

Modelli di previsione per variabili dipendenti binarie.

Le variabili risposta di tipo binario presentano una codifica corrispondente a «1», successo, e «0», insuccesso. Un vettore n di risposte casuali e indipendenti dicotomiche potrebbe essere il seguente:

$$\mathbf{y} = \begin{bmatrix} 0 \\ 1 \\ \vdots \\ 1 \end{bmatrix}$$

nel quale, ciascuna risposta segue una medesima distribuzione bernoulliana, $\Omega = \{0; 1\}$, con probabilità di «1» pari a p e probabilità di «0» pari a $1 - p$:

$$\begin{aligned} P(y_i = 1) &= p; \\ P(y_i = 0) &= 1 - p. \end{aligned}$$

Possiamo riscrivere la probabilità associata a ciascuna generica osservazione y_i nei termini di:

$$P(y_i) = p^{y_i}(1 - p)^{1 - y_i}, \text{ con } y_i = 0, 1. \quad \text{Eq. 35}$$

Avremo quindi per

$$\begin{aligned} y_i = 1, \quad P(y_i) &= p^1(1 - p)^0 = p; \\ y_i = 0, \quad P(y_i) &= p^0(1 - p)^1 = (1 - p). \end{aligned}$$

Scriviamo ora la funzione di probabilità di massa per le nostre n osservazioni (...la nostra funzione di verosimiglianza), che sarà proporzionale al prodotto di n funzioni di Bernoulli (Eq. 35):

$$\begin{aligned} L(p; y_i) &= \prod_{i=1}^n p^{y_i}(1 - p)^{1 - y_i} \\ &= \prod_{i=1}^n \frac{p^{y_i}(1 - p)^1}{(1 - p)^{y_i}} \\ &= \prod_{i=1}^n \frac{p^{y_i}}{(1 - p)^{y_i}}(1 - p) \\ &= \left[\frac{p}{(1 - p)} \right]^{\sum_{i=1}^n y_i} \prod_{i=1}^n (1 - p) \end{aligned}$$

che si può riscrivere come

$$\begin{aligned} L(p; y_i) &= \exp \left\{ \ln \left[\frac{p}{(1 - p)} \right]^{\sum_{i=1}^n y_i} \prod_{i=1}^n (1 - p) \right\} \\ &= \exp \left\{ \sum_{i=1}^n y_i \ln \left[\frac{p}{(1 - p)} \right] \right\} \prod_{i=1}^n (1 - p) \end{aligned} \quad \text{Eq. 36}$$

Prendendo il logaritmo naturale, (log-Verosimiglianza)

$$\begin{aligned} l(p; y_i) &= \sum_{i=1}^n y_i \ln \left[\frac{p}{(1 - p)} \right] + \sum_{i=1}^n \ln(1 - p) \\ &= \sum_{i=1}^n \left[y_i \ln \left[\frac{p}{(1 - p)} \right] + \ln(1 - p) \right] \end{aligned} \quad \text{Eq. 37}$$

Assumiamo l'esistenza di un'associazione statistica tra la risposta binaria y_i ed una covariata x_i , che ci aiuta a ridefinire la previsione dell'esito di successo o insuccesso, dati i valori di x_i :

$$y = \begin{bmatrix} 0 \\ 0 \\ 1 \\ \vdots \\ 1 \end{bmatrix}, \mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ \vdots \\ x_n \end{bmatrix}.$$

In questo caso, la probabilità associata a ciascuna osservazione y_i sarà **condizionata** alla conoscenza del valore in x_i , secondo i parametri β_j di un **adeguato modello statistico**. Formalmente, possiamo scrivere che:

$$P(y_i = 1) = p(y_i = 1 | x_i, \beta_j);$$

$$P(y_i = 0) = 1 - p(y_i = 1 | x_i, \beta_j).$$

La log-Verosimiglianza per n osservazioni casuali indipendenti, identicamente distribuite secondo una funzione di Bernoulli, può quindi essere riscritta come

$$l(\beta_j; y_i, x_i) =$$

$$= \sum_{i=1}^n \left[y_i \ln \left[\frac{p(y_i = 1 | x_i, \beta_j)}{1 - p(y_i = 1 | x_i, \beta_j)} \right] + \ln(1 - p(y_i = 1 | x_i, \beta_i)) \right]$$

Eq. 38

Modello lineare di probabilità.

Potremmo usare una funzione di regressione lineare per specificare le probabilità degli esiti y_i .

- Si costruisce la variabile binaria y_i definita come:

$$y_i = \begin{cases} 1 & \text{se si realizza un evento "successo"} \\ 0 & \text{altrimenti (insuccesso)} \end{cases},$$

e si suppone che il suo valore atteso sia una funzione lineare di una variabile esplicativa:

$$E(y_i | x_i, \beta_j) = \alpha + \beta x_i. \quad \text{Eq. 39}$$

- Poiché la variabile casuale y_i può assumere soltanto due valori [0,1], e ricordando la formula del valore atteso di una variabile aleatoria discreta

$$E(y_i) = \sum_{i=1}^n y_i p_i,$$

si ha che

$$E(y_i | x_i, \beta_j) = 1 \times p(y_i = 1 | x_i, \beta_j) + 0 \times p(y_i = 0 | x_i, \beta_j)$$

$$= p(y_i = 1 | x_i, \beta_j). \quad \text{Eq. 40}$$

- Per l' Eq. 39, si ha quindi che la probabilità subordinata di successo è una funzione lineare della variabile esplicativa (*modello lineare di probabilità*), cioè

$$E(y_i | x_i, \beta_j) = p(y_i = 1 | x_i, \beta_j) = \alpha + \beta x_i. \quad \text{Eq. 41}$$

Modello lineare di probabilità.

- Facile da stimare applicando i minimi quadrati ordinari
- I suoi parametri β_j possono essere direttamente interpretati come gli effetti marginali delle variabili esplicative sulla variabile risposta dicotomica.
- Produce una buona approssimazione delle osservazioni quando le osservazioni sulle variabili esplicative sono vicine alla loro media.
- L'errore di previsione ε_i non ha una distribuzione normale attorno alla retta di regressione, bensì una distribuzione bernoulliana che può assumere soltanto due valori:

$$\varepsilon_i = y_i - E(y_i|x_i, \beta_j) =$$

$$= \begin{cases} 1 - (\alpha + \beta x_i) & \text{quando } y_i = 1 \\ 0 - (\alpha + \beta x_i) & \text{quando } y_i = 0' \end{cases}$$

con probabilità

$$P(\varepsilon_i = 1 - (\alpha + \beta x_i)) = \alpha + \beta x_i;$$

$$P(\varepsilon_i = -(\alpha + \beta x_i)) = 1 - (\alpha + \beta x_i).$$

Sulla base di queste probabilità si possono calcolare il valore atteso e la varianza della variabile aleatoria ε_i :

$$E(\varepsilon_i) = [1 - (\alpha + \beta x_i)](\alpha + \beta x_i) +$$

$$-(\alpha + \beta x_i)[1 - (\alpha + \beta x_i)] = 0$$

Eq. 42

Modello lineare di probabilità.

$$\begin{aligned} Var(\varepsilon_i) &= [1 - (\alpha + \beta x_i)]^2 (\alpha + \beta x_i) + \\ &\quad - (\alpha + \beta x_i)^2 [1 - (\alpha + \beta x_i)] \end{aligned}$$

Rinomiamo per semplicità la quantità $\alpha + \beta x_i$,

$$\begin{aligned} Var(\varepsilon_i) &= \left[\underbrace{1 - (\alpha + \beta x_i)}_a \right]^2 (\alpha + \beta x_i) + \\ &\quad - \underbrace{(\alpha + \beta x_i)}_a^2 \left[\underbrace{1 - (\alpha + \beta x_i)}_a \right] \end{aligned}$$

riscrivendo la varianza dell'errore come:

$$Var(\varepsilon_i) = (1 + a^2 - 2a)a + a^2(1 - a)$$

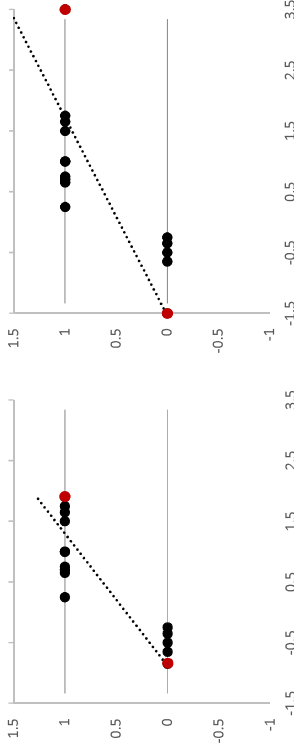
$$= a + a^3 - 2a^2 + a^2 - a^3$$

$$= a - a^2 = (\alpha + \beta x_i)[1 - (\alpha + \beta x_i)].$$

Eq. 43


Quindi, se da un lato l'errore è indipendente in media dalle variabili esplicative (**Eq. 42**), la sua varianza non è unica e costante bensì dipende dallo specifico valore di x_i (**Eq. 43, eteroschedasticità**).

- Il modello lineare di probabilità non produce (automaticamente) un valore di probabilità vincolato all'intervallo [0, 1], soprattutto per osservazioni x_i lontane dalla media (Vedi figura successiva).



Modello lineare di probabilità.

La retta tratteggiata in figura rappresenta la funzione di regressione stimata; le rette parallele all'asse delle ascisse sono quelle in cui cadono le coppie di osservazioni (x_i, y_i) , rappresentate dai punti in nero. Da notare come il modello lineare per la probabilità sia estremamente suscettibile alle osservazioni in x_i lontane dalla media (vedi punti in rosso).





Modello NON lineare di probabilità.

Per superare gli inconvenienti connessi al modello di probabilità lineare è conveniente considerare una funzione che fornisca un valore ammissibile di $p(y_i = 1|x_i, \beta_j)$ per tutti i possibili valori delle variabili esplicative.

Modello Logit (di regressione logistica).

Nel modello *logit* la probabilità dell'evento «successo», condizionatamente a x_i , viene scritta come

$$p(y_i = 1 | x_i, \beta_j) = \frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}}, \quad \text{Eq. 44}$$



detta *funzione di ripartizione logistica*, dalla quale otteniamo le due quantità fondamentali:

1. Complemento ad 1 della Eq. 44,

$$\begin{aligned} 1 - p(y_i = 1 | x_i, \beta_j) &= \\ &= \frac{1 + \exp\{\alpha + \beta x_i\} - \exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} \\ &= \frac{1}{1 + \exp\{\alpha + \beta x_i\}} \end{aligned} \quad \text{Eq. 45}$$

2. Logaritmo del rapporto delle probabilità, per dato x_i ,

$$\begin{aligned} \underbrace{\ln \left[\frac{p(y_i = 1|x_i, \beta_j)}{1 - p(y_i = 1|x_i, \beta_j)} \right]}_{\text{LOGIT}} &= \ln \left[\frac{\frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}}}{\frac{1}{1 + \exp\{\alpha + \beta x_i\}}} \right] = \\ &= \ln[\exp\{\alpha + \beta x_i\}] = \alpha + \beta x_i \end{aligned} \quad \text{Eq. 46}$$

da cui si individuano le peculiarità del modello *logit*: è il **logit che dipende linearmente dalle variabili esplicative e non la probabilità come nel caso del modello di probabilità lineare**. La quantità dentro alla parentesi (rapporto di probabilità, *odds*)

$$\frac{p(y_i = 1|x_i, \beta_j)}{1 - p(y_i = 1|x_i, \beta_j)} = \frac{p(y_i = 1|x_i, \beta_j)}{p(y_i = 0|x_i, \beta_j)}$$

definisce una sorta di pronostico in favore di una determinata «scelta». Se, ad esempio,

$$p(y_i = 1|x_i, \beta_j) = .25,$$

allora il pronostico è .333, cioè

$$\frac{p(y_i = 1|x_i, \beta_j)}{p(y_i = 0|x_i, \beta_j)} = \frac{.25}{.75} = \frac{1}{3}$$

3 a 1 in favore dell'evento $y_i = 0$.

Se, ad esempio, $p(y_i = 1|x_i, \beta_j) = .50$, allora il pronostico è 1, cioè «parità» di scelta tra 1 e 0:

$$\frac{p(y_i = 1|x_i, \beta_j)}{p(y_i = 0|x_i, \beta_j)} = \frac{.50}{.50} = 1.$$

Se, ad esempio, $p(y_i = 1|x_i, \beta_j) = .75$, allora il pronostico è 3, cioè

$$\frac{p(y_i = 1|x_i, \beta_j)}{p(y_i = 0|x_i, \beta_j)} = \frac{.75}{.25} = 3$$

3 a 1 in favore dell'evento $y_i = 1$.

Come si interpretano quindi α e β ?

Interpretazione fondamentale di β

Il pronostico a favore di $y_i = 1$ si modifica moltiplicativamente di $\exp\{\beta\}$ per ciascun incremento unitario in x_i .

Per $x_i = 0$ (o valore medio, se centrata), l'Eq. 46 diventa:

$$\frac{p(y_i = 1|x_i = 0)}{1 - p(y_i = 1|x_i = 0)} = \exp\{\alpha + \beta \cdot 0\} = \exp\{\alpha\},$$

Per un incremento unitario in x_i abbiamo che

$$\frac{p(y_i = 1|x_i = 1)}{1 - p(y_i = 1|x_i = 1)} = \exp\{\alpha + \beta\} = \exp\{\alpha\} \cdot \exp\{\beta\}.$$

Cosa succede al pronostico quando x_i passa a $x_i + 1$?
In corrispondenza di x_i

$$\frac{p(y_i = 1|x_i, \beta_j)}{p(y_i = 0|x_i, \beta_j)} = \exp\{\alpha\} \cdot \exp\{\beta\}^{x_i}.$$

In corrispondenza di $x_i + 1$

$$\frac{p(y_i = 1|x_i + 1, \beta_j)}{p(y_i = 0|x_i + 1, \beta_j)} = \exp\{\alpha\} \cdot \exp\{\beta\}^{x_i+1}$$

$$= \exp\{\alpha\} \cdot \exp\{\beta\}^{x_i} \cdot \exp\{\beta\}^1$$

$$= \frac{p(y_i = 1|x_i, \beta_j)}{p(y_i = 0|x_i, \beta_j)} \exp\{\beta\}$$

$\exp\{\beta\}$ è un odds ratio.

$$\frac{p(y_i = 1|x_i + 1, \beta_j)}{p(y_i = 0|x_i + 1, \beta_j)} = \exp\{\beta\} \quad \text{Eq. 47}$$

$$\frac{p(y_i = 1|x_i, \beta_j)}{p(y_i = 0|x_i, \beta_j)}$$

$$\beta = 0.693147 \quad \exp(\beta) = 2 = \frac{2}{\frac{1}{1}}$$

Con beta **positivo**, il pronostico a favore di $y_i = 1$ aumenta (raddoppia) ad ogni incremento unitario in x_i ;

$$\beta = -0.693147 \quad \exp(\beta) = 1/2 = \frac{1}{\frac{2}{1}}$$

Con beta **negativo**, il pronostico a favore di $y_i = 1$ diminuisce (dimezza) ad ogni incremento unitario in x_i ;

Modello Logit (stima dei parametri).

Non ci rimane che stimare i parametri ignoti del modello mediante MLE, non prima di aver introdotto tre nuove regole di derivazione, i cui risultati ci consentono di ricavare velocemente le derivate prime e seconde della funzione di log-Verosimiglianza, nei parametri ignoti del modello logit. (vedi Appendice alla lezione).

Funzione di log-Verosimiglianza:

Riscriviamo l' Eq. 38 inserendo le due quantità fondamentali derivanti dall'espressione della probabilità condizionata di successo nei termini della funzione di ripartizione logistica (Eq. 45, 46):

$$l(\beta_j; y_i, x_i) = \sum_{i=1}^n [y_i(\alpha + \beta x_i) + \ln \left[\frac{1}{1 + \exp\{\alpha + \beta x_i\}} \right]]$$

$$= \sum_{i=1}^n [y_i(\alpha + \beta x_i) - \ln(1 + \exp\{\alpha + \beta x_i\})]. \quad \text{Eq. 48}$$

Derivate prime parziali [vedi Eq. A.1-A.4]:

$$\frac{\partial l(\beta_j; y_i, x_i)}{\partial \alpha} = \sum_{i=1}^n [y_i - p(y_i = 1|x_i, \beta_i)] \quad \text{Eq. 49}$$

$$\frac{\partial l(\beta_j; y_i, x_i)}{\partial \beta} = \sum_{i=1}^n [y_i x_i - p(y_i = 1|x_i, \beta_i) x_i] \quad \text{Eq. 50}$$

Derivate seconde parziali e cross- parziali[vedi A.5 e A.6]:

$$\begin{aligned} \frac{\partial^2 l(\beta_j; y_i, x_i)}{\partial \alpha^2} &= \frac{d}{d\alpha} \sum_{i=1}^n [y_i - p(y_i = 1 | x_i, \beta_i)] \\ &= - \sum_{i=1}^n \frac{d}{d\alpha} \left[\frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} \right] \\ &= - \sum_{i=1}^n p(y_i = 1 | x_i, \beta_i) [1 - p(y_i = 1 | x_i, \beta_i)] \end{aligned} \quad \text{Eq. 51}$$

$$\begin{aligned} \frac{\partial^2 l(\beta_j; y_i, x_i)}{\partial \beta^2} &= \frac{dy}{d\beta} \sum_{i=1}^n [y_i x_i - p(y_i = 1 | x_i, \beta_i) x_i] \\ &= - \sum_{i=1}^n x_i \frac{dy}{d\beta} \left[\frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} \right] \\ &= - \sum_{i=1}^n x_i^2 p(y_i = 1 | x_i, \beta_i) [1 - p(y_i = 1 | x_i, \beta_i)] \end{aligned} \quad \text{Eq. 52}$$

$$\begin{aligned} \frac{\partial^2 l(\beta_j; y_i, x_i)}{\partial \alpha \beta} &= \frac{dy}{d\beta} \sum_{i=1}^n [y_i - p(y_i = 1 | x_i, \beta_i)] \\ &= - \sum_{i=1}^n \frac{dy}{d\beta} \left[\frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} \right] \\ &= - \sum_{i=1}^n x_i p(y_i = 1 | x_i, \beta_i) [1 - p(y_i = 1 | x_i, \beta_i)] \end{aligned} \quad \text{Eq. 53}$$

Derivate seconde parziali tutte di segno negativo (la funzione di Verosimiglianza va massimizzata).

Vettore derivate prime

$$\begin{aligned} \mathbf{u} &= \begin{bmatrix} \frac{\partial l(\beta_j; y_i, x_i)}{\partial \alpha} \\ \frac{\partial l(\beta_j; y_i, x_i)}{\partial \beta} \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n [y_i - p(y_i = 1 | x_i, \beta_i)] \\ \sum_{i=1}^n x_i [y_i - p(y_i = 1 | x_i, \beta_i)] \end{bmatrix} \\ &= \begin{bmatrix} \sum_{i=1}^n \left[y_i - \frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} \right] \\ \sum_{i=1}^n \left[x_i \left[y_i - \frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} \right] \right] \end{bmatrix} \end{aligned}$$

Trattasi di equazioni esponenziali, in cui l'incognita compare come esponente, quindi, non riconducibile ad un polinomio uguagliato a zero. La soluzione di massima verosimiglianza ($\mathbf{u} = \mathbf{0}$) andrà cercata per approssimazione del risultato secondo i metodi iterativi che abbiamo visto.

In termini matriciali,

$$\mathbf{X}'(\mathbf{y} - \mathbf{p}) = \underbrace{\begin{bmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_n \end{bmatrix}}_{2 \times n} \underbrace{\begin{bmatrix} y_1 - p(y_1 = 1 | x_1, \beta_1) \\ y_2 - p(y_2 = 1 | x_2, \beta_2) \\ \vdots \\ y_n - p(y_n = 1 | x_n, \beta_n) \end{bmatrix}}_{n \times 1} = \mathbf{u} \quad \text{Eq. 54}$$

Dove \mathbf{X}' è la matrice del modello lineare che abbiamo già visto, \mathbf{y} è il vettore di risposte binarie osservate, e \mathbf{p} è il vettore di valori previsti di probabilità di successo, secondo la funzione di ripartizione logistica.

Appendice alla lezione

Regola generale della derivazione di funzioni composte o **Chain Rule**:

$$\frac{d}{dx} f[g(x)] = \frac{d}{dg} f[g] \cdot \frac{d}{dx} g(x),$$

$$\text{così } \frac{d}{dx} (x^2 + 1)^3 = \frac{d}{d(x^2+1)} (x^2 + 1)^3 \cdot \frac{d}{dx} (x^2 + 1) = 3(x^2 + 1)^2 \cdot 2x.$$

$$\frac{d}{dx} \exp\{f(x)\} = \exp\{f(x)\} \cdot \frac{d}{dx} f(x),$$

Ad esempio,

$$\frac{d}{d\alpha} \exp\{\alpha + \beta x_i\} = \exp\{\alpha + \beta x_i\} \cdot \frac{d}{d\alpha} (\alpha + \beta x_i) = \exp\{\alpha + \beta x_i\} (1\alpha^0)$$

Eq. A.1

$$\frac{d}{d\beta} \exp\{\alpha + \beta x_i\} = \exp\{\alpha + \beta x_i\} \cdot \frac{d}{d\beta} (\alpha + \beta x_i) = \exp\{\alpha + \beta x_i\} (x_i 1\beta^0)$$

Eq. A.2

$$\frac{d}{dx} \ln[f(x)] = \frac{1}{f(x)} \cdot \frac{d}{dx} f(x),$$

Ad esempio,

$$\frac{d}{d\alpha} \ln[1 + \exp\{\alpha + \beta x_i\}] = \frac{1}{1 + \exp\{\alpha + \beta x_i\}} \cdot \frac{d}{d\alpha} (1 + \exp\{\alpha + \beta x_i\})$$

$$= \frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} = p(y_i = 1|x_i, \beta_i)$$

Eq. A.3

$$\frac{d}{d\beta} \ln[1 + \exp\{\alpha + \beta x_i\}] = \frac{1}{1 + \exp\{\alpha + \beta x_i\}} \cdot \frac{d}{d\beta} (1 + \exp\{\alpha + \beta x_i\})$$

$$= \frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} x_i = p(y_i = 1|x_i, \beta_i) x_i$$

Eq. A.4

$$\frac{d}{dx} \left[\frac{g(x)}{h(x)} \right] = \frac{\left[\frac{d}{dx} g(x) \right] h(x) - \left[\frac{d}{dx} h(x) \right] g(x)}{h(x)^2},$$

Ad esempio,

$$\frac{d}{d\alpha} \left[\frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} \right] = ? \quad \frac{d}{d\beta} \left[\frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} \right] = ?$$

Appendice alla lezione

$$= \frac{\frac{d}{d\alpha} \exp\{\alpha + \beta x_i\} (1 + \exp\{\alpha + \beta x_i\}) - \left[\frac{d}{d\alpha} (1 + \exp\{\alpha + \beta x_i\}) \right] \exp\{\alpha + \beta x_i\}}{(1 + \exp\{\alpha + \beta x_i\})^2}$$

Applicando la **Eq. A.1**

$$= \frac{\exp\{\alpha + \beta x_i\} \cdot (1 + \exp\{\alpha + \beta x_i\}) - \exp\{\alpha + \beta x_i\} \cdot \exp\{\alpha + \beta x_i\}}{(1 + \exp\{\alpha + \beta x_i\})^2}$$

$$= \frac{\exp\{\alpha + \beta x_i\} + \exp\{\alpha + \beta x_i\}^2 - \exp\{\alpha + \beta x_i\}^2}{(1 + \exp\{\alpha + \beta x_i\})^2}$$

$$= \frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}}$$

$$= p(y_i = 1|x_i, \beta_i) \cdot [1 - p(y_i = 1|x_i, \beta_i)]$$

Eq. A.5

$$\frac{d}{d\beta} \left[\frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} \right] =$$

$$= \frac{\left[\frac{d}{d\beta} \exp\{\alpha + \beta x_i\} \right] (1 + \exp\{\alpha + \beta x_i\}) - \left[\frac{d}{d\beta} (1 + \exp\{\alpha + \beta x_i\}) \right] \exp\{\alpha + \beta x_i\}}{(1 + \exp\{\alpha + \beta x_i\})^2}$$

Applicando la **Eq. A.2**

$$= \frac{\exp\{\alpha + \beta x_i\} x_i \cdot (1 + \exp\{\alpha + \beta x_i\}) - \exp\{\alpha + \beta x_i\} x_i \cdot \exp\{\alpha + \beta x_i\}}{(1 + \exp\{\alpha + \beta x_i\})^2}$$

$$= \frac{\exp\{\alpha + \beta x_i\} x_i - \exp\{\alpha + \beta x_i\}^2 x_i}{(1 + \exp\{\alpha + \beta x_i\})^2}$$

$$= x_i \frac{\exp\{\alpha + \beta x_i\}}{1 + \exp\{\alpha + \beta x_i\}} \cdot \frac{1}{1 + \exp\{\alpha + \beta x_i\}}$$

$$= x_i \cdot p(y_i = 1|x_i, \beta_i) \cdot [1 - p(y_i = 1|x_i, \beta_i)]$$

Eq. A.6