

Predavanje 5

KORELACIJA I REGRESIJA

Pregled

- Regresijom i korelacijom analizira se povezanost (zavisnost, odnos) dve ili više varijabli .
- Dve varijable su povezane ako promenama jedne varijable odgovaraju promene kod druge varijable.
- Korelacija - analizira jačinu i smer povezanosti .
- Regresija - analizira oblik povezanosti.
- Regresioni model omogućava predikciju vrednosti zavisne varijable na osnovu poznavanja vrednosti nezavisnih varijabli.
- Posmatrane varijable treba da budu zavisne tj. da predstavljaju komponente višedimenzionalne slučajne promenljive.

Korelacija

Korelacija


Korelacija je veza između dve varijable.

Dvodimenzionalni podaci su predstavljeni uređenim parovima (x, y) .





Dijagram rasipanja (scatter plot) je grafikon koji nam sugeriše postojanje i oblik zavisnosti između varijabli.

Primer:

x	1	2	3	4	5
y	-4	-2	-1	0	2



Linearna korelacija



Koeficijent korelacije

Koeficijent korelacije (Pirsonov, r) je mera jačine i smera linearne veze između dve varijable.

$$r = \frac{S_{XY}}{S_X S_Y}$$





Diagram illustrating the components of the Pearson correlation coefficient formula:

- S_{XY} is labeled as **kovarijansa** (Covariance).
- $S_X S_Y$ is labeled as **Standardne devijacije** (Standard deviations).

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{n \sum x^2 - (\sum x)^2} \sqrt{n \sum y^2 - (\sum y)^2}}.$$

- Vrednost koeficijenta r je u intervalu od -1 do 1 .
- Ako su x i y u jakoj **pozitivnoj** / **negativnoj** korelaciji, r je blizu **1/-1**.
- Ako x i y nisu u linearnoj korelaciji, r je blizu 0 .

Primeri koeficijenta korelacije



Primer:

Izračunati i okarakterisati koeficijent korelacije:

x	y	xy	x^2	y^2
1	-3	-3	1	9
2	-1	-2	4	1
3	0	0	9	0
4	1	4	16	1
5	2	10	25	4
$\sum x = 15$	$\sum y = -1$	$\sum xy = 9$	$\sum x^2 = 55$	$\sum y^2 = 15$

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{n \sum x^2 - (\sum x)^2} \sqrt{n \sum y^2 - (\sum y)^2}} = \frac{5(9) - (15)(-1)}{\sqrt{5(55) - 15^2} \sqrt{5(15) - (-1)^2}} \approx 0.986$$

Postoji jaka pozitivna linearna korelacija između x i y .

Testiranje koeficijenta korelacije populacije

- Na osnovu izračunatog koeficijenta korelacije r možemo proceniti značajnost koeficijenta korelacije populacije ρ .
- Statistički test, sa nultom hipotezom $H_0(\rho=0)$.
- Ako je p-vrednost testa manja od zadatog praga značajnosti, odbacujemo nultu hipotezu i zaključujemo da postoji statistički značajna korelacija.
- Test je veoma senzitivan na obim uzorka (broj parova podataka), npr.

n	$\alpha = 0.05$	$\alpha = 0.01$
4	0.950	0.990
5	0.878	0.959
6	0.811	0.917
7	0.754	0.875

Tabela prikazuje granične vrednosti značajnih koeficijenata korelacije $|r|$.

Test statistika

***t*-Test za koeficijent korelacije**

Za određivanje značajnosti koeficijenta korelacije između dve promenljive koristimo sledeću test statistiku:

$$t = \frac{r}{\sigma_r} = \frac{r}{\sqrt{\frac{1-r^2}{n-2}}}$$

Koja ima Studentovu raspodelu sa $n - 2$ stepena slobode.

Primer:

Podaci predstavljaju broj sati provedenih na FB tokom vikenda i broj osvojenih poena na testu u ponedjeljak. Proveriti da li sa pragom značajnosti $\alpha = 0.01$ postoji značajna linearna korelacija?

Broj sati, x	0	1	2	3	3	5	5	5	6	7	7	10
Broj poena, y	96	85	82	74	95	68	76	84	58	65	75	50

- *Koeficijent korelacije $r \approx -0.831$.*

Nastavak primera:

$H_0: \rho = 0$ (nema korelacije) $H_a: \rho \neq 0$ (značajna korelacija)

Prag značajnosti je $\alpha = 0.01$.


d.f. = $12 - 2 = 10$.

Kritične vrednosti: $-t_0 = -3.169$ i $t_0 = 3.169$.

Test statistika:

$$t = \frac{r}{\sqrt{\frac{1-r^2}{n-2}}} = \frac{-0.831}{\sqrt{\frac{1-(-0.831)^2}{12-2}}} \approx -4.72.$$

Test statistika upada u region odbacivanja, pa odbacujemo H_0 .




Sa pragom značajnosti 1% zaključujemo da postoji značajna negativna korelacija između vremena provedenog na FB i ostvarenog uspeha na testu u ponedeljak.

Korelacija i kauzalnost

Činjenica da su dve varijable u jakoj korelaciji **ne** podrazumeva da između njih postoji uzročno-posledična tj. kauzalna veza.


Postoje 3 mogućnosti:



LINEARNA REGRESIJA

Reziduali

Ako između x i y postoji značajna linearna korelacija, možemo odrediti jednačinu prave koja tu zavisnost opisuje. Ta prava je **prava linearne regresije**.



Za svaki par (x_i, y_i) možemo izračunati razliku opažene i predviđene vrednosti d_i , koja se zove **rezidual**.

Regresiona prava

Regresiona prava je ona prava za koju je suma kvadrata reziduala minimalna.

Jednačina regresione prave

$$\hat{y} = mx + b$$

$$m = \frac{n \sum xy - (\sum x)(\sum y)}{n \sum x^2 - (\sum x)^2} \text{ and } b = \bar{y} - m\bar{x} = \frac{\sum y}{n} - m \frac{\sum x}{n}$$

where $\bar{y}$ is the mean of the y -values and $\bar{x}$ is the mean of the x -values. The regression line always passes through $(\bar{x}, \bar{y})$.

Primer:

Odrediti jednačinu regresione prave.

x	y	xy	x^2	y^2
1	-3	-3	1	9
2	-1	-2	4	1
3	0	0	9	0
4	1	4	16	1
5	2	10	25	4
$\Sigma x = 15$	$\Sigma y = -1$	$\Sigma xy = 9$	$\Sigma x^2 = 55$	$\Sigma y^2 = 15$


$$m = \frac{n \Sigma xy - (\Sigma x)(\Sigma y)}{n \Sigma x^2 - (\Sigma x)^2} = \frac{5(9) - (15)(-1)}{5(55) - (15)^2} = \frac{60}{50} = 1.2$$

Nastavak primera:

$$b = \bar{y} - m\bar{x} = \frac{-1}{5} - (1.2)\frac{15}{5} = -3.8$$

Jednačina regresione prave glasi:

$$\hat{y} = 1.2x - 3.8.$$



Primer:

Podaci predstavljaju broj sati provedenih na FB tokom vikenda i broj osvojenih poena na testu u ponedjeljak.

- odrediti jednačinu regresione prave.
- iskoristiti dobijenu jednačinu za predikciju broja bodova studenta koji je proveo 9h na FB.

Broj sati, x	0	1	2	3	3	5	5	5	6	7	7	10
Broj poena, y	96	85	82	74	95	68	76	84	58	65	75	50
xy	0	85	164	222	285	340	380	420	348	455	525	500
x^2	0	1	4	9	9	25	25	25	36	49	49	100
y^2	9216	7225	6724	5476	9025	4624	5776	7056	3364	4225	5625	2500

$$\sum x = 54$$

$$\sum y = 908$$

$$\sum xy = 3724$$

$$\sum x^2 = 332$$


$$\sum y^2 = 70836$$

Nastavak primera:

$$m = \frac{n \sum xy - (\sum x)(\sum y)}{n \sum x^2 - (\sum x)^2} = \frac{12(3724) - (54)(908)}{12(332) - (54)^2} \approx -4.067$$

$$\begin{aligned} b &= \bar{y} - m\bar{x} \\ &= \frac{908}{12} - (-4.067)\frac{54}{12} \\ &\approx 93.97 \end{aligned}$$

$$\hat{y} = -4.07x + 93.97$$



Nastavak primera:

Koristeći jednačinu $\hat{y} = -4.07x + 93.97$, možemo predvideti bodove za provedenih 9 sati na FB.

$$\begin{aligned}\hat{y} &= -4.07x + 93.97 \\ &= -4.07(\textcolor{red}{9}) + 93.97 \\ &= 57.34\end{aligned}$$

Možemo očekivati da student koji provede 9 sati na FB tokom vikenda osvoji 57 bodova na testu u ponedeljak.


Predikcija može biti **interpolacija (unutar opsega X-a)** i **ekstrapolacija (van opsega X-a)**.

Varijacija regresione prave

Da bi izračunali totalnu varijaciju regresione prave, moramo izračunati: **totalnu devijaciju, objašnjenu devijaciju** i **neobjašnjenu devijaciju**.

$$\text{Total deviation} = y_i - \bar{y} \quad \text{Explained deviation} = \hat{y}_i - \bar{y}$$

$$\text{Unexplained deviation} = y_i - \hat{y}_i$$



Totalna varijacija regresione prave predstavlja sumu kvadrata totalnih devijacija (razlika opažene i izračunate srednje vrednosti y)

$$\text{Total variation} = \sum (y_i - \bar{y})^2$$

Objašnjena varijacija regresione prave predstavlja sumu kvadrata objašnjenih devijacija

$$\text{Explained variation} = \sum (\hat{y}_i - \bar{y})^2$$

Nebjašnjena varijacija regresione prave predstavlja sumu kvadrata neobjašnjenih devijacija (razlika opažene i predviđene vrednosti y)

$$\text{Unexplained variation} = \sum (y_i - \hat{y}_i)^2$$

Totalna var = Objašnjena var + neobjašnjena var

Koeficijent determinacije

Koeficijent determinacije r^2 predstavlja odnos objašnjene i ukupne varijacije:

$$r^2 = \frac{\text{Explained variation}}{\text{Total variation}}$$

Primer:

Ako je koeficijent korelacije između vremena na FB i uspeha na testu $r \approx -0.831$, izračunaj i prokomentariši koeficijent determinacije.

$$\begin{aligned} r^2 &\approx (-0.831)^2 \\ &\approx 0.691 \end{aligned}$$

Oko 69.1% varijacije kod uspeha na testu je objašnjeno vremenom na FB. Ostalih 30.9% varijacije je neobjašnjeno.

Standardna greška procene

Kada se procenjena $\hat{y}$ -vrednost računa na osnovu prave za datu vrednost x , u pitanju je tačkasta ocena.

Moguće je konstruisati i interval poverenja za y .

Standardna greška procene s_e je srazmerna neobjašnjenjnoj varijaciji, i izračunava se po sledećoj formuli (gde je n broj parova podataka):

$$s_e = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n - 2}}$$

Što su bliže predviđene i opažene vrednosti, to je manja standardna greška procene.

Primer:

Za date parove podataka je određena regresiona prava

$$\hat{y} = 1.2x - 3.8.$$

Izračunati standardnu grešku procene.

x_i	y_i	$\hat{y}_i$	$(y_i - \hat{y}_i)^2$
1	-3	-2.6	0.16
2	-1	-1.4	0.16
3	0	-0.2	0.04
4	1	1	0
5	2	2.2	0.04
			$\Sigma = 0.4$

Neobjašnjena
varijacija

$$s_e = \sqrt{\frac{\Sigma(y_i - \hat{y}_i)^2}{n - 2}} = \sqrt{\frac{0.4}{5 - 2}} \approx 0.365$$

Standardna greška procene iznosi približno 0.365.

Interval poverenja za y

Za datu jednačinu regresione prave $\hat{y} = mx + b$ i za datu vrednost x_0 (konkretnu vrednost promenljive x),
 c -interval poverenja za y je

$$\hat{y} - E < y < \hat{y} + E$$

Gde je

$$E = t_c s_e \sqrt{1 + \frac{1}{n} + \frac{n(x_0 - \bar{x})^2}{n \sum x^2 - (\sum x)^2}}.$$

E je margina greške, $\hat{y}$ je tačkasta predviđena vrednost.
Verovatnoća da interval sadrži pravu vrednost y iznosi c .

Interval poverenja

Primer:

Za podatke koji predstavljaju vreme provedeno na FB tokom vikenda i broj osvojenih bodova na testu u ponedeljak, konstruisati 95% interval poverenja za predikciju broja bodova studenta koji je 4 sata proveo na FB.

sati, x	0	1	2	3	3	5	5	5	6	7	7	10
poeni, y	96	85	82	74	95	68	76	84	58	65	75	50

$$\hat{y} = -4.07x + 93.97$$

$$s_e = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n - 2}} = \sqrt{\frac{658.25}{12 - 2}} \approx 8.11$$

Nastavak primera:

Broj stepeni slobode je $n - 2 = 12 - 2 = 10$.

Tačkasta ocena broja bodova je:

$$\hat{y} = -4.07x + 93.97 = -4.07(4) + 93.97 = 77.69.$$

Kritična vrednost je $t_c = 2.228$, i margina $E = 18.83$.

$$\hat{y} - E < y < \hat{y} + E$$

$$77.69 - 18.83 = 58.86$$

$$77.69 + 18.83 = 96.52$$

Sa sigurnošću 95% možemo tvrditi da će broj bodova kod studenta koji provede 4h na FB biti između 58.86 i 96.52.

Regresiona analiza - rezime

- Regresija koju smo videli je najjednostavniji vid regresione analize – **jednostruka linearna regresija**.
- Postoje mnoga uopštenja:
 - **Višestruka linearna regresija** – više nezavisnih varijabli, jedna zavisna varijabla, linearna veza.
 - **Polinomijalna regresija** – jedna ili više nezavisnih varijabli, polinomna veza.
 - **Logistička regresija** – koristi se za kombinaciju neprekidnih i kategoričkih nezavisnih varijabli i jednu, obično dihotomnu zavisnu varijablu (npr. predikcija pojave bolesti u zavisnosti od pojave više simptoma).
 - ...