

# Επιβάρυνση των συντελεστών β

142B

Στο logistic παράδειγμα έχουμε:

$$\log \frac{P}{1-P} = \beta_0 + \beta_1 X_1 + \beta_2 X_2$$

↳ αύξηση κατά 1 του  $X_2 \rightarrow$  αύξηση του  $\log \frac{P}{1-P}$  κατά  $\beta_2$  (απόλυτος)

↳  $\frac{P}{1-P} = \exp\{\beta_0 + \beta_1 X_1 + \beta_2 X_2\} \rightarrow$  αύξηση του  $\frac{P}{1-P}$  κατά  $e^{\beta_2}$  (συν/κός).

$$P = \frac{e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2}}{1 + e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2}} \rightarrow \frac{\partial P}{\partial X_2} = P \cdot (1-P) \beta_2$$

Συνεπώς, η μεταβολή στη  $X_2$  επιφέρει λογαριθμική μεταβολή στη πιθανότητα να  $P$  κατά ένα 0.5 κατά ένα ή να  $X_2$  κατά ένα ή να  $X_2$ .

↳ Με άλλα λόγια,  $P = P(X)$  είναι αντίστροφο του  $X$ .

$$\text{Ορίζεται: odds}(X) = \frac{P(X)}{1-P(X)} \rightarrow \log(\text{odds}(X)) = \beta_0 + \beta_1 X$$

$$\text{Αν: } X \rightarrow X+1 \text{ τότε } \rightarrow \text{odds}(X) = e^{\beta_0 + \beta_1 X}$$
$$\rightarrow \text{odds}(X+1) = e^{\beta_0 + \beta_1 (X+1)} = \text{odds}(X) \cdot e^{\beta_1}$$

$$\text{Ορίζεται: } \text{odds}(\text{ratio}) = e^{\beta_1} \text{ και}$$

$$\log(\text{odds}(\text{ratio})) = \log \frac{\text{odds}(X+1)}{\text{odds}(X)} = \beta_1$$

Onote:  $\frac{\text{odds}(x+1) - \text{odds}(x)}{\text{odds}(x)} = e^b - 1 \approx b$

odno do opisanja u poglavlju:

$$e^b \approx 1 + b$$

# Διασπορά Δεδομένων (Binary data)

$y$ : εμφάνιση ή απουσία

$y_1, y_2, \dots, y_n$  κωδ. παρατηρήσεις από  $y_1, y_2, \dots, y_n$

και:

$y_i$ : αριθμός επιτυχιών σε  $N_i$  δοκιμές με πιθανότητα  $P_i$

Ορισμός:  $y_i = \sum_{j=1}^{N_i} Z_{ij}$  όπου:  $Z_{ij} = \begin{cases} 1, & \text{if ind. } P_i \\ 0, & \text{if ind. } 1-P_i \end{cases}$

Συνάρτηση:  $f_Y(y; N, P) = \binom{N}{y} P^y \cdot (1-P)^{N-y}$

με:  $E(Y) = NP$  και  $V(Y) = NP(1-P)$

↳ Για κάθε  $i$  παρατηρήσει ένα διάνυσμα αποτελεσμάτων. Παράδειγμα  
'Ετσι έχουμε:  $x_i = \begin{pmatrix} x_{i1} \\ \vdots \\ x_{ik} \end{pmatrix}$

## α) Δεδομένα των δοκιμών

	$y_i$	$x_1$	...	$x_k$	} Σε αυτή τη περίπτωση (των δοκιμών) έχουμε $N_i = 1$ . Συνάρτηση Bernoulli data
δοκιμή 1 :	1	---	---	---	
δοκιμή 2 :	0	---	---	---	
⋮	⋮	⋮	⋮	⋮	
⋮	⋮	⋮	⋮	⋮	



6) κατά συνδυασμό των ανεξάρτητων β.β.

Εξάφ.

$y_i$	$N_i$	$x_1$	...	$x_k$
1	2	...	...	...
3	5	...	...	...
⋮	⋮	⋮	⋮	⋮

Όλοι οι πιθανοί συνδυασμοί των ανεξ. παραβλητών.  
Συνολός: Διωνομικός  $\mathcal{F}$ -σώμα

↳ Η καλύτερη απεικόνιση ~~από~~ της των κλάσεων των ανεξ. των παραβλητών (απ. απεικόνιση -  $\mathcal{F}$  από τις β.β.  $x_1, \dots, x_k$  σε μια κλάση  $i$  για μια β.β.  $x_1, \dots, x_k$ )

↳ Δε μπορεί να χρησιμοποιηθεί για συνολικό  $\mathcal{F}$ -σώμα (ανεξ. παραβλητές).

↳ Ζητάμε λοιπόν μια σέση καλύτερα από  $P_i$  και  $X_i$ 's

↳ Παίρνουμε τον λογαριθμικό των "odds"

$$\text{αρχ: } \logit(P_i) = \log \frac{P_i}{1-P_i} = \sum_i x_i \beta \in (-\infty, +\infty)$$

$$\underbrace{\hspace{10em}}_{g(P_i)}$$

# Συνεργατικότητα

Onoee:  $f(y_i; p_i) \propto p_i^{y_i} (1-p_i)^{N_i-y_i}$

Log-likelihood.

$$\log f(y; p_i) = \sum_{i=1}^n y_i \log(p_i) + (N_i - y_i) \log(1-p_i)$$

H ποσότητα αυτή (για ορισμένο i) αυτής  
είναι ΕΟΚ ή κανονική παρατήρηση

$$\theta_i = \log \frac{p_i}{1-p_i} \quad \text{και} \quad b(\theta_i) = \log(1 + e^{\theta_i}) \cdot N_i$$

Άρα  $p_i = E(Y_i) = b'(\theta_i) = N_i \frac{e^{\theta_i}}{1 + e^{\theta_i}} = N_i p_i$

και κανονικό link:  $g(\mu) = b'^{-1}(p_i) = \log \frac{p_i}{1-p_i}$

↳ Εντάξει και  $\hat{\theta}$  ή Fisher's Scoring

↳ Εντάξει και  $\hat{V}(\hat{\theta})$  για Ε.Υ. / Δ.Ε.



# Deviance

146

$$L_{os} = 2 \cdot \sum_{i=1}^n \frac{y_i (\hat{\theta}_i^{(s)} - \hat{\theta}_i^{(0)}) - (b(\hat{\theta}_i^{(s)}) - b(\hat{\theta}_i^{(0)}))}{a(\eta_i)}$$

know:  $\theta_i = \log \frac{p_i}{1-p_i}$ ,  $a(\eta_i) = 1$

now:  $b(\theta_i) = N_i \log(1 + e^{\theta_i}) = -N_i \log(1 - p_i)$

Apdx:  $L_{os} = 2 \cdot \sum_{i=1}^n \left[ y_i \left( \log \frac{\hat{p}_i^{(s)}}{1 - \hat{p}_i^{(s)}} - \log \frac{\hat{p}_i^{(0)}}{1 - \hat{p}_i^{(0)}} \right) + N_i \left( \log(1 - \hat{p}_i^{(s)}) - \log(1 - \hat{p}_i^{(0)}) \right) \right] =$

$$= 2 \cdot \sum_{i=1}^n \left[ y_i \log \frac{\hat{p}_i^{(s)}}{\hat{p}_i^{(0)}} + (N_i - y_i) \log \frac{1 - \hat{p}_i^{(s)}}{1 - \hat{p}_i^{(0)}} \right] =$$

$$= 2 \sum_{i=1}^n \left[ y_i \log \frac{y_i / N_i}{\hat{p}_i^{(0)}} + (N_i - y_i) \log \frac{1 - y_i / N_i}{1 - \hat{p}_i^{(0)}} \right] =$$

$$= 2 \sum_{i=1}^n \left[ y_i \log \frac{y_i}{E_0(y_i)} + (N_i - y_i) \log \frac{N_i - y_i}{N_i - E_0(y_i)} \right]$$

apdx ja no saturated modelo kover:  $\hat{p}_i^{(s)} = \frac{y_i}{N_i}$

now:  $N_i \hat{p}_i^{(0)} = E_0(y_i)$  o saturated # maximum kuro ano ro pnduro kovero.

(147)

↳ Η Deviance αγγίζει τους παρατηρούμενους  
 απ. συντελεστές με τους αναμενόμενους για  
 το συγκεκριμένο (αυθόνο) κομμάτι.

Έλεγχος κρίσης μορφολογίας.

↳ κρίση ανόθευ  $H_0$  είναι:  $L_{as} \overset{\text{αυθ.}}{\sim} \chi_{q-p}^2$

↳ (!) Οα πρέπει:  $\sum_{i=1}^n N_i \rightarrow \infty$  ή  $N_i p_i \rightarrow \infty$

↳ Αν για κάποια  $i$  είναι:  $N_i p_i \not\rightarrow \infty$   
 τότε χρησιμοποιούμε το  $\chi^2$  του Pearson

↳ Ομοίως, για ελέγχους ομοιογένειας  
 ενταυμιζόμενων ιατών:  $L_{as} - L_{is} \sim \chi_{q-p}^2$

Σημ. η μορφολογία  $\chi^2$  είναι αρκετά  
 απίθανη για διαφορετικές αναμενόμενες παρατηρήσεις που  
 δεν είναι για τις ίδιες τις αναμενόμενες.



# Alla Link Functions

↳  $H$  logit(p) Das ist eine in Standard link fun.

↳ Funktion or link functions definition  
von einem zum anderen

$$g: (0,1) \rightarrow \mathbb{R}$$

nx:  $g(p) = F^{-1}(p)$  and  $F$  exp. distribution  
kanonisch normalis z.b.

(normalisierter k.f. probis distribution z.b.)

## Link functions

a)  $logit(p) = \log \frac{p}{1-p}$  --- uniglobale exponen-  
tial zur logistic  
kanonisch

b)  $probit(p) = \Phi^{-1}(p)$  --- zur normalen  
kanonisch

c)  $comp \log-log: \log(-\log(1-p))$  --- log(standard)