

## LOGISTIČNA REGRESIJA

Predpostavljamo, da imamo  $m$  neodvisnih spremenljivk  $X_1, \dots, X_m$  in odvisno spremenljivko  $Y$ , ki ima lahko samo vrednosti 0 in 1. Zapišimo  $\mathbf{X} = (X_1, \dots, X_m)$ . Predpostavljamo, da velja naslednji pospoljen regresijski model, ki je znan pod imenom *logistični regresijski model*:

$$P(Y = 1|\mathbf{X}) = \frac{\exp(\beta_0 + \sum_{k=1}^n \beta_k X_k)}{1 + \exp(\beta_0 + \sum_{k=1}^n \beta_k X_k)},$$

kjer so  $\beta_0, \beta_1, \dots, \beta_m$  parametri modela.

V datoteki `logistic.dat` so podatki za izpis iz S-PLUS, ki je vključen.

```
*** Import Data ***
```

```
Import Successful
```

```
File name: /valjhun/mihael/teaching/istat/verstat/data/logit.dat
Data name: logit
```

```
Number of rows: 1000
```

```
Number of columns: 3
```

```
Columns:
```

Name	Type
1 Col1	numeric
2 Col2	numeric
3 Col3	numeric

```
*** Generalized Linear Model ***
```

```
Call: glm(formula = Col1 ~ Col2 + Col3,
          + family = binomial(link = logit),
          + data = logit, na.action = na.exclude,
          + control = list(epsilon = 0.0001, maxit = 50, trace = F))
```

```
Deviance Residuals:
```

Min	1Q	Median	3Q	Max
-----	----	--------	----	-----

-2.061219 -1.047069 0.5614318 1.049224 2.122089

Coefficients:

	Value	Std. Error	t value
(Intercept)	0.05832206	0.06777698	0.8604996
Col2	0.41705971	0.08130599	5.1295077
Col3	0.56273870	0.07989416	7.0435527

(Dispersion Parameter for Binomial family taken to be 1 )

Null Deviance: 1385.81 on 999 degrees of freedom

Residual Deviance: 1252.243 on 997 degrees of freedom

Number of Fisher Scoring Iterations: 3

Correlation of Coefficients:

	(Intercept)	Col2
Col2	0.0623449	
Col3	-0.0199886	-0.3277031

Analysis of Deviance Table

Binomial model

Response: Col1

Terms added sequentially (first to last)

	Df	Deviance	Resid. Df	Resid. Dev
NULL			999	1385.810
Col2	1	79.92338	998	1305.887
Col3	1	53.64399	997	1252.243

Odgovorite na naslednja vprašanja:

- Za dane podatke  $y_1, y_2, \dots, y_n$  in  $\mathbf{x}_1, \dots, \mathbf{x}_n$  zapišite (pogojno) funkcijo verjetja.

- b. Prepričajte se, da so parametri v izpisu ocenjeni po metodi največjega verjetja.
- c. Zapišite analitični izraz za Fisherjevo matriko verjetja.
- d. Prepričajte se, da so standardne napake na izpisu ocenjene tako, da izračunamo inverz Fisherjeve matrike informacije.
- e. Kako bi (pogojno) preizkusili domnevo  $H_0: \beta_1 = \beta_2 = 0$ ? Na kaj bi se sklicali?
- f. V načelu moramo upoštevati tudi, da so  $\mathbf{x}_1, \dots, \mathbf{x}_n$  tudi vzorec iz neke populacije. Privzemite, do so  $\mathbf{X}_1, \dots, \mathbf{X}_n$  neodvisne dvorazsežne normalne z  $\mu_1 = \mu_2 = 0$ ,  $\sigma_1^2 = \sigma_2^2 = 1$  in nekim  $\rho \in (-1, 1)$ . Kako bi ocenili brezpogojno standardno napako cenilk za parametre  $\beta$ , če poznate  $\rho$ ?
- g. Kako bi ocenili brezpogojno standardno napako, če ne poznate parametra  $\rho$ ? S simulacijo se prepričajte za konkreten primer, da so vaše ocene prave. Komentirajte, zakaj je bolj “pošteno” navajati brezpogojne standardne napake?
- h. Kako bi brezpogojno preizkusili domnevo  $H_0: \beta_1 = \beta_2 = 0$  v primeru, ko  $\rho$  poznate?