

Proučavanje povezanosti između kontinuiranih varijabli

19.01.2024.


Rosa Karlić

Dva moguća cilja


- Opisati odnose između dvije ili više kontinuiranih varijabli
- Koristiti navedene odnose za predviđanje vrijednosti varijabli

Kovarijanca

- Kovarijanca – koliko se jedna varijabla mijenja kad se druga varijabla mijenja σ_{XY}
- Kovarijanca uzorka: $s_{XY} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n-1}$



Kovarijanca





Izvor: <https://stats.stackexchange.com/questions/18058/how-would-you-explain-covariance-to-someone-who-understands-only-the-mean>

- Proporcionalna skali na kojoj su mjereni X i Y
- Osjetljiva na *outliere* (netipične vrijednosti)

Korelacija



- Korelacija – kovarijanca normalizirana standardnom devijacijom
- Koeficijent korelacije – mjeri snagu odnosa između dviju varijabli
- Pearsonov koeficijent korelacije – linearni odnosi

$$\rho = \frac{Cov(X, Y)}{\sigma_X \sigma_Y}$$





Spearmanov koeficijent korelacijske

- Pearsonov koeficijent korelacijske nakon što su vrijednosti varijabli pretvorene u rangove
- Nulta hipoteza: nema monotonog odnosa između dvije varijable



Značajna povezanost među varijablama?




ABSOLUTE VALUE OF R	INTERPRETATION
< 0.19	Slight; almost no relationship
0.20–0.39	Low correlation; definite but small relationship
0.40–0.69	Moderate correlation; substantial relationship
0.70–0.89	High correlation; strong relationship
0.90–1.00	Very high correlation; very dependable relationship
≥ 0.30	Practically significant relationship

Izvor: <https://doi.org/10.4102/sajhrm.v7i1.175>

- Koeficijent determinacije = r^2 jačina povezanosti

Korelacija u biološkim eksperimentima



- a-f. Scatter plot analysis to determine correlation coefficients between and within platforms using Jurkat RNA as an example. Correlations for all cell lines are given in Table 4. (a) Operon versus Incyte (b) Affymetrix versus Incyte (c) Affymetrix versus Operon (d) GEM2 versus GEM2 replicate correlation (e) Operon versus Operon (f) HG-U133A versus HG-U133A

Petersen, D., Chandramouli, G., Geoghegan, J. et al. Three microarray platforms: an analysis of their concordance in profiling gene expression. *BMC Genomics* 6, 63 (2005). <https://doi.org/10.1186/1471-2164-6-63>

Korelacija u biološkim eksperimentima






Figure 1 Comparison of RNA-seq replicate experiments. The FPKM for biological replicate 1 is plotted against biological replicate 2 for each gene, demonstrating strong correlation between replicate experiments at each time point. The correlation coefficient, R , is shown for each time point.

Korelacija – uzorkovanje iz više različitih populacija




<https://www.frontiersin.org/articles/10.3389/fsysb.2023.1042156/full>

Korelacija – uzorkovanje iz više različitih populacija




<https://www.frontiersin.org/articles/10.3389/fsysb.2023.1042156/full>

Korelacija – utjecaj netipičnih točaka (outliers)



<https://www.frontiersin.org/articles/10.3389/fsysb.2023.1042156/full>

Korelacija – uzorci nisu međusobno neovisni



Tumačenje i značajnost koeficijenta korelaciјe

Pitanje: U istraživanju povezanosti raspoloženja i količine tekućine unesene pijenjem tijekom dana dobivena je povezanost $r = 0,12$; $P = 0,003$. Je li ispravno zaključiti kako postoji značajna povezanost raspoloženja i količine pojedine tekućine?

Tumačenje i značajnost koeficijenta korelacijske

Pitanje: U istraživanju povezanosti raspoloženja i količine tekućine unesene pijenjem tijekom dana dobivena je povezanost $r = 0,12$; $P = 0,003$. Je li ispravno zaključiti kako postoji značajna povezanost raspoloženja i količine pojedine tekućine?

Odgovor: Nije ispravno.

Tumačenje: Nakon izračuna koeficijenta korelacijske važno je znati kako rezultat protumačiti, odnosno objasniti što vrijednosti koeficijenta korelacijske zaista znače. U prikazu rezultata korelacija obvezno se navode koeficijent povezanosti (korelacijski "r") i to brojem s dva decimalna mesta, te značajnost koeficijenta korelacijski "P" brojem s tri decimalna mesta (4). Ukoliko je koeficijent korelacijski značajan s obzirom na postavljenu granicu značajnosti (uobičajeno $P < 0,05$), zaključujemo da je koeficijent korelacijski značajan i da se smije tumačiti. Ukoliko je vrijednost $P > 0,05$ zaključujemo da koeficijent korelacijski nije značajan i tada se bez obzira na njegovu vrijednost ne smije tumačiti.

Tumačenje i značajnost koeficijenta korelaciјe

Pitanje: U istraživanju povezanosti koncentracije alkohola u krvi i prometnih nesreća utvrđeni su $r = 0,78$ i $P=0,002$. Možemo li zaključiti kako uzimanje alkohola uzrokuje prometne nesreće, tj. promatrane prometne nesreće su posljedica uzimanja alkohola?

Tumačenje i značajnost koeficijenta korelaciјe

Pitanje: U istraživanju povezanosti koncentracije alkohola u krvi i prometnih nesreća utvrđeni su $r = 0,78$ i $P=0,002$. Možemo li zaključiti kako uzimanje alkohola uzrokuje prometne nesreće, tj. promatrane prometne nesreće su posljedica uzimanja alkohola?


Odgovor: Ne, ne možemo.

Tumačenje: Korelacija govori o povezanosti, a ne o uzročno posljedičnoj vezi među varijablama. Dakle, ukoliko postoji visoka povezanost između uzimanja alkohola i prometnih nesreća ne možemo zaključiti da jedna varijabla utječe na drugu, odnosno da uzimanje alkohola uzrokuje nesreće u prometu. Moguće je da veća količina alkohola uzorkuje više prometnih nesreća, no postoji mogućnost značajnog utjecaja ostalih neispitivanih čimbenika ili rijetkih događaja (7,8). U opisanom primjeru to bi moglo biti stanje na cesti, ispravnost vozila, moguća bolest vozača nevezana za alkohol, djelovanje drugih farmakološki aktivnih tvari i sl.

Linearna regresija

- Jednostavan kvantitativni model

	Daily calorific input (kcal)	Body mass (g)
1	8.6	22.1
2	2.9	21.1
3	4.4	22.3
4	4.9	22.2
5	9.7	25.3
6	9.7	24.5
7	6.3	23.6
8	4.7	22.5
9	7.2	24.3
10	6.9	22.5



Best-fitting linear model

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i$$

Linearna regresija

```
> f <- lm(mass ~ kcal, data=ms)
> summary(f)
```

Call:
lm(formula = mass ~ kcal, data = ms)

Residuals:

Min	1Q	Median	3Q	Max
-1.8462	-0.2947	0.1323	0.5608	0.9667

Coefficients:


	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	20.1813	0.8750	23.065	1.33e-08 ***
kcal	0.4378	0.1269	3.449	0.00871 **

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.8862 on 8 degrees of freedom

Multiple R-squared: 0.5979, Adjusted R-squared: 0.5476

F-statistic: 11.9 on 1 and 8 DF, p-value: 0.008709



- β_0 odsječak na osi Y (i.e. prosječna vrijednost Y ako su svi X jednaki 0)
- β_i prosječno povećanje Y kad se X_j poveća za 1 jedinicu i svi ostali X su konstantni



Linearna regresija

$$R^2 = 1 - \frac{\text{variance explained by the model}}{\text{total variance}}$$

$$R^2 = 1 - \frac{\sum(y_i - f(x_i))^2}{\sum(y_i - \bar{y})^2}$$


It is a measure of fit quality.
The higher R^2 , the better fit.

Adjusted R^2 takes into
account number of model
parameters.



Kategorički prediktori

	Body mass (g)	Diet
1	16.8	norm
2	20.9	norm
3	25.8	hifat
4	38.0	hifat
5	31.6	hifat



$$\begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \\ y_5 \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 1 & 0 \\ 0 & 1 \\ 0 & 1 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix} + \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \epsilon_4 \\ \epsilon_5 \end{pmatrix}$$

```
> f1 <- lm(mass ~ diet, data = mdat)
> summary(f1)


Estimate Std. Error t value Pr(>|t|)
(Intercept) 18.900     3.708   5.098  0.0146 *
diethifat   12.900     4.787   2.695  0.0741 .
```

H_0 : effect size is equal zero

dietfat = difference between normal and high-fat diet

Više od jednog prediktora

	Body mass (g)	Diet	Sex
1	16.9	norm	f
2	20.9	norm	f
3	15.8	norm	f
4	28.0	norm	m
5	21.6	norm	m
6	15.9	norm	m
7	32.4	hifat	f
8	33.7	hifat	f
9	32.9	hifat	f
10	28.5	hifat	m
11	37.6	hifat	m
12	31.9	hifat	m



Linearna regresija s interakcijama


```
> f <- lm(mass ~ diet + sex + diet:sex, data = mds)
> summary(f)$coefficients
```

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	17.867	2.335	7.652	6.01e-05 ***
diethifat	15.133	3.302	4.583	0.00179 **
sexm	3.967	3.302	1.201	0.26400
diethifat:sexm	-4.300	4.670	-0.921	0.38407

Interaction not significant, we are overfitting

Pregled reziduala

- Reziduali sadrže informacije o tome zašto model možda ne odgovara podacima
- Reziduali – uočene pogreške ako je model točan
- Pretpostavke o pogreškama:
 - Pogreške su neovisne
 - Slijede normalnu distribuciju sa srednjom vrijednošću 0 i konstantnom varijancom σ^2
 - Nakon ispitivanja reziduala možemo zaključiti vrijede li ove pretpostavke ili ne






$$\varepsilon_i \sim N(0, \sigma^2)$$





Testiranje normalnosti reziduala

- Grafičke metode:
 - Histogram
 - Kvantil-kvantil prikaz s obzirom na standardnu normalnu distribuciju
- Testovi za normalnost
 - Anderson-Darling test, Shapiro-Wilk test, Lilliefors test (adaptacija Kolmogorov-Smirnoff testa), D'Agostino-Pearson test...



Je li linearan model prikladan za sljedeće analize?







Grafički prikaz reziduala



Ne-linearni odnosi







High leverage points (točke visokog utjecaja)



Provjeriti vremenske učinke, nestalnu varijancu, potrebu za transformacijom i zakrivljenost


- Zadovoljavajući dijagram reziduala trebao bi pokazivati slučajni uzorak
- Nezadovoljavajući prikazi reziduala:




$$p(X) = \frac{e^{\beta_0 + \beta_1 X}}{1 + e^{\beta_0 + \beta_1 X}}$$

Logistička regresija

Case/control



The G allele is associated with disease



$$\ln(P(X)/1-P(X)) = \alpha + \beta X + \varepsilon$$

β = difference in log odds for cases vs. controls

$e^{(\beta)}$ = difference in odds
= Odd Ratio (OR)

Allelic effect is an OR:

OR > 1 increased risk

OR < 1 decreased risk

Adapted from <https://www.colorado.edu/ibg/isg-workshop/isgw-online-resources/b1-introduction-gwas-part-1>