lambda(x'_i\beta)[1 - \Lambda(x'_i\beta)], \quad (9)$$

⁴Di fatto σ rappresenta un coefficiente di proporzionalità che può essere posto uguale ad 1 senza determinare perdita di generalità del modello. Una spiegazione intuitiva sarà fornita a pag. 11.

⁵Per questo motivo la variabile casuale normale standardizzata è tabulata.

Figura 1: Funzioni di densità

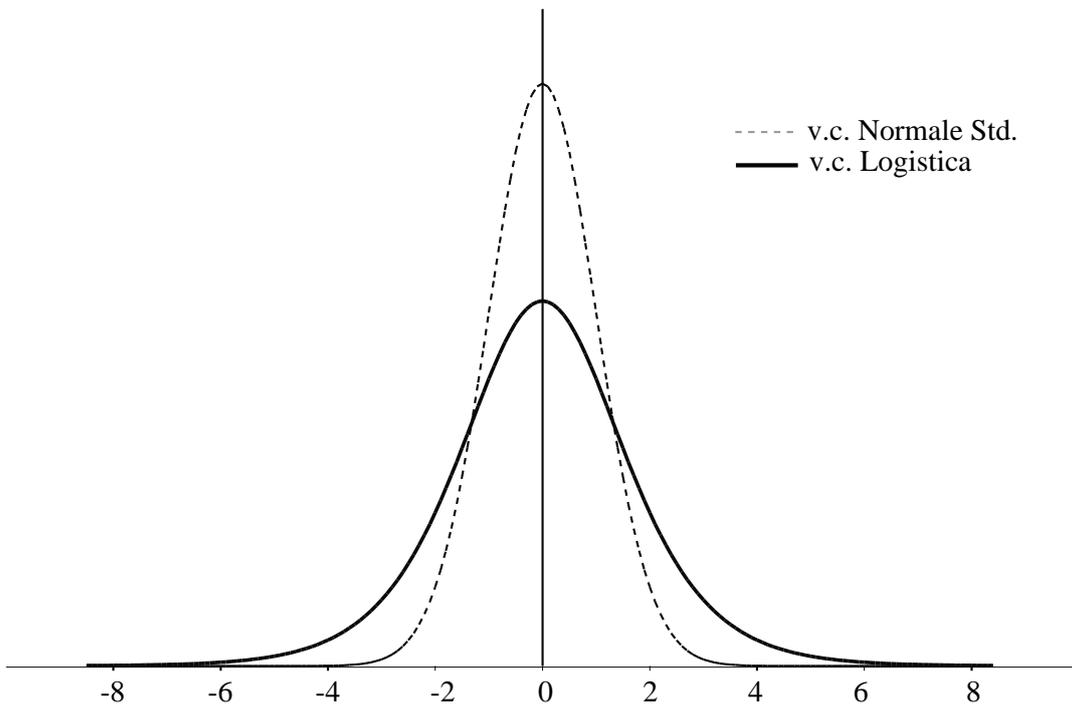
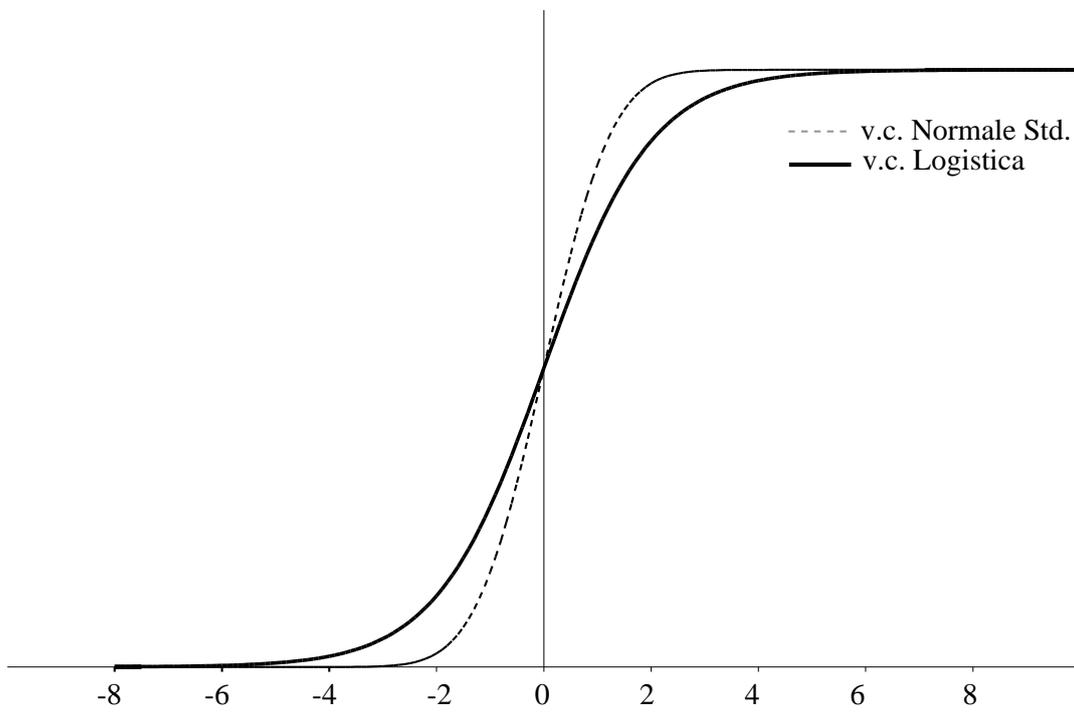


Figura 2: Funzioni di ripartizione



6. il LOG-ODDS RATIO è lineare nelle variabili e nei parametri, infatti

$$\begin{aligned}\log \Lambda(x'_i\beta) &= \log \left[\frac{e^{x'_i\beta}}{1 + e^{x'_i\beta}} \right] \\ &= x'_i\beta - \log(1 + e^{x'_i\beta})\end{aligned}$$

e

$$\begin{aligned}\log[1 - \Lambda(x'_i\beta)] &= \log \left[\frac{1}{1 + e^{-x'_i\beta}} \right] \\ &= -\log(1 + e^{-x'_i\beta}).\end{aligned}$$

Poiché il log-odds ratio è dato dal logaritmo del rapporto tra la probabilità che $y_i = 1$ e la probabilità che $y_i = 0$, si ha

$$\begin{aligned}\log \frac{p_i}{1 - p_i} &= \log \frac{\Lambda(x'_i\beta)}{1 - \Lambda(x'_i\beta)} \\ &= \log \Lambda(x'_i\beta) - \log[1 - \Lambda(x'_i\beta)] \\ &= x'_i\beta\end{aligned}\tag{10}$$

La scelta tra un Logit o un Probit dipende esclusivamente da ragioni pratiche in quanto di fatto non esistono motivi teorici per la scelta. Amemiya (1981) discute queste ragioni, ma la questione ancora oggi resta aperta. In diverse applicazioni, inoltre, non sembrano esserci sostanziali differenze tra un approccio o l'altro.

1.2.1 Interpretazione dei coefficienti

Nel modello lineare di probabilità i parametri contenuti in β rappresentano gli effetti marginali che le variabili esplicative x_i esercitano sulla variabile dipendente, infatti

$$\frac{\partial E(y_i | x_i)}{\partial x_i} = \beta.$$

Tale effetto marginale è indipendente da $i = 1, 2, \dots, N$. A prescindere dal modello utilizzato nella stima, nel Logit e nel Probit tale condizione non è vera perché il vettore dei parametri è inserito all'interno di una funzione non lineare, quindi risulta

$$\frac{\partial E(y_i | x_i)}{\partial x_i} = \frac{\partial F(x'_i\beta)}{\partial x_i} = f(x'_i\beta)\beta$$

che invece dipende necessariamente dalle variabili esplicative x_i . In particolare risulta

$$f(x'_i\beta)\beta = \begin{cases} \phi(x'_i\beta)\beta & \text{Probit} \\ \lambda(x'_i\beta)\beta = \Lambda(x'_i\beta)[1 - \Lambda(x'_i\beta)]\beta & \text{Logit} \end{cases}\tag{11}$$

Una quantità spesso utilizzata nel confronto tra le stime Logit e Probit è la pendenza (slope at mean) $m(\bar{x})$ che ricorre al vettore delle medie aritmetiche di x_i per valutare gli effetti marginali⁶. La pendenza è perciò definita come segue:

$$m(\bar{x}) = \frac{\partial F(\bar{x}'\beta)}{\partial \bar{x}} = f(\bar{x}'\beta)\beta\tag{12}$$

dove \bar{x} vettore k -dimensionale contenente le medie aritmetiche delle variabili esplicative x_i .

In grandi campioni la pendenza del Probit e del Logit tendono a coincidere; se ciò accade anche in campioni finiti, in pratica non c'è sostanziale differenza tra le due stime.

⁶Ad esempio, il pacchetto econometrico `Gretl` per default utilizza le pendenze al posto degli standard error dei parametri nelle stime Logit e Probit.

E' inoltre possibile effettuare un confronto tra i diversi modelli basandosi sulla stima dei coefficienti β . Tenendo presente che la varianza della variabile casuale normale standardizzata è 1, mentre quella della variabile casuale logistica è $\pi^2/3$, standardizzando la stima Logit si ottiene

$$\hat{\beta}_P \approx \frac{\hat{\beta}_L}{\sqrt{\pi^2/3}} = \frac{\sqrt{3}}{\pi} \hat{\beta}_L = 0.551 \hat{\beta}_L$$

Amemiya (1981) dimostra che si ottengono risultati più accurati se si utilizza un coefficiente pari a 0.625, in quanto approssima meglio la conversione quando $x'_i\beta = 0$, cioè quando $F(x'_i\beta) = 0.5$. Data la leptocurtosi della variabile casuale logistica (si veda la Figura ???), per campioni sbilanciati⁷ tale coefficiente tende a diminuire lungo le code della distribuzione.

Considerando anche il modello lineare di probabilità risulta

$$\hat{\beta}_{PL} \approx 0.25 \hat{\beta}_L$$

mentre per la costante si ha

$$\hat{\alpha}_{PL} \approx 0.5 + 0.25 \hat{\alpha}_L.$$

In questo modo sono possibili tutte le conversioni tra $\hat{\beta}_P$, $\hat{\beta}_L$ e $\hat{\beta}_{PL}$.

1.2.2 Stima

Poiché la forma funzionale della media condizionale di y_i date le variabili esplicative x_i non è lineare cade un'importante ipotesi del modello lineare classico, quindi non è possibile stimare un Probit o un Logit col metodo OLS. Generalmente questo tipo di modelli viene stimato ricorrendo al metodo MLE.

Se si considerano N eventi i.i.d. dicotomici con $Pr(y_i = 1) = p_i$ e $Pr(y_i = 0) = 1 - p_i$, in pratica si ha un campionamento da una popolazione bernoulliana nel quale la funzione di probabilità per ciascuna osservazione è data da $p(y_i) = p_i^{y_i} (1 - p_i)^{1 - y_i}$. La funzione di probabilità congiunta del campione o funzione di verosimiglianza è perciò⁸

$$\begin{aligned} L(\beta) &= \prod_{i=1}^N p_i^{y_i} (1 - p_i)^{1 - y_i} \\ &= \prod_{i=1}^N F(x'_i\beta)^{y_i} [1 - F(x'_i\beta)]^{1 - y_i}. \end{aligned} \quad (13)$$

La log-verosimiglianza è

$$\ell(\beta) = \sum_{i=1}^N y_i \log F(x'_i\beta) + (1 - y_i) \log[1 - F(x'_i\beta)]. \quad (14)$$

⁷Un campione si definisce sbilanciato se la numerosità delle $y_i = 1$ e quella delle $y_i = 0$ differiscono sostanzialmente.

⁸Si tenga presente che la distribuzione bernoulliana è un caso particolare della distribuzione binomiale con numero delle prove pari a 1. In questo caso il coefficiente binomiale associato a ciascuna osservazione vale

$$\binom{1}{y_i} = 1$$

per ogni y_i .

Lo score è

$$\begin{aligned}
s(\beta) &= \sum_{i=1}^N y_i \frac{\partial \log F(x'_i \beta)}{\partial \beta} + (1 - y_i) \frac{\partial \log[1 - F(x'_i \beta)]}{\partial \beta} \\
&= \sum_{i=1}^N y_i \frac{\partial F(x'_i \beta) / \partial \beta}{F(x'_i \beta)} + (1 - y_i) \frac{\partial[-F(x'_i \beta)] / \partial \beta}{1 - F(x'_i \beta)} \\
&= \sum_{i=1}^N \frac{\partial F(x'_i \beta) / \partial \beta [y_i - F(x'_i \beta)]}{F(x'_i \beta) [1 - F(x'_i \beta)]} \\
&= \sum_{i=1}^N \frac{y_i - F(x'_i \beta)}{F(x'_i \beta) [1 - F(x'_i \beta)]} f(x'_i \beta) x_i.
\end{aligned} \tag{15}$$

In particolare si ha

$$s(\beta) = \begin{cases} \sum_{i=1}^N \frac{y_i - \Phi(x'_i \beta)}{\Phi(x'_i \beta) [1 - \Phi(x'_i \beta)]} \phi(x'_i \beta) x_i & \text{Probit} \\ \sum_{i=1}^N \frac{y_i - \Lambda(x'_i \beta)}{\Lambda(x'_i \beta) [1 - \Lambda(x'_i \beta)]} \lambda(x'_i \beta) x_i = \sum_{i=1}^N [y_i - \Lambda(x'_i \beta)] x_i & \text{Logit} \end{cases} \tag{16}$$

In pratica, per entrambi i modelli, la funzione score può essere scritta nella forma

$$s(\beta) = \sum_{i=1}^N g_i x_i, \tag{17}$$

dove $g_i = y_i - \Lambda(x'_i \beta)$ per il Logit, mentre g_i assume una forma più complessa per il Probit⁹.

Per ottenere lo stimatore MLE occorre che la condizione del primo ordine sullo score $s(\beta) = 0$ sia soddisfatta; poiché β è inserito all'interno della funzione non lineare $F(x'_i \beta)$, la soluzione del problema non può essere ottenuta in forma chiusa, quindi occorrono algoritmi di calcolo numerico per ottimizzare la funzione log-verosimiglianza. Il metodo di Newton rappresenta l'algoritmo più conveniente per raggiungere la convergenza. Una volta ottenuta la stima per il vettore β è possibile calcolare le quantità $e^{x_i \hat{\beta}}$, $\phi(x_i \hat{\beta})$, $\Phi(x_i \hat{\beta})$, $\lambda(x_i \hat{\beta})$ e $\Lambda(x_i \hat{\beta})$.

La garanzia che lo stimatore MLE $\hat{\beta}$ risolve un problema di ricerca di un massimo deriva dal fatto che la

⁹In particolare, sfruttando la proprietà $\Phi(x'_i \beta) = 1 - \Phi(-x'_i \beta)$, per il Probit la funzione score può essere scritta nella forma

$$\begin{aligned}
s(\beta) &= \left[\sum_{y_i=1} \frac{\phi(x'_i \beta)}{\Phi(x'_i \beta)} + \sum_{y_i=0} \frac{-\phi(x'_i \beta)}{\Phi(-x'_i \beta)} \right] x_i \\
&= \sum_{i=1}^N \frac{q_i \phi(q_i x'_i \beta)}{\Phi(q_i x'_i \beta)} x_i \\
&= \sum_{i=1}^N g_i x_i,
\end{aligned}$$

dove $q_i = 2y_i - 1$ in modo da trasformare i valori 0 e 1 nei valori ± 1 .

matrice di informazione è almeno semidefinita positiva, infatti risulta

$$I(\beta) = \begin{cases} \sum_{i=1}^N \frac{\phi(x'_i\beta)^2}{\Phi(x'_i\beta)[1-\Phi(x'_i\beta)]} x_i x'_i & \text{Probit} \\ \sum_{i=1}^N \lambda(x'_i\beta) x_i x'_i & \text{Logit} \end{cases} \quad (18)$$

Dalla (18) risulta che in entrambi i modelli la matrice di informazione è una forma quadratica di dimensione $k \times k$, quindi risulta almeno definita positiva (Hessiana $H(\beta) = -I(\beta)$ almeno definita negativa).

La matrice asintotica delle covarianze di β è data da

$$V_\beta = [I(\beta)]^{-1} \quad (19)$$

che rappresenta anche l'estremo di Cramer-Rao. Lungo la diagonale principale di tale matrice sono disposti gli standard error $se(\beta)$ utili per la verifica di ipotesi sui parametri del vettore β stimato.

Poiché nei modelli Probit e Logit la probabilità prevista è pari a $\hat{p}_i = F(x'_i\hat{\beta})$, mentre gli effetti marginali previsti ammontano a $f(x'_i\hat{\beta})\hat{\beta}$, lo standard error degli stessi effetti marginali viene calcolato via Delta Method attraverso gli elementi diagonali della matrice

$$\Sigma_{\hat{\beta}} = \left\{ \left[\frac{\partial F(x'_i\hat{\beta})}{\partial \beta} \right]' V_\beta \left[\frac{\partial F(x'_i\hat{\beta})}{\partial \beta} \right] \right\}^{1/2}.$$

1.2.3 Verifica di ipotesi

Nei modelli Probit e Logit tutti i test statistici standard per la verifica di ipotesi sui parametri stimati $\hat{\beta}$ si possono applicare (test t , W , LR e LM).

Un test corrispondente al test F nel modello lineare classico per l'ipotesi nulla $H_0 : \beta_j = 0$, con $j = 2, 3, \dots, k$, è dato dal rapporto di verosimiglianza

$$LR = 2[\ell(\hat{\beta}) - \ell(\tilde{\beta})], \quad (20)$$

dove $\ell(\hat{\beta})$ è la funzione log-verosimiglianza valutata in corrispondenza della stima MLE, $\ell(\tilde{\beta})$ è la funzione log-verosimiglianza valutata sotto H_0 nella quale tutti i parametri, esclusa la costante del modello¹⁰, siano posti uguali a zero. Poiché l'ipotesi nulla prevede $(k-1)$ vincoli, la distribuzione del test è $LR \sim \chi^2_{k-1}$.

Sotto H_0 la funzione $\ell(\tilde{\beta})$ non deve essere stimata in quanto può essere agevolmente calcolata attraverso i seguenti passaggi; partendo dalla (14), poiché il vettore dei parametri è vincolato ad essere nullo in tutte le sue componenti ad eccezione di β_1 , si ottiene

$$\ell(\tilde{\beta}) = \sum_{i=1}^N y_i \log F(\beta_1) + (1 - y_i) \log[1 - F(\beta_1)].$$

Dato che $p_i = F(x'_i\beta)$, se tutti i valori di β (ad eccezione della costante) sono nulli risulta che la probabilità stimata di $y_i = 1$ non dipende da x_i quindi $p = F(\beta_1)$. Sostituendo in $\ell(\tilde{\beta})$ si ha

$$\ell(\tilde{\beta}) = \sum_{i=1}^N y_i \log p + (1 - y_i) \log(1 - p).$$

¹⁰In questo caso è implicita l'ipotesi che la prima colonna della matrice X delle le variabili esplicative sia data dal vettore ι_N contenente N elementi pari ad 1.

Tenendo conto che $\sum_{i=1}^N y_i = N_1$, $\sum_{i=1}^N (1 - y_i) = N_0$ e $N = N_1 + N_0$ risulta

$$\begin{aligned}\ell(\tilde{\beta}) &= N_1 \log p + N_0 \log(1 - p) \\ &= N \left[\frac{N_1}{N} \log p + \frac{N_0}{N} \log(1 - p) \right] \\ &= N [p \cdot \log p + (1 - p) \cdot \log(1 - p)].\end{aligned}\tag{21}$$

Un'altra procedura di test molto utile all'interno dei modelli Probit e Logit è il test LM ottenuto partendo dalla condizione (17) sullo score che può essere riscritta nella forma matriciale

$$s(\beta) = X'G\iota_N$$

dove la matrice G è diagonale di dimensione $N \times N$ con i valori g_i disposti lungo la diagonale principale.

La matrice di informazione può essere stimata in modo consistente attraverso il metodo BHHH

$$I(\beta) = \frac{\partial \ell(\beta)'}{\partial \beta} \frac{\partial \ell(\beta)}{\partial \beta} = X'G'GX,$$

dove ovviamente $G' = G$. Il test LM può essere così ottenuto attraverso la statistica

$$\begin{aligned}\text{LM} &= s(\tilde{\beta})'[I(\tilde{\beta})]^{-1}s(\tilde{\beta}) \\ \text{LM} &= \iota_N'G'X(X'G'GX)^{-1}X'G\iota_N \\ \text{LM} &= N \left[\frac{1}{N} \iota_N'G'X(X'G'GX)^{-1}X'G\iota_N \right].\end{aligned}$$

Dato che $N = \iota_N'\iota_N$, il test LM è pari a

$$\text{LM} = NR_\iota^2,\tag{22}$$

cioè N volte l'indice di determinazione non centrato della regressione *Outer Product Gradients* (OPG regression) di ι_N su GX . Questa procedura permette di testare diverse ipotesi sui parametri, non solo quella di azzeramento di tutti i parametri, esclusa la costante; poiché richiede la stima del solo modello vincolato, questo test è molto utile per condurre test di specificazione (soprattutto di variabili omesse) o test di eteroschedasticità. Naturalmente, se H_0 impone q vincoli, il test ha distribuzione $\text{LM} \sim \chi_q^2$.

1.2.4 Bontà di adattamento

Diverse misure di bontà di adattamento sono state proposte per i modelli di scelta binaria; un'ipotesi molto sfruttata in questo contesto è quella introdotta a pag. 8 in base alla quale tutti i coefficienti contenuti nel vettore β sono azzerati ad eccezione della costante. Sotto H_0 la funzione log-verosimiglianza è data dall'equazione (21).

Tutte le misure di bontà di adattamento nei modelli Probit e Logit prevedono l'utilizzo della funzione log-verosimiglianza libera $\ell(\hat{\beta})$ e della log-verosimiglianza vincolata data da $\ell(\tilde{\beta})$.

Pseudo- R^2

$$R^2 = 1 - \frac{1}{1 + 2N[\ell(\hat{\beta}) - \ell(\tilde{\beta})]}\tag{23}$$

I casi estremi di quest'indice indicano che, quando nel modello libero i coefficienti stimati sono nulli, log-verosimiglianza libera e vincolata coincidono, quindi lo pseudo- R^2 è nullo. Viceversa, quando c'è perfetto adattamento, $\hat{p}_i = y_i$ quindi $F(x_i'\hat{\beta}) = y_i$ per ogni $i \in [1, N]$. Sostituendo questo risultato nella (14) si ottiene immediatamente che $\ell(\hat{\beta}) = 0$. Dato che per definizione $\ell(\hat{\beta}) \geq \ell(\tilde{\beta})$, ciò significa che la log-verosimiglianza è negativa, quindi lo pseudo- R^2 diventa

$$R^2 = 1 - \frac{1}{1 - 2N\ell(\tilde{\beta})}$$

ed è sempre minore di 1. In definitiva $R^2 \in [0, 1)$.

R^2 di McFadden

$$R^2 = 1 - \frac{\ell(\hat{\beta})}{\ell(\tilde{\beta})} \quad (24)$$

In questo caso $R^2 \in [0, 1]$ (l'estremo superiore è incluso) poiché se le due log-verosimiglianze coincidono l'indice è nullo, mentre nel caso di perfetto adattamento è nulla solo la log-verosimiglianza libera, quindi l'indice è pari a 1.

R^2 di previsione

Questo indice mette a confronto le previsioni corrette con quelle non corrette. Una previsione è definita corretta se risulta

$$\begin{aligned} \text{-se } y_i = 1 &\Rightarrow F(x'_i \hat{\beta}) > 0.5 \Rightarrow x'_i \hat{\beta} > 0 \\ \text{-se } y_i = 0 &\Rightarrow F(x'_i \hat{\beta}) \leq 0.5 \Rightarrow x'_i \hat{\beta} \leq 0. \end{aligned}$$

Nel caso del modello vincolato, la migliore previsione è fornita da

$$\begin{aligned} \text{-se } y_i = 1 &\Rightarrow \frac{N_1}{N} > 0.5 \\ \text{-se } y_i = 0 &\Rightarrow \frac{N_0}{N} \leq 0.5. \end{aligned}$$

L'errore di previsione è perciò definito nel modello libero come

$$\widehat{EP} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2,$$

mentre in quello vincolato è

$$\widetilde{EP} = \begin{cases} 1 - \hat{p} & \text{se } \hat{p} > 0.5 \\ \hat{p} & \text{se } \hat{p} \leq 0.5. \end{cases}$$

In questo caso $\widetilde{EP} \leq 0.5$ per definizione. L'indice di bontà di adattamento è analogo all' R^2 di McFadden, ma utilizza l'errore di previsione, quindi

$$R^2 = 1 - \frac{\widehat{EP}}{\widetilde{EP}} \quad (25)$$

Nel caso di perfetto adattamento \widehat{EP} è ovviamente nullo quindi l'indice assume valore massimo pari ad 1. Il problema sorge quando si cerca un valore minimo per R^2 , in quanto può accadere che $\widehat{EP} > \widetilde{EP}$, interpretabile come una migliore previsione da parte del modello vincolato rispetto a quella ottenibile dal modello libero: questa affermazione è naturalmente insostenibile dato che nel modello vincolato molte variabili esplicative sono escluse. In questo caso l'indice assume valori negativi quindi, nella pratica, è perciò auspicabile ottenere almeno un valore positivo per tale indice.

1.2.5 Giustificazione teorica

Dal punto di vista teorico i modelli Probit e Logit possono essere giustificati in base a due principi differenti.

A) Massimizzazione di una funzione di utilità

Ipotesi:

1. U_i^0 e U_i^1 sono le funzioni di utilità per l' i -esimo individuo per l'alternativa binaria 1 o 0,
2. ciascuna funzione di utilità è composta da una parte sistematica ed una casuale, cioè $U_i^j = S_i^j + \varepsilon_i^j$,

3. l'individuo sceglie l'alternativa $j = 1$ se e solo se $U_i^1 > U_i^0$.

Date queste ipotesi si ottiene:

$$\begin{aligned} Pr(y_i = 1) &= Pr(U_i^1 > U_i^0) \\ &= Pr(S_i^1 + \varepsilon_i^1 > S_i^0 + \varepsilon_i^0) \\ &= Pr(\varepsilon_i^0 - \varepsilon_i^1 < S_i^1 - S_i^0) \\ &= F(S_i^1 - S_i^0) \end{aligned}$$

Si ottengono i modelli Probit e Logit semplicemente assumendo che la differenza $(\varepsilon_i^0 - \varepsilon_i^1)$ abbia distribuzione normale oppure logistica. Se tale differenza ha varianza pari a σ^2 , l'espressione di cui sopra diventa

$$Pr(y_i = 1) = F\left(\frac{S_i^1 - S_i^0}{\sigma}\right).$$

Ovviamente, specificando la componente sistematica come $S_i^j = (x_i^j)' \beta^*$, si ottiene

$$\begin{aligned} Pr(y_i = 1) &= Pr\left(\frac{(x_i^1 - x_i^0)' \beta^*}{\sigma}\right) \\ &= Pr\left(\frac{x_i^1 \beta^*}{\sigma}\right) \\ &= Pr(x_i^1 \beta), \end{aligned}$$

formulazione nella quale risulta evidente il fatto che i parametri contenuti in β non possono essere stimati separatamente da σ . Occorre perciò un vincolo di normalizzazione da imporre al parametro della varianza dell'errore in modo da avere esatta identificazione.

B) Variabile latente

Ipotesi:

1. esiste una variabile latente y_i^* non osservabile,
2. la variabile y_i è osservabile e può assumere solo i valori 0 e 1,
3. esiste una soglia c tale per cui si osservano

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

4. $y_i^* = (x_i^1 - x_i^0)' \beta^* + (\varepsilon_i^1 - \varepsilon_i^0) = x_i^1 \beta + \varepsilon_i$

Date queste ipotesi si ha

$$\begin{aligned} Pr(y_i = 1) &= Pr(y_i^* > c) \\ &= Pr(y_i^* - x_i^1 \beta^* > c - x_i^1 \beta^*) \\ &= Pr(\varepsilon_i > c - x_i^1 \beta^*) \\ &= Pr\left(\frac{\varepsilon_i}{\sigma} > \frac{c - x_i^1 \beta^*}{\sigma}\right) \\ &= 1 - Pr\left(\frac{\varepsilon_i}{\sigma} < \frac{c - x_i^1 \beta^*}{\sigma}\right) \\ &= 1 - F\left(\frac{c - x_i^1 \beta^*}{\sigma}\right) \\ &= F\left(\frac{x_i^1 \beta^* - c}{\sigma}\right) \\ &= F(x_i^1 \beta - C), \end{aligned}$$

dove $\beta = \beta^*/\sigma$ e $C = c/\sigma$. In questo caso i parametri contenuti in β non possono essere stimati separatamente da σ e da c , quindi si possono fissare $\sigma = 1$ e $c = 0$ per ottenere l'equazione analoga alle espressioni (6) e (7). Tale imposizione garantisce l'identificazione del modello e non determina alcuna perdita di generalità in quanto la stima di β mantiene β^* e σ sempre nella stessa proporzione. Infine, se il modello contiene una costante ($\alpha = \beta_1$), anche la scelta di $c = 0$ non produce alcun effetto sulle stime: ponendo $c = c_0$ infatti si può definire una nuova costante pari ad $\alpha - c_0/\sigma$ e stimare un modello nelle stesse condizioni in cui C è nullo.

Questo scenario è identico a quello basato sull'approccio della massimizzazione dell'utilità: se $c = 0$ infatti basta definire la variabile latente come $y_i^* = U_i^1 - U_i^0$. Quando $U_i^1 > U_i^0 \Rightarrow y_i^* > 0$ e si osserva $y_i = 1$ mentre, quando $U_i^1 \leq U_i^0 \Rightarrow y_i^* \leq 0$, e in questo caso si osserva $y_i = 0$.