

LINEARNI MODELI 2

STATISTIČKI PRAKTIKUM 2

Kada je opravdano koristiti linearni regresijski model?

Promatramo linearni regresijski model u p varijabli

$$Y_n = \beta_0 + \beta_1 x_1^{(n)} + \dots + \beta_p x_p^{(n)} + \varepsilon_n.$$

Četiri glavne pretpostavke koje opravdavaju korištenje LRM-a u svrhu analize podataka i predviđanja su:

- (i) *linearni* odnos između varijabli poticaja i odaziva
- (ii) *nezavisnost* grešaka
- (iii) *normalna distribuiranost* grešaka
- (iv) *homogenost* grešaka (jednakost normalnih distribucija)

Ukoliko neka od pretpostavki nije opravdana, naša previđanja mogu biti nevaljana.

(i) Linearnost podataka

Pretpostavljamo da Y ovisi linearno o prediktorima.

Ukoliko postoji nelinearan odnos jedne ili više varijabli, naša predviđanja (posebno izvan raspona uzorka) mogu biti potpuno netočna.

Detekcija odnosa varijabli i dobar izbor početnog modela ključan je za ispravnu analizu podataka.

Kako prepoznati nelinearnost?

Nelinearnost je najlakše uočiti iz grafičke usporedbe

- ▶ stvarnih i predviđenih vrijednosti varijable odaziva ($Y - \hat{Y}$ graf)
- ▶ reziduala i predviđenih vrijednosti - *residual-fit plot* ($\hat{Y} - e$ graf)

U prvom grafu očekujemo simetrično raspršenje podataka oko dijagonale, a u drugom oko apscise (veća odstupanja sugeriraju lošiji model).

Kako ukloniti nelinearnost?

Potrebno je *transformirati* jednu ili više varijabli poticaja i/ili varijablu odaziva nekom nelinearnom funkcijom. Odabir funkcije ovisi o tipu podataka.

(ii) Nezavisnost grešaka

Problem zavisnosti grešaka javlja se kao moguća posljedica

- ▶ “cluster” podataka (uzorkovanje iz određene grupe umjesto cijele populacije)
- ▶ longitudinalnih podataka (uzorkovanje populacije kroz vrijeme - promjene u modelu su rezultat drugih faktora, potrebno korištenje vremenskih nizova koji uključuju varijablu vremena)
- ▶ čiste koreliranosti (loš odabir modela, koristiti modele koji uključuju koreliranost podataka, npr. ARMA)

Napomena: Nezavisnost dviju normalnih slučajnih varijabli povlači njihovu nekoreliranost.

Budući da se nezavisnost u principu ne može testirati, testiramo nekoreliranost.

Serijsku korelaciju među greškama ε možemo procijeniti koristeći rezidualne e . U R-u to čini funkcija `acf`

```
> model=lm(y~x)
> corr=acf(model$res)
> corr$acf
---
> acf(model$res)
```

Output je grafički prikaz vrijednosti *autokorelacijske funkcije*, zajedno s pripadnom 95%-pouzdanom prugom (približne širine $4/\sqrt{n}$).

(iii) Homogenost grešaka

Nejednakost varijance grešaka može rezultirati

- ▶ preširokim/preuskim intervalima pouzdanosti za procjene
- ▶ preferiranjem određenog podskupa podataka pri procjeni

Najčešće se pojavljuje kod vremenskih podataka (varijanca raste s vremenom).

Ključna pretpostavlja kako bi izbjegli probleme s predviđanjima i omogućili dobre procjene.

Homogenost se može uočiti iz grafičkog prikaza

- ▶ reziduala obzirom na vrijeme ($t - e$ graf), ako se radi o vremenskom nizu
- ▶ residual-fit plot-a ($\hat{Y} - e$ graf).

Kod oba grafa pozornost treba obratiti na rast reziduala, želimo postići simetrično raspršenje oko osi x .

Moguća rješenja su:

- ▶ analiza podataka po dijelovima s jednakom varijancom (više linearnih modela)
- ▶ ispitivanje pravilnog odabira modela
- ▶ korištenje alternativnih modela (ARCH)

(iv) Normalnost grešaka

Velika odstupanja od normalnosti mogu prouzročiti brojne probleme pri procjeni vrijednosti i pouzdanih intervala, budući da je normalnost grešaka korištena pri određivanju distribucija ostalih varijabli vezanih uz model.

Jedan od uzroka može biti i prisutnost *outliera*, koji mogu stvoriti probleme pri procjeni parametara modela (povećanje kvadratne greške).


Normalnost grešaka možemo provjeriti preko reziduala, korištenjem

- ▶ normalnog vjerojatnosnog grafa,
- ▶ Lillieforsovog testa,
- ▶ Shapiro-Wilkovog testa

```
> shapiro.test(model$res),
```

- ▶ Jarque-Bera testa.

Veliki uzorci iz distribucija *lakog repa* neće prouzročiti probleme u procjeni. Ako su greške kontrolirane i pripadaju distribuciji lakog repa svi rezultati će zbog snage CGT vrijediti asimptotski. Problemi su i dalje mogući kada greške imaju distribuciju *teškog repa*:



Analiza greške ε preko analize ostataka e

Ako su greške ε_i nezavisne i (normalno) jednako distribuirane, ostaci e ne moraju biti. Naime $e = (\mathbb{I} - \mathbf{H})\varepsilon$,
 $\mathbf{H} = \mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T$, pa je $\text{Var}(e) = (\mathbb{I} - \mathbf{H})\sigma^2$, odnosno

$$\text{Var}(e_i) = \sigma^2(1 - h_{ii}).$$

Problem se rješava uvođenjem studentiziranih ostataka

$$r_i = \frac{e_i}{\hat{\sigma}\sqrt{1 - h_{ii}}}.$$

Ako su pretpostavke na grešku modela točne, tada je $\text{Var}(r_i) = 1$, a korelacija $\text{Cor}(r_i, r_j)$ je mala.

U R-u ih dobivamo pomoću naredbe

```
> rstudent(model)
```

i u praksi radimo sa studentiziranim rezidualima.

Poluga

Poluge h_{ii}

- ▶ mjere osjetljivost procijenjenog $\hat{y}_i$ s obzirom na promjenu opažene vrijednosti y_i (odnosno, koliko i -ta opservacija utječe na procjenu parametara regresije)
- ▶ iz intervala $[0, 1]$ (što je poluga veća, utjecaj pojedine opažene vrijednosti na predviđenu je veći)
- ▶ $\sum h_{ii} = p + 1$

Točke visoke poluge - neobično velike ili male vrijednosti prediktora ili neobične vrijednosti s obzirom na vrijednosti ostalih prediktora, u praksi $h_{ii} > 2p/n$

Outlieri - točka čija opažena vrijednost ne prati trend ostalih točaka (opažena vrijednost značajno odstupa od ostalih opaženih vrijednosti točaka sličnih vrijednosti varijabli prediktora)

Utjecajne točke

Utjecajne točke u modelu

- ▶ imaju značajan utjecaj na neki dio procijenjenog modela (npr. predviđene vrijednosti, procijenjene koeficijente ili p-vrijednosti testova)
- ▶ njihovim uklanjanjem značajno mijenjamo dobivene procjene
- ▶ kandidati su točke visoke poluge i outlieri.

Jedan način da otkrivanja je računajući **Cookovu udaljenost** D_i koja kvantificira sveukupan utjecaj točke:

- ▶ > 0.5 - moguće je da je točka utjecajna
- ▶ > 1 - točka je vrlo vjerojatno utjecajna
- ▶ D_i poput palca (poput slova T) odskače od ostalih Cookovih udaljenosti D_j - točka je gotovo sigurno utjecajna

Zadatak

Promotrimo model s nenormalno distribuiranim greškama.
Simulirajmo podatke za model

$$Y_i = 1 + x_i + 2 \sin(x_i) + \varepsilon_i,$$

gdje je $x_i = i/10$, za $i = 0, 1, \dots, 100$ i $\varepsilon_i \sim U(-1, 1)$ nezavisne.

- (a) Nacrtajmo stvarni model, procjenu modela i pouzdanu prugu za opažanja.
- (b) Nacrtajte *residual-fit plot* i analizirajte ga.
- (c) Proučite raspon ostataka i nacrtajte pripadni graf *autokorelacijske funkcije*.
- (d) Nacrtajte normalni vjerojatnosni graf ostataka i studentiziranih ostataka i usporedite ga s pravcem $y = x$.

Testiranje (linearnih) hipoteza o parametrima

Možemo li ukloniti neke varijable iz modela, čiji je doprinos mali i bez njih ne dobivamo značajno lošiji model?

Neka je $\mathbf{C} \in M_{m \times (p+1)}(\mathbb{R})$ i $\mathbf{g} \in M_{m \times 1}$, t.d. $r(\mathbf{C}) = m < p + 1$.
Hipotezu

$$H_0 : \quad \mathbf{C}\mathbf{b} = \mathbf{g}$$

testiramo statistikom

$$F = \frac{(\mathbf{C}\hat{\mathbf{b}} - \mathbf{g})^T [\mathbf{C}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{C}^T]^{-1} (\mathbf{C}\hat{\mathbf{b}} - \mathbf{g})}{\hat{\sigma}^2} \stackrel{H_0}{\sim} F(m, p + 1)$$

Parametar m predstavlja broj jednadžbi uz koje je vezana nulta hipoteza (nužno manji od broja parametara modela).

Primjer testiranja linearnih hipoteza

Metodom najmanjih kvadrata podatke iz yy modelirajmo kao

$$Y = \beta_0 + \beta_1 x + \beta_2 x^2 + \beta_3 \sin x.$$

```
> pl=lm(yy~x+I(x^2)+sin(x))
```

Testirajmo hipotezu da je uži model dovoljan, tj.

$$H_0: \beta_2 = 0, \beta_1 = 1.$$

```
> pl2=lm(yy~offset(1*x)+sin(x))
```

```
> anova(pl2,pl)
```

Analysis of Variance Table

Model 1: $yy \sim \text{offset}(x) + \sin(x)$

Model 2: $yy \sim x + \sin(x) + I(x^2)$

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	99	32.044				
2	97	31.403	2	0.641	0.9896	0.3755

Izbor varijabli

Želimo izabrati *najbolji* podskup varijabli poticaja (*optimalni* model):

- ▶ želimo objasniti podatke na najjednostavniji mogući način (višak varijabli sigurno neće pogoršati model, ali nas zanima hoće li ga *značajno* poboljšati)
- ▶ višak varijabli poticaja pojačat će *šumove* kod izračunavanja procjena
- ▶ može doći do kolinearnosti - više varijabli pokušava procijeniti isti dio nezavisne varijable (teško se procjenjuje utjecaj pojedine varijable jer se efekt podijeli na njih više)
- ▶ veliki modeli su neučinkoviti (invertiranje velikih matrica)
- ▶ izbacivanjem prevelikog broja varijabli poticaja gubimo moć predikcije

Procedure za izbor varijabli

1. hijerarhijski izbor modela (anova);
2. procedure korak po korak (dodavanjem ili uklanjanjem jedne po jedne varijable);
3. procedure bazirane na kriterijima (kojeg računamo za sve modele od interesa i na temelju njih odabiremo najbolji).

AIC i BIC kriteriji

Za p mogućih varijabli poticaja, imamo 2^{p+1} mogućih modela od kojih želimo odabrati najbolji prema nekom kriteriju.

1. Akaike Information Criterion

$$\text{AIC} = -2\log\text{-likelihood} + 2p$$

2. Bayes Information Criterion

$$\text{BIC} = -2\log\text{-likelihood} + \log n \cdot p$$

Za linearne modele

$$-2\log\text{-likelihood} = n \log(\text{SSE}/n).$$

$$(\text{SSE} = \sum_{k=1}^n (\hat{y}_i - y_i)^2).$$

- ▶ želimo što veći log-likelihood
- ▶ veći modeli $\implies$ manji SSE i veći p (detektiramo varijable koje ne smanjuju grešku dovoljno značajno)
- ▶ najbolji model je ravnoteža između broja parametara i pristajanja podacima
- ▶ BIC strože kažnjava veće modele
- ▶ različiti kriteriji mogu donijeti različite odluke

Za određivanje AIC i BIC koristimo naredbu

```
> AIC(u1, k=...),
```

gdje k označava način kažnjavanja velikih modela ($k_{\text{AIC}} = 2$,
 $k_{\text{BIC}} = \log(n)$)

Ukoliko želimo provesti hijerarhijsku analizu optimalnog modela, da izbjegnemo ručno računanje kriterija za svaki model, koristimo funkciju

```
> step(model, k=..., trace=...),
```

gdje je `model` najopćenitiji model (sa svim varijablama).

Zadatak

Modelirajmo podatke iz primjera s uniformno distribuiranim greškama i to modelom s funkcijom sinus i polinomom 3. stupnja. Nađimo najpogodniji pod-model za ove podatke

- (1) po AIC i BIC kriteriju,
- (2) testirajući razliku između modela prigodnim statističkim testom, i to krećući od
 - (a) punog modela izbacujući jednu po jednu varijablu
 - (b) nul-modela dodajući jednu po jednu varijablu.

Underfitting vs. overfitting

Koliko dobro naš model uči iz podataka?

- ▶ *underfitting* - prilagodba modela podacima dobra, ali nedovoljno precizna i prejednostavna (predviđene vrijednosti daleko od stvarnih zbog nedostatka važnih odnosa)
 - ▶ *overfitting* - model predobro odgovara podacima (prekompleksan model koji opisuje šumove umjesto pravih uzoraka). Model će loše predviđati na novom skupu podataka.
- Moguća rješenja:
- *cross-validation* (uzimanje slučajnih poduzoraka od početnog uzorka, na njima se provodi prilagodba te potom uzima neki prosjek rješenja)
 - više podataka
 - jednostavniji podaci
 - dodavanje šuma početnim podacima

Ometajuće varijable

Ometajuće varijable (*confounding variables*)

- ▶ ometaju vezu između zavisne i važne nezavisne varijable
- ▶ utječu na neku drugu nezavisnu varijablu i na varijablu odziva, čime daje na važnosti toj varijabli odziva koja možda nije potrebna u modelu

Kolinearnost

- ▶ statistička povezanost između nezavisnih varijabli
- ▶ teško je procijeniti utjecaj pojedine nezavisne varijable na varijablu odziva
- ▶ male promjene u podacima značajno mijenjaju procijenjene koeficijente

Mjere kolinearnosti:

► Tolerancija

- mjeri udio varijance u nezavisnoj varijabli koji nije objašnjen ostalim nezavisnim varijablama
- $T = 1 - R^2$, gdje je R^2 koeficijent determinacije, dobiven regresijom promatrane varijable na sve ostale nezavisne varijable
- $T < 0.1$ - visok stupanj multikolinearnosti (većinu varijance prediktora objašnjavaju druge prediktorske varijable)

► VIF (Variance inflation factor)

- koliko se varijanca regresijskog koeficijenta povećava zbog kolinearnosti među prediktorima
- $VIF = \frac{1}{T} = \frac{1}{1-R^2}$
- visoka vrijednost VIF-a znači da prediktor dijeli puno varijance s drugim prediktorima, što može dovesti do nestabilnih procjena koeficijenata
- $VIF > 5$ potrebno detaljnije promotriti varijable poticaja
- $VIF > 10$ značajna multikolinearnost