

# Matematičke metode u marketingu. Generalizirani linearni model



Lavoslav Čaklović  
PMF-MO

2016

## Jedan loš linear model

$$n = 1000, \quad i = 1, \dots, n$$

$$Y = \begin{cases} 1 & \text{ako } y_i > 0 \\ 0 & \text{inače} \end{cases} \quad \begin{aligned} y_i &= -2x_i + rnorm(n) \\ x_i &= round(0.001 * i + rnorm(n), 1) \end{aligned}$$





Lijevo: OLS  
Desno: qqplot

## Jedan loš linear model

$$n = 1000, \quad i = 1, \dots, n$$

$$Y = \begin{cases} 1 & \text{ako } y_i > 0 \\ 0 & \text{inače} \end{cases} \quad \begin{aligned} y_i &= -2x_i + rnorm(n) \\ x_i &= round(0.001 * i + rnorm(n), 1) \end{aligned}$$



Lijevo: OLS  
Desno: GLM

## Što je uzrok slabe predikcije u modelu ( $R^2 = 0.2$ )?

Problem je što su varijable ( $Y|X = x_i \sim B(1, p_i)$ ) gdje  $p_i$  ovisi o  $i$  pa i njihova varijanca  $m_i p_i (1 - p_i)$ <sup>1</sup> nije konstantna. To može biti pogubno za linearnu regresiju (vidi qqplot na prethodnoj slici desno).

### Nešto bolji model

Jednostavnosti radi, promatrajmo jednu dihotomnu varijablu  $Y$  i jedan prediktor  $X$ . Promatramo

$$p(x) := P(Y = 1|X = x) \quad (1)$$

i regresijski model ( $z \in (-\infty, +\infty)$ )

$$z := \log \frac{p(x)}{1 - p(x)} = \beta_0 + \beta_1 x + \epsilon. \quad (2)$$

Zamjerka modelu:  $z$  ne poprima realne vrijednosti za  $p(x) = 0$  i  $p(x) = 1$ . Ako je  $z \in \mathbb{R}$  i  $p_i$  u manjoj mjeri ovisno o  $i$  nema razloga ne koristiti model (2).

---

<sup>1</sup> $m_i$  je učestalost podatka  $x_i$ .

Što je uzrok slabe predikcije u modelu ( $R^2 = 0.2$ )?

Problem je što su varijable ( $Y|X = x_i \sim B(1, p_i)$ ) gdje  $p_i$  ovisi o  $i$  pa i njihova varijanca  $m_i p_i (1 - p_i)$ <sup>1</sup> nije konstantna. To može biti pogubno za linearnu regresiju (vidi qqplot na prethodnoj slici desno).

### Nešto bolji model

Jednostavnosti radi, promatrajmo jednu dihotomnu varijablu  $Y$  i jedan prediktor  $X$ . Promatramo

$$p(x) := P(Y = 1|X = x) \quad (1)$$

i regresijski model ( $z \in (-\infty, +\infty)$ )

$$z := \log \frac{p(x)}{1 - p(x)} = \beta_0 + \beta_1 x + \epsilon. \quad (2)$$

Zamjerka modelu:  $z$  ne poprima realne vrijednosti za  $p(x) = 0$  i  $p(x) = 1$ . Ako je  $z \in \mathbb{R}$  i  $p_i$  u manjoj mjeri ovisno o  $i$  nema razloga ne koristiti model (2).

---



<sup>1</sup>  $m_i$  je učestalost podatka  $x_i$ .

**Neki osnovni pojmovi.** Funkciju  $p \mapsto \log\left(\frac{p}{1-p}\right)$  nazivamo *logit* funkcijom i u regresiji igra ulogu *link-funkcije*. Njoj inverzna (tzv. *logistička funkcija*) je

$$\Lambda(z) = \frac{e^z}{1 + e^z}. \quad (3)$$

Očito:

$$\Lambda'(z) = \Lambda(z)(1 - \Lambda(z)). \quad (4)$$



Lijevo: *logit*  
Desno: *logistic*

## Logistička regresija

Ideja *logističke regresije* je da se umjesto modela (2) i metode najmanjih kvadrata promatra model

$$z := \log \frac{p(x)}{1 - p(x)} = \beta_0 + \beta_1 x$$

(bez slučajne greške  $\epsilon$ ) uz pretpostavku da je odzivna varijabla binomna, tj.

$$Y \sim B(1, p).$$

Želimo procijeniti  $p(x_i) := P(Y|X = x_i)$  kao funkciju od  $\theta = (\beta_0, \beta_1)$ .

Koeficijenti modela procjenjuju se maksimizacijom vjerodostojnosti<sup>2</sup>:

$$\mathcal{L}(\theta) = \prod_{i=1}^n P(Y = y_i | X = x_i) = \prod_{i=1}^n p(x_i, \theta)^{y_i} (1 - p(x_i, \theta))^{1-y_i} \quad (5)$$

gdje  $y_i \in \{0, 1\}$ , a

$$p(x, \theta) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}} = \Lambda(\beta_0 + \beta_1 x). \quad (6)$$

---

<sup>2</sup>Vjerodostojnost danog uzorka je produkt individualnih vjerojatnosti.

Umjesto da maksimiziramo  $\mathcal{L}$  maksimizirat ćemo njen logaritam. Zbog jednostavnosti računa uvedimo označke  $p_i = p(x_i, \theta) = \Lambda(z_i)$  i  $p' = \frac{d}{dz}\Lambda(z)$ :

$$\log(\mathcal{L}) = \sum_{y_i=1} \log(p_i) + \sum_{y_i=0} \log(1 - p_i)$$

$$\begin{aligned} \frac{d}{dz}(\log(\mathcal{L}(z))) &= \sum_{y_i=1} \frac{p'_i}{p_i} - \sum_{y_i=0} \frac{p'_i}{1-p_i} \quad (\text{pa zbog (4) slijedi}) \\ &= \sum_{y_i=1} \frac{p_i(1-p_i)}{p_i} - \sum_{y_i=0} \frac{p_i(1-p_i)}{1-p_i} = \sum_{y_i=1} (1-p_i) - \sum_{y_i=0} p_i. \end{aligned}$$

Nužni uvjeti maksimalnosti su:

$$\frac{\partial \log(\mathcal{L})}{\partial \beta_0} = \sum_{y_i=1} (1-p_i) \frac{\partial z_i}{\partial \beta_0} - \sum_{y_i=0} p_i \frac{\partial z_i}{\partial \beta_0} = 0$$

$$\frac{\partial \log(\mathcal{L})}{\partial \beta_1} = \sum_{y_i=1} (1-p_i) \frac{\partial z_i}{\partial \beta_1} - \sum_{y_i=0} p_i \frac{\partial z_i}{\partial \beta_1} = 0,$$

odnosno (zbog  $z = \beta_0 + \beta_1 x$ )

$$\sum_{y_i=1} (1 - p_i) - \sum_{y_i=0} p_i = 0$$
$$\sum_{y_i=1} (1 - p_i)x_i - \sum_{y_i=0} p_i x_i = 0.$$

Rješenja dobivenih jednadžbi nije moguće dobiti u zatvorenoj formi već se rješavaju numerički Newtonovim iterativnim postupkom. Gornji sustav jednadžbi nema rješenje u slučaju potpune separacije, a za djelomičnu separaciju Newtonova procedura može biti nestabilna.

Za male uzorke, procjena parametara pomoću maksimalne vjerodostojnosti pati od pristranosti.

## Primjer (Potpuna separacija)

Najjednostavniji primjer potpune separacije je:

$$\begin{array}{c} x \quad Y \\ \hline n_1 \left\{ \begin{array}{cc} x_1 & 1 \\ \vdots & \vdots \\ x_1 & 1 \end{array} \right. \\ n_2 \left\{ \begin{array}{cc} x_2 & 0 \\ \vdots & \vdots \\ x_2 & 0 \end{array} \right. \end{array}$$

Nužni uvjet ekstrema vodi na sustav jednadžbi

$$n_1(1 - p_1) - n_2 p_2 = 0$$

$$n_1(1 - p_1)x_1 - n_2 p_2 x_2 = 0$$

koji ima rješenje samo ako je  $x_1 = x_2$ .

U slučaju djelomične separacije varijabla  $Y$  može u donjem bloku imati nekoliko vrijednosti 1. Potpuna separacija često se javlja kod klasifikacije bolesti koje su učestale sa starošću (prediktor  $x$  je vrijeme).

U slučaju separacije svaki softverski paket upozorava korisnika.


## Interpretacija modela

Za izračunate  $\beta_0, \beta_1$  vjerojatnost  $P(X = x)$  i vrijednost od  $z$  su:

$$p(x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}} = \Lambda(\beta_0 + \beta_1 x)$$

$$z(x) = \log \frac{p(x)}{1 - p(x)} = \beta_0 + \beta_1 x.$$

$$p(x) = \Lambda(z(x))$$



- Točka infleksije od  $\Lambda$  je  $x_i := -\frac{\beta_0}{\beta_1}$ ,  
 $\Lambda(z_i) = \frac{1}{2}$  (maks. separiranost).
- $\beta_1 = 0 \implies$  omjer ne ovisi o  $x$
- $\exp(\beta_0) \cdot \exp(\beta_1)$  je promjena omjera za jedinično povećanje  $x$
- Marginalni efekt od  $p$  je:  
$$p'(x) = \beta_1 \Lambda'(z(x))$$
$$= \beta_1 \Lambda(z)(1 - \Lambda(z)).$$

## Probit model

Funkcija  $\Lambda(z)$  je kumulativna distribucija *standardne logističke distribucije*  $LOG(0, 1)$  čija je gustoća

$$\lambda(z) = \frac{e^z}{(1+z)^2}, \quad \mu = 0, \sigma = \frac{\pi^2}{3}.$$

To sugerira ideju da se umjesto logističke distribucije uzme kumulativna distribucija neke druge slučajne varijable. *Probit* model koristi kumulativnu distribuciju normalne razdiobe:

$$p(x) = \Phi(\beta_0 + \beta_1 x) = \int_{-\infty}^{\beta_0 + \beta_1 x} \varphi(x) dx.$$

Marginalni efekt za probit model (tj. derivacija od  $p$ ) je

$$p'(x) = \frac{\partial \Phi}{\partial x}(x) = \beta_1 \varphi(\beta_0 + \beta_1 x). \tag{7}$$

Logistički model i probit model u praksi nude iste zaključke uz neznatne razlike u procjeni koeficijenata.

## Interpretacija marginalnog efekta

Za logit model marginalni efekt

$$p'(x) = \beta_1 \Lambda(z(x))(1 - \Lambda(z(x)))$$

predstavlja promjenu poželjnosti od  $Y = 1$  ako se vrijednost prediktora poveća za 1. Primijetimo da je predznak promjene jednak predznaku od  $\beta_1$ .

Za probit model vrijedi isti zaključak (v. formulu (7)).

## Kategorijski prediktor

## Logistička regresija u R-u.

```
glm(Y ~ x + z, data = data_frame, family = 'binomial')
```

### Zadaci

- Prouči R-kôd <https://onlinecourses.science.psu.edu/stat504/node/225>  
**Još neke zanimljivosti**
- Prvi pokušaj modeliranja binarne ovisnosti: Anscombe, "The transformation of Poisson... ", Biometrika (1948).
- U posljednje vrijeme se proučavaju situacije kad je linearni model za binarnu odzivnu varijablu koristan, v. Ottar Hellevik, Linear versus logistic regression when the dependent variable is a dichotomy, Qual Auant (2009)