

1. del: Linearna regresija in korelacija

1. Ugibanje korelacijskega koeficiente na podlagi razsevnega diagrama:
 - Uporabite dejavne spletne strani **Guessing Correlations** (v spletni brskalnik vtipkajte URL <http://www.stat.uiuc.edu/courses/stat100/java/GCApplet/GCAppletFrame.html> ali pa pridite do njih preko domače strani IBM po poti Povezave→Statistics→Teaching)!
 - Nalogo ponovite trikrat (uporabite gumb New Plots)!
2. Vaje z dejavnimi spletnimi stranmi **Illuminations Lessons: Investigating Linear Relationships: The Regression Line and Correlation** (http://illuminations.nctm.org/index_o.aspx?id=135):
 - Sledite povezavi Lesson 2: The Effects of Outliers. Odgovorite na **vprašanji a in b** v poročilu! Pri uporabi interaktivnega delovnega področja (koordinatni sistem z gumbi in okenci za določanje osi, izris regresijske premice in izbris točk) upoštevajte navodila, izpisana v rdeči barvi:
 - ob kazalniku miši so vseskozi izpisane trenutne koordinate;
 - točko dodate s klikom na levi gumb miši;
 - CTRL+klik na obstoječo točko (kadar je izbrana, se pojavi okoli kazalnika krogec) jo izbriše;
 - SHIFT+klik na obstoječo točko in držanje levega gumba miši pritisnjene točko premika.
 - Odgovorite na **vprašanja c, d in e** v poročilu!
3. Zaženite program SPSS in odprite datoteko C:\Statistika\Dodipl\RegX.
 - S postopkom Graphs → Scatter... (privzeta možnost Simple → gumb Define) narišite razsevni diagram, pri čemer naj bo **Y** odvisna spremenljivka (na ordinatni osi), **X** pa neodvisna spremenljivka (na abscisni osi)! V diagram vrišite regresijsko premico (z dvoklikom v diagram odprite **Chart Editor**; s klikom na eno od točk označite podatkovni niz; dodajte regresijsko premico s klikom na ikono Add fit line ali preko menija Chart → Add Chart Element → Fit Line at Total → gumb Close)! Geometrijsko ocenite približno vrednost regresijske konstante in regresijskega koeficiente ter presodite, kolikšna se vam zdi razpršenost točk okoli regresijske premice!
 - S postopkom Analyze → Regresion → Linear... za iste podatke izvedite linearno regresijsko analizo (v okence Dependent spravite spremenljivko **Y**, v okence Independent(s) pa **X**) ter dobljeni vrednosti regresijske konstante in regresijskega koeficiente primerjajte s približno ocenjenima! Zapišite enačbo regresijske premice ter interpretirajte korelacijski koeficient, regresijski koeficient in test statistične značilnosti regresijskega koeficiente!
4. Odprite datoteko PorX in preučite možnost premo sorazmerne napovedi porodne teže otroka na podlagi starosti matere, t.j. povezanost med spremenljivko **STAROST** kot prediktorjem in spremenljivko **PTO** kot kriterijem v linearinem modelu. Uporabite enak postopek (razsevni diagram, približna ocena parametrov, linearna regresija in korelacija) kot pri prejšnji nalogi!

2. del: Preizkušanje povezanosti opisnih spremenljivk

5. Preučujemo povezanost med kajenjem matere med nosečnostjo in nizko porodno težo otroka (glede na mejo 2500g je izračunana spremenljivka **NPTO**: 0=ne, t.j. normalna porodna teža; 1=da, t.j. nizka porodna teža).

- Izdelajte kontingenčno tabelo (postopek Analyze → Descriptive Statistics → Crosstabs...; spremenljivka **kajenje** naj določa vrstice, **NPTO** pa stolpce), ki naj poleg opaženih frekvenc vsebuje tudi pričakovane frekvence (gumb Cells...)! Presodite, ali so podatki ustrezni za uporabo testa hi-kvadrat! V zvezi s tem premislite, kateri dve možnosti imamo na razpolago, če želimo analizirati povezanost dveh opisnih spremenljivk s testom hi-kvadrat, dani podatki pa ne ustrezajo zahtevi o majhnem deležu celic z nizko pričakovano frekvenco!
- Odprite datoteko 500PorX! Ponovite postopek izdelave kontingenčne tabele s spremenljivkama **KAJ** (0=ne, t.j. mati ni kadila; 1=da, t.j. mati je kadila) in **NPTO**, pri čemer naj bo v celicah izpisana tudi relativna frekvenca kategorij **NPTO** za dano vrednost **KAJ** (t.j. vrstični delež), za vsako celico pa nato ročno izračunajte razliko med opaženo in pričakovano frekvenco! Hkrati izvedite tudi test hi-kvadrat (gumb Statistics... → opcija Chi-square)! Interpretirajte dobljene rezultate!

2. a) Pritisnite CLEAR; narišite točke, ki kažejo naraščanje z leve na desno; pritisnite SHOW GRAPH.

- Ali se premica dobro prilega točkam? _____
- Ali enačba regresijske premice kaže pozitiven naklon? _____

b) Dodajte točko, ki odstopa od trenda.

- Kaj se zgodi z regresijsko premico? Razložite!

- Zgrabite osamelca in ga vlecite naokoli! Kako se pri tem spreminja regresijska premica?

c) Izdelajte razsevni diagram, ki ima točno določeno vrednost korelacijske koeficiente:

- $r = 1$
- $r = -1$
- $r = 0$

d) V levem spodnjem kotu koordinatne ravnine narišite oblak točk, ki ne kažejo nikakršnega trenda. Potem narišite eno točko v desnem zgornjem kotu.

- Ali dobljeni razsevni diagram kaže linearno povezanost? _____
- Je vrednost r blizu ena? _____

e) Ali visoka vrednost r nujno pomeni, da so podatki linearni? _____

Ali vrednost r blizu nič vedno pomeni, da podatki niso linearni? _____

3. Približna ocena na podlagi razsevnega diagrama:

$$\begin{array}{ll} a & \approx \underline{\hspace{2cm}} \\ b & \approx \underline{\hspace{2cm}} \end{array}$$

razpršenost točk okoli regresijske premice (obkrožite): majhna zmerna velika

Rezultati linearne regresije:

$$\begin{array}{ll} a & = \underline{\hspace{2cm}} \\ b & = \underline{\hspace{2cm}} \end{array}$$

enačba regresijske premice: _____

interpretacija regresijskega koeficienta: _____

$$r = \underline{\hspace{2cm}}$$

interpretacija korelacijskega koeficienta: _____

$$SE_b = \underline{\hspace{2cm}}$$

$$t = \underline{\hspace{2cm}}$$

$$p = \underline{\hspace{2cm}}$$

interpretacija testa statistične značilnosti regresijskega koeficienta: _____

4. Približna ocena na podlagi razsevnega diagrama:

$$a \approx \underline{\hspace{2cm}}$$

$$b \approx \underline{\hspace{2cm}}$$

razpršenost točk okoli regresijske premice (obkrožite): majhna zmerna velika

Rezultati linearne regresije:

$$a = \underline{\hspace{2cm}}$$

$$b = \underline{\hspace{2cm}}$$

enačba regresijske premice: $\underline{\hspace{5cm}}$

interpretacija regresijskega koeficienta: $\underline{\hspace{5cm}}$

$$r = \underline{\hspace{2cm}}$$

interpretacija korelacijskega koeficienta: $\underline{\hspace{5cm}}$

$$SE_b = \underline{\hspace{2cm}}$$

$$t = \underline{\hspace{2cm}}$$

$$p = \underline{\hspace{2cm}}$$

interpretacija testa statistične značilnosti regresijskega koeficienta: $\underline{\hspace{5cm}}$

$\rule{1cm}{0.4pt}$

5. Analiza vzroca velikosti $N=96$:

So podatki ustrezni za uporabo testa hi-kvadrat? $\underline{\hspace{2cm}}$

Zakaj? $\underline{\hspace{5cm}}$

Možnosti:

- $\underline{\hspace{2cm}}$
- $\underline{\hspace{2cm}}$

Analiza vzorca velikosti $N=500$:

$$f_O - f_P \quad \text{celica A } \underline{\hspace{1cm}} \quad \text{celica B } \underline{\hspace{1cm}} \\ \text{celica C } \underline{\hspace{1cm}} \quad \text{celica D } \underline{\hspace{1cm}}$$

delež celic s $f_P < 5$ = $\underline{\hspace{2cm}}$ \Rightarrow podatki $\underline{\hspace{2cm}}$ ustrezni za uporabo testa hi-kvadrat

$$\chi^2 = \underline{\hspace{2cm}}$$

$$p = \underline{\hspace{2cm}}$$

interpretacija rezultatov testa hi-kvadrat: $\underline{\hspace{5cm}}$

$\rule{1cm}{0.4pt}$