

Matematika i statistika

Doktorski studij Strojarskog fakulteta

Sveučilište u Slavonskom Brodu

Predavanje 4

Predavač:

izv.prof.dr.sc. Nenad Šuvak, Odjel za matematiku, Sveučilište u Osijeku

VEZA IZMEDU VARIJABLI

- ▶ za parove podataka iz dvije neprekidne varijable želimo zaključivati o postojanju zavisnosti između njih
- ▶ kod neprekidnih varijabli zavisnost se može pojaviti na brojne načine - različiti tipovi veza među varijablama

DETERMINISTIČKA VEZA

- **deterministička veza** između dvije varijable zadana pravilom


$$y = f(x)$$

gdje je y zavisna varijabla, x nezavisna varijabla, a $f: \mathbb{R} \rightarrow \mathbb{R}$ zadana funkcija

- primjerice, pravilima $y = x + 54$, $y = x^2 - 14x$ i $y = \sin(3x)$ zadane su determinističke veze među varijablama x i y
- za svaku dopuštenu vrijednost nezavisne varijable x možemo izračunati točnu vrijednost zavisne varijable y

STATISTIČKI MODEL S ADITIVNOM GREŠKOM

- ▶ u praktičnim problemima ne možemo očekivati determinističku vezu
- ▶ **dijagram raspršenja** podataka (eng. scatter plot) je prikaz uređenih parova podataka iz dviju varijabli u koordinatnom sustavu



STATISTIČKI MODEL S ADITIVNOM GREŠKOM

- ▶ **regresijska metoda** modeliranja prepostavlja da možemo uspostaviti funkciju vezu ali uz dodanu grešku
- ▶ veza između nezavisne varijable x i zavisne slučajne varijable $Y(x)$ će biti oblika

$$Y(x) = f(x) + \varepsilon, \quad (1)$$

gdje prepostavljamo da je ε slučajna varijabla koja opisuje grešku u modeliranju

- ▶ mnogo nezavisnih slučajnih smetnji u pravilu ima normalnu distribuciju – u primjenama se u klasičnom načinu modeliranja prihvata da je model adekvatan ako je u njemu postignuta normalna distribuiranost grešaka ε

STATISTIČKI MODEL S ADITIVNOM GREŠKOM

- ▶ sparena mjerenja $(x_1, y_1), \dots, (x_n, y_n)$ dvaju obilježja koja dolaze od slučajnih varijabli Y_1, \dots, Y_n (čije su realizacije realni brojevi y_1, \dots, y_n) i nezavisne varijable x (čije su izmjerene vrijednosti x_1, \dots, x_n)
- ▶ cilj je utvrditi zavisnost između dvije varijable
- ▶ **regresijski model** – matematički model oblika

$$Y_i = f(x_i) + \varepsilon_i, \quad i = 1, \dots, n,$$

gdje je f realna funkcija jedne realne varijable, a $\varepsilon_1, \dots, \varepsilon_n$ međusobno nezavisne slučajne varijable takve da je $E \varepsilon_i = 0$ i $\text{Var}(\varepsilon_i) = \sigma^2$

STATISTIČKI MODEL S ADITIVNOM GREŠKOM

- ▶ prvi korak u uspostavljanju ovakvih veza među varijablama Y i x prikaz je podataka u dijagramu raspršenja iz kojeg se lako vidi grupiraju li se sparena mjerenja oko pravca (linearna zavisnost) ili neke krivulje (neka druga funkcionalna zavisnost - polinomijalna, logaritamska, ...)

REGRESIJSKI PRAVAC

- ▶ prepostavimo da je graf funkcije f u modelu pravac
- ▶ f možemo prikazati formulom $f(x) = \alpha + \beta x$
- ▶ slobodni koeficijent α zove se **odsječak na y -osi**, a koeficijent β uz nezavisnu varijablu x zove se **koeficijent smjera** i važan je iz sljedećeg razloga:
 - ako je $\beta < 0$ funkcija $f(x) = \alpha + \beta x$ je padajuća
 - ako je $\beta > 0$ funkcija $f(x) = \alpha + \beta x$ je rastuća
- ▶ graf funkcije $f(x) = \alpha + \beta x$ nazivamo **regresijskim pravcem**, a koeficijente α i β **regresijskim parametrima**

LINEARNI REGRESIJSKI MODEL

linearni regresijski model

$$Y_i = \alpha + \beta x_i + \varepsilon_i, \quad i = 1, \dots, n.$$

- ▶ x_1, x_2, \dots, x_n – izmjerene vrijednosti varijable x
- ▶ Y_1, Y_2, \dots, Y_n – slučajne varijable s izmjerenim vrijednostima y_1, \dots, y_n)
- ▶ α i β – **nepoznati parametri** linearne veze koje treba **procijeniti** u postupku modeliranja (to zapravo znači da trebamo **procijeniti regresijski pravac** $y = \alpha + \beta x$)

LINEARNI REGRESIJSKI MODEL

- ▶ $\varepsilon_1, \dots, \varepsilon_n$ predstavljaju varijable greške koja je dodana na linearu vezu $(\alpha + \beta x_i)$ – nemjerljive slučajne varijable za koje prepostavljamo da
 - ▶ međusobno su nezavisne
 - ▶ sve imaju normalnu distribuciju
 - ▶ imaju očekivanje 0
 - ▶ sve imaju jednaku varijancu σ^2

METODA NAJMANJIH KVADRATA

- ▶ na osnovu podataka želimo procijeniti nepoznate parametre α i β
- ▶ tako ćemo dobiti i procjenu nepoznatog regresijskog pravca $y = \alpha + \beta x$
- ▶ ako su α i β poznati za svaku izmjerenu vrijednost x_i možemo odrediti broj

$$y'_i = \alpha + \beta x_i$$

- ▶ y'_i – **teorijska vrijednost** zavisne varijable u x_i (eng. predicted value)
- ▶ y_i – **izmjerena ili eksperimentalna** vrijednost zavisne varijable u x_i (eng. observed value)
- ▶ y_i se razlikuje od teorijske vrijednosti pa točke (x_i, y_i) , $i = 1, \dots, n$, uglavnom ne leže na pravcu $y = \alpha + \beta x$

METODA NAJMANJIH KVADRATA

- ▶ parametre čemo odrediti tako da razlike između izmjerениh i teorijskih vrijednosti budu što manje
- ▶ metoda koju koristimo naziva se **metoda najmanjih kvadrata**
- ▶ procjenu treba odrediti tako da funkciju

$$\begin{aligned} D(\alpha, \beta) &= \sum (\text{eksperimentalne v.} - \text{teorijske v.})^2 \\ &= \sum_{i=1}^n (y_i - (\alpha + \beta x_i))^2 \end{aligned}$$

učinimo što manjom

- ▶ procjene $\hat{\alpha}$ i $\hat{\beta}$ regresijskih parametara α i β trebamo odrediti tako da vrijedi:

$$D(\hat{\alpha}, \hat{\beta}) = \min_{(\alpha, \beta) \in \mathbb{R}^2} D(\alpha, \beta)$$

METODA NAJMANJIH KVADRATA

- ▶ procjene $\hat{\alpha}$ i $\hat{\beta}$ nazivamo **procjenama u smislu metode najmanjih kvadrata** (eng. least squares estimates) regresijskih parametara α i β
- ▶ procjena nepoznatog regresijskog pravca $y = \alpha + \beta x$ je pravac $y = \hat{\alpha} + \hat{\beta}x$

METODA NAJMANJIH KVADRATA

- ▶ procjene se mogu eksplicitno izraziti:

$$\hat{\beta} = \frac{s_{xy}}{s_x^2}, \quad \hat{\alpha} = \bar{y}_n - \hat{\beta} \bar{x}_n,$$

gdje su

$$\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i, \quad \bar{y}_n = \frac{1}{n} \sum_{i=1}^n y_i,$$

$$s_x^2 = \sum_{i=1}^n (x_i - \bar{x}_n)^2, \quad s_y^2 = \sum_{i=1}^n (y_i - \bar{y}_n)^2,$$

$$s_{xy} = \sum_{i=1}^n (x_i - \bar{x}_n)(y_i - \bar{y}_n)$$

METODA NAJMANJIH KVADRATA

- ▶ koristeći formulu procijenjenog regresijskog pravca $y = \hat{\alpha} + \hat{\beta}x$, za svaku vrijednost x možemo izračunati pripadnu procjenu teorijske vrijednosti – **predikcija**
- ▶ $\hat{y}_i = \hat{\alpha} + \hat{\beta}x_i$ — predikcija zavisne varijable za vrijednost x_i nezavisne varijable
- ▶ odstupanje procijenjene vrijednosti \hat{y}_i od izmjerene vrijednosti y_i zavisne varijable:

$$e_i = y_i - \hat{y}_i = y_i - (\hat{\alpha} + \hat{\beta}x_i)$$

- ▶ e_1, \dots, e_n zovemo **rezidualima** i možemo ih smatrati procjenama grešaka $\varepsilon_1, \dots, \varepsilon_n$ iz modela $Y_i = \alpha + \beta x_i + \varepsilon_i$

METODA NAJMANJIH KVADRATA

- ▶ suma kvadrata svih reziduala upravo je minimalna postignuta vrijednost za D , tj. $D(\hat{\alpha}, \hat{\beta})$, i predstavlja jednu mjeru kvalitete modela koju označavamo SSE (sum of squares of errors):

$$SSE = \sum_{i=1}^n e_i^2.$$

- ▶ R - primjer 1

STATISTIČKO ZALJUČIVANJE


- ▶ da bismo mogli koristiti dobiveni model potrebno je napraviti analizu prihvatljivosti modela
- ▶ istražujemo jesu li ispunjene osnovne pretpostavke klasičnog regresijskog modela: greške modela trebaju biti međusobno nezavisne i jednako distribuirane slučajne varijable s normalnom distribucijom
- ▶ dio analize modela koji se provodi u tu svrhu obično se naziva **analiza reziduala**

ANALIZA REZIDUALA

Jednakost varijanci grešaka

- ▶ imaju li $\varepsilon_1, \dots, \varepsilon_n$ jednake varijance? - homogenost varijanci grešaka
- ▶ zaključujemo na temelju procjena grešaka modela – reziduala e_1, \dots, e_n
- ▶ grafički prikažemo reziduale u ovisnosti o predikcijama – dijagram raspršenosti za točke $(\hat{y}_i, e_i), i = 1, \dots, n$
- ▶ ako u tom dijagramu uočavamo sustavno povećanje ili smanjenje raspršenosti, to je znak da varijance nisu homogene

ANALIZA REZIDUALA



parovi (\hat{y}_i, e_i) koji sugeriraju homogenost varijanci reziduala

ANALIZA REZIDUALA



ovakav raspored parova (\hat{y}_i, e_i) sugerira stalan rast varijance, dakle varijance nisu homogene


R - primjer 1

ANALIZA REZIDUALA

Nezavisnost grešaka


- ▶ jesu li $\varepsilon_1, \dots, \varepsilon_n$ nezavisne?
- ▶ zavisnost grešaka može se manifestirati na razne načine
- ▶ koristiti ćemo dvije grafičke metode:
 - ▶ dijagram raspršenosti reziduala u odnosu na vrijednosti nezavisne varijable
 - ▶ dijagram raspršenosti parova susjednih reziduala, tj. parova $(e_i, e_{i-1}), i = 2, \dots, n$
- ▶ ako nema nikakve pravilnosti u izgledu dijagrama, nemamo razloga sumnjati u nezavisnost

ANALIZA REZIDUALA



ovakav raspored parova (x_i, e_i) sugerira zavisnost grešaka modela

ANALIZA REZIDUALA



ovakav raspored parova (e_i, e_{i-1}) sugerira zavisnost grešaka modela

R - primjer 1

ANALIZA REZIDUALA

Normalna distribuiranost grešaka

- ▶ jesu li $\varepsilon_1, \dots, \varepsilon_n$ normalno distribuirane?
- ▶ možemo provjeriti KS testom i Shapiro-Wilk testom na rezidualima e_1, \dots, e_n
- ▶ nije nužan uvjet, ali ukoliko ne vrijedi treba biti oprezan u statističkom zaključivanju o modelu

ako nemamo razloga sumnjati u ispravnost prepostavki modela, možemo ga koristiti za zaključivanje o vezi između nezavisne i zavisne varijable

R - primjer 1

ZAKLJUČIVANJE O KOEFICIJENTU SMJERA REGRESIJSKOG PRAVCA

- ▶ je li model $Y_i = \alpha + \beta x_i + \varepsilon_i$ bolji od nul-modela $Y_i = \alpha + \varepsilon_i$ (modela u kojemu je $\beta = 0$)?
- ▶ koji od dva modela bolje opisuje promjene u očekivanju slučajnih varijabli Y_i u ovisnosti o vrijednostima x_i ?
- ▶ ako je $\beta = 0$, takav regresijski pravac bio bi paralelan s x -osi pa promjena vrijednosti nezavisne varijable ne bi rezultirala promjenom očekivanja zavisne varijable
- ▶ to možemo utvrditi statističkim testom čije su hipoteze

$$\mathcal{H}_0 : \beta = 0,$$

$$\mathcal{H}_1 : \beta \neq 0$$

ZAKLJUČIVANJE O KOEFICIJENTU SMJERA REGRESIJSKOG PRAVCA

- ▶ test se temelji na test-statistici čiju vrijednost \hat{t} za eksperimentalne vrijednosti x_i i y_i računamo formulom

$$\hat{t} = \frac{s_x \cdot \hat{\beta}}{s} \sqrt{n-1},$$

gdje je

$$s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2}, \quad s = \sqrt{\frac{SSE}{n-2}} = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n-2}},$$

a $\hat{\beta}$ procjena regresijskog koeficijenta β metodom najmanjih kvadrata

- ▶ ako je nul-hipoteza istinita, test-statistika ima Studentovu $t(n-2)$ distribuciju

ZAKLJUČIVANJE O KOEFICIJENTU SMJERA REGRESIJSKOG PRAVCA

- ▶ na temelju realizacije \hat{t} test statistike računamo pripadnu p -vrijednost na sljedeći način: $p = P(|T| \geq |\hat{t}|)$ gdje je T slučajna varijabla koja ima Studentovu $t(n - 2)$ distribuciju
- ▶ tako izračunatu p -vrijednost uspoređujemo s razinom značajnosti α i donosimo odluku kako slijedi:
 - ▶ ako je $p \leq \alpha$, odbacujemo nul-hipotezu i na razini značajnosti α prihvaćamo alternativnu hipotezu, tj. podaci potvrđuju da se promjene u vrijednosti nezavisne varijable odražavaju na promjene zavisne varijable na razini značajnosti α (model ima smisla)
 - ▶ ako je $p > \alpha$, nemamo dovoljno argumenata tvrditi da se promjene u vrijednosti nezavisne varijable odražavaju na promjene zavisne varijable na razini značajnosti α
- ▶ R - primjer 1

DIO VARIJABILNOSTI OBJAŠNJEN MODELOM

- ▶ koliki je dio promjena u eksperimentalnim vrijednostima zavisne varijable objašnjen dobivenim modelom?
- ▶ **koeficijent determinacije – R^2** definiran je izrazom

$$R^2 = \frac{s_{xy}^2}{s_x^2 s_y^2}, \quad R^2 \in [0, 1]$$

- ▶ koeficijent determinacije R^2 – u kolikoj mjeri je rasipanje eksperimentalnih vrijednosti zavisne varijable objašnjeno linearnom funkcijom $x \mapsto \alpha + \beta x$, a u kolikoj se mjeri radi o tzv. rezidualnom ili neobjašnjrenom rasipanju, a tu informaciju očitavamo iz broja $(1 - R^2)$

DIO VARIJABILNOSTI OBJAŠNJEN MODELOM

- ▶ velika vrijednost koeficijenta determinacije (R^2 blizu 1) ukazuje na to da linearan model objašnjava velik dio raspršenosti u eksperimentalnim vrijednostima zavisne varijable (samo mali dio je ostao neobjašnjen modelom i treba ga pripisati slučajnoj grešci)
- ▶ modeli kod kojih je R^2 mali nisu informativni za opis varijable Y korištenjem vrijednosti nezavisne varijable x jer opisuju samo mali dio varijablnosti u podacima iz Y , dok je veliki dio ostao neobjašnjen modelom
- ▶ [R - primjer 1](#)
- ▶ [R - primjeri 2 i 3](#)

MULTIVARIJATNI LINEARNI REGRESIJSKI MODEL

multivarijatni linearni regresijski model

$$Y_i = \alpha + \beta_1 x_i^{(1)} + \dots + \beta_k x_i^{(m)} + \varepsilon_i, \quad i = 1, \dots, n$$

- ▶ $x_1^{(k)}, x_2^{(k)}, \dots, x_n^{(k)}$ - vrijednosti nezavisnih (prediktorskih) varijable $x^{(k)}, k = 1, \dots, m$
- ▶ Y_1, Y_2, \dots, Y_n slučajne varijable (njihove izmjerene vrijednosti su y_1, \dots, y_n)
- ▶ $\alpha, \beta_1, \dots, \beta_m$ - regresijski koeficijenti koje procjenjujemo metodom najmanjih kvadrata
- ▶ $e_i = y_i - \hat{\alpha} - \hat{\beta}_1 x_i^{(1)} - \dots - \hat{\beta}_k x_i^{(m)}$ - reziduali (procjene grešaka), gdje su $\hat{\alpha}, \hat{\beta}_1, \dots, \hat{\beta}_m$ procjene regresijskih koeficijenata

STATISTIČKO ZAKLJUČIVANJE - VIŠE VARIJABLI

- ▶ dolazi li do promjene obilježja koje proučavamo zbog provođenja neke aktivnosti, u nekom drugom trenutku ili općenito u nekim drugim uvjetima?
- ▶ za dvije varijable (uzorka) možemo koristiti ranije obrađene metode
- ▶ za više od dvije varijable postoje analogne metode

USPOREDBA OČEKIVANJA

- ▶ promatrati ćemo jednu neprekidnu varijablu Y (zavisna varijabla)
- ▶ druga varijabla X (**faktor**) bit će diskretna s k različitim mogućih realizacija, $k \in \mathbb{N}$
- ▶ uzorak je veličine $n = n_1 + \dots + n_k$

$$y_{11}, \dots, y_{1n_1}$$

$$y_{21}, \dots, y_{2n_2}$$

$$\vdots$$

$$y_{k1}, \dots, y_{kn_k}$$

gdje je n_i veličina uzorka karakterizirana kategorijom faktora i , $i \in \{1, \dots, k\}$

USPOREDBA OČEKIVANJA

- ▶ pretpostavka: uzorci su nezavisni i iz normalnih distribucija s jednakim varijancama, odnosno

$$y_{11}, \dots, y_{1n_1} \quad \text{je uzorak iz } \mathcal{N}(\mu_1, \sigma^2)$$
$$y_{21}, \dots, y_{2n_2} \quad \text{je uzorak iz } \mathcal{N}(\mu_2, \sigma^2)$$

⋮

⋮

$$y_{k1}, \dots, y_{kn_k} \quad \text{je uzorak iz } \mathcal{N}(\mu_k, \sigma^2),$$

- ▶ želimo analizirati efekte faktora X na varijablu Y (slično kao kod jednostavne linearne regresije uz bitnu razliku što varijabla X predstavlja kategorije)

USPOREDBA OČEKIVANJA

- nul-hipoteza je

$$\mathcal{H}_0 : \mu_1 = \mu_2 = \dots = \mu_k$$

(očekivanje obilježja Y se ne mijenja u ovisnosti o kategorijama obilježja X)

- alternativnu hipotezu formuliramo kao dvostranu hipotezu

$$\mathcal{H}_1 : \text{postoje } i, j \in \{1, \dots, k\} \text{ takvi da je } \mu_i \neq \mu_j$$

- statistički test za ovu svrhu temelji se na analizi varijance cijelog uzorka i uzoraka po kategorijama faktora, te na F distribuciji (F -test)
- poznat je kao **(jednofaktorska) analiza varijance** (*one-way ANOVA*)
- provoditi usporedbu očekivanja višestrukom primjenom t -testa po parovima varijabli nije dobro jer rezultira većom pogreškom prvog tipa

USPOREDBA OČEKIVANJA

- ▶ test je relativno robustan na odstupanja od normalnosti pogotovo ako se radi o velikim uzorcima
- ▶ u slučaju da je homogenost varijanci narušena može se koristiti Welchova varijanta F -testa
- ▶ R - primjeri 4, 5 i 6

LITERATURA

- ▶ Benšić, M. i Šuvak, N., *Primijenjena statistika*, Odjel za matematiku, Sveučilište J.J. Strossmayera, Osijek, 2013.
- ▶ Benšić, M. i Šuvak, N., *Uvod u vjerojatnost i statistiku*, Odjel za matematiku, Sveučilište J.J. Strossmayera, Osijek, 2014.