

GENERALIZIRANI LINEARNI MODELI

STATISTIČKI PRAKTIKUM 2

Do sada

1. $Y = \alpha_0 + \alpha_1 x_1 + \dots + \alpha_p x_p + \varepsilon$, $\varepsilon \sim N(0, \sigma^2)$, $x_1, \dots, x_p$
kvantitativne varijable prediktori
2. prediktori mogu biti i faktorske varijable (paralelni pravci), npr.
 $Y = \alpha_0 + \alpha_1 x_1 + \alpha_2 d_1 + \alpha_3 d_2 + \varepsilon$
3. uvodimo interakciju između prediktora
 $Y = \alpha_0 + \alpha_1 x_1 + \alpha_2 d_1 + \alpha_3 d_2 + \alpha_4 x_1 d_1 + \alpha_5 x_1 d_2 + \varepsilon$
4. dozvoljavamo ne-Gaussovsu strukturu varijable Y

GLM čine široku klasu linearnih modela koja obuhvaća modele sa

- ▶ specijalnim strukturama grešaka
- ▶ kategorijskim ili uređenim varijablama odaziva
- ▶ multinomijalnim varijablama (zavisnim)
- ▶ ...

$$Y = g^{-1}(X\beta) + \varepsilon, \quad g(\mathbb{E}Y) = X\beta$$

U standardnom linearnom modelu greške su bile n.j.d. $\sim N(0, \sigma^2)$, a funkcija g je bila identiteta.

Sada Y ne mora više biti neprekidna, ali u R-u ne možemo raditi sa bilo kakvim funkcijama g i distribucijama od Y .

Osnove modela

$$Y = g^{-1}(X\beta) + \varepsilon$$

GLM sastoji se od tri elementa:

1. slučajni - vjerojatnosna distribucija F iz eksponencijalne familije distribucija, $Y \sim F$;
2. sistemski - linearni prediktor $X\beta$;
3. veza između slučajne i sistemske komponente - vezna (*link*) funkcija g t.d. $\mu = \mathbb{E}Y = g^{-1}(X\beta)$.

Gustoća iz *eksponencijalne familije* se može zapisati u obliku

$$f(x | \theta) = h(x) \exp \{ \eta(\theta) T(x) - A(\theta) \},$$

npr. binomna, Poissonova, eksponencijalna, normalna, geometrijska distribucija.

Procjena parametara

Parametri modela β mogu se procijeniti metodom maksimalne vjerodostojnosti (ML). Procjenitelji se općenito ne mogu dobiti u zatvorenoj formi, ali se uvijek mogu procijeniti iterativnom metodom najmanjih kvadrata s težinama (IWLS).

U R-u je implementirana procedura `glm`

```
> glm  
glm(formula, family = gaussian, data, weights, subset,  
     na.action, ...)
```

Parametrom `family` specificiramo distribuciju i link funkciju modela.

U proceduri `glm` implementirano je 6 distribucija s najčešće korištenim pripadnim link funkcijama:

Distribucija	Link funkcija
normalna	identiteta
binomna	logit, probit
Poissonova	log, identiteta, korijen
...	...

Bernoullijeva razdioba

```
family=binomial(link=logit)  
family=binomial(link=probit)
```

Neka Y poprima vrijednosti 0 ili 1, tj. $Y \sim B(p)$, $p = \mathbb{E}Y$. Pri odabiru generaliziranog linearnog modela često se promatraju dvije link funkcije:

- ▶ logit $g(y) = \ln \left(\frac{y}{1-y} \right)$, $y \in \langle 0, 1 \rangle$
- ▶ probit $g(y) = \Phi^{-1}(y)$, $y \in \langle 0, 1 \rangle$

Zadatak

U datoteci `binary.csv` nalaze se podaci o uspješnosti upisa 400 studenata na poslijediplomske studije. Za svakog su aplikanta dani rezultati GRE testa, prosjek ocjena (GPA) i rang fakulteta na koji se aplicirao.

Procijenite parametre probit modela za dane podatke, odredite pripadne 95% pouzdane intervale za koeficijente te na temelju danog modela procijenite koja je vjerojatnost da student s GRE rezultatom 750 i prosjekom 3.88 upadne na poslijediplomski program na sveučilištu ranga 1.

Rezultati:

- ▶ *devijanca* - mjera odstupanja opažanja od očekivane vrijednosti dane modelom
- ▶ *null-deviance* =
 $2(\log L(\text{saturirani model}) - 2 \log L(\text{null model}))$ = pokazatelj koliko dobro osnovni model (samo slobodni član) opisuje podatke
- ▶ *residual deviance* =
 $2(\log L(\text{saturirani model}) - 2 \log L(\text{proposed model}))$ = pokazatelj koliko dobro predloženi model opisuje podatke, odgovara sumi kvadrata reziduala u standardnom linearnom modelu
- ▶ *AIC (Akaike information criterion)* = $-2 \log L - k \cdot (p + 1)$, gdje je $p + 1$ broj parametara modela

Odstupanje točaka

Točke u modelu mogu odstupati od ostalih točaka po

- ▶ x-osi - točke **visoke poluge** (*eng. high leverage*)
- ▶ y-osi - outlieri

Točka (podatak) također može biti **utjecajna** za model ako ima značajan utjecaj na neki dio procijenjenog modela (predviđene vrijednosti varijable odaziva, procijenjene parametre ili procijenjen utjecaj pojedinog prediktora u modelu), tj. izbacivanjem te točke iz modela procijenjene vrijednosti se značajno promijene.

Outlieri i točke visoke poluge mogu i ne moraju biti utjecajne u modelu.

Poluga h_i mjeri odstupanja po x-osi i -tog podatka od prosjeka vrijednosti svih podataka (broj u rasponu od 0 do 1). Predstavlja utjecaj koji opažena vrijednost y_i ima na predviđenu vrijednost $\hat{y}_i$. Što je poluga veća, to je uloga i -tog podatka u formiranju predviđanja $\hat{y}_i$ veća. Vrijedi: $\sum_{i=1}^n h_i = p + 1$.

Potencijalno utjecajne točke su točke visoke poluge za koje je

$$h_i > 3 \frac{p + 1}{n}.$$

Outlieri - podaci čiji su studentizirani reziduali r_i po apsolutnoj vrijednosti veći od 3.

Utjecajne točke

Jedna od mjera kojom možemo identificirati utjecajne točke u modelu je **Cookova udaljenost** (*eng. Cook's distance*). Definirana je s

$$D_i = \frac{(y_i - \hat{y}_i)^2}{(p + 1)MSE} \frac{h_i}{(1 - h_i)^2}.$$

D_i opisuje koliko se sve predviđene vrijednosti promijene kada iz modela izbacimo i -ti podatak, tj. koliko je ta točka utjecajna.

- ▶ $D_i > 0.5$ - i -ta točka je možda utjecajna (treba dalje istražiti)
- ▶ $D_i > 1$ - i -ta točka je vjerojatno utjecajna
- ▶ u usporedbi s ostalim Cookovim udaljenostima, D_i značajno odskoče po svojoj vrijednosti (graf izgleda poput slova T) - i -ta točka je gotovo sigurno utjecajna

```
> plot(cooks.distance(model))  
> plot(cooks.distance(model), type="h")
```

Što s utjecajnim točkama?

Ekstremnost ne znači nužno da točke trebamo izbaciti iz modela. U principu, točke ćemo izbaciti ukoliko se radi o pogrešci u mjerenju ili prilikom upisivanja podataka. Također, moguće je da podatak nije reprezentativan za populaciju koju promatramo. Točku nećemo izbaciti samo zato što se ne uklapa u model koji indiciraju ostale točke. Svako izbacivanje podataka treba dobro opravdati.

Ukoliko nemamo razloga za odbacivanjem utjecajne točke ili nismo sigurni radi li se o pogrešci možemo:

- ▶ provjeriti model koji smo dobili (goodness-of-fit) i napraviti potrebne promjene (uvesti nove prediktore ili interakciju među postojećim prediktorima, proučiti odnos između varijabli i uzeti model koji bi bolje opisao taj odnos),
- ▶ analizirati oba modela: s točkom i bez nje i prikazati obje varijante.

Analiza reziduala

Pozivanjem naredbe `plot(model)` dobijemo grafičku analizu reziduala:

- ▶ reziduali vs. predviđene vrijednosti $\hat{y}_i$
- ▶ normalni vjerojatnosni graf studentiziranih reziduala
- ▶ $\sqrt{|r_i|}$ vs. $\hat{y}_i$ (*scale-location plot*, raspored reziduala obzirom na lokaciju podataka unutar modela)
- ▶ r_i vs. h_i zajedno s krivuljama Cookovih udaljenosti