

Statistika i osnovna mjerenja

Dvodimenzionalne raspodjele i korelacija

M. Makek
2017/2018

Višedimenzionalne raspodjele

Primjer: u eksperimentu sudaramo 2 protona

- Prije sudara oni imaju energiju i impuls $E_1, p_1; E_2, p_2$
- Nakon sudara nastaje mnoštvo različitih čestica s energijama i impulsima E_k', p_k'
- Da bismo odredili energiju i impuls čestice u konačnom stanju mjerimo npr. njen impuls u magnetskom spektrometru i energiju u kalorimetru.
- U tom slučaju energija i impuls su kontinuirane slučajne varijable
- Pitanja: da li su nezavisne? Ako ne, kako su one povezane? Kako su povezane sa energijama i impulsima ostalih čestica?
- U eksperimentima se često opaža veći broj varijabli, koje mogu biti neovisne ili povezane, o čemu će ovisiti analiza rezultata i račun pogreške

Dvodimenzionalne raspodjele

- Uzmimo **dvije** diskretne slučajne varijable **X** i **Y** definirane na istom prostoru elementarnih događaja
- Def: **združena raspodjela vjerojatnosti** $p(x,y)$ za diskretne slučajne varijable X i Y je vjerojatnost da istodobno X poprimi vrijednost x i Y poprimi vrijednost y:

$$p(x,y) = P(X=x \text{ i } Y=y)$$

- Def: Rubne raspodjele vjerojatnosti za varijable X i Y označavamo s $p_X(x)$ i $p_Y(y)$, a dane su izrazima:

$$p_X(x) = \sum_{y \in D_Y} p(x,y) \quad p_Y(y) = \sum_{x \in D_X} p(x,y)$$

→ vjerojatnost da pojedina varijabla iz združene raspodjele poprimi neku vrijednost bez obzira na drugu varijablu.

Dvodimenzionalne raspodjele

- Primjer: studenti prve godine razvrstani po ocjenama (varijabla X) i spolu (varijabla Y)

Ocjena	Muško	Žensko	UKUPNO
1	10	2	12
2	13	3	16
3	15	7	22
4	18	7	25
5	4	3	7
UKUPNO	60	22	82

- Na temelju raspodjele definiramo vjerojatnost a posteriori:

- *Vjerojatnost* da student bude žensko i ima ocjenu 3 je $7/82$, a vjerojatnost student bude muško i ima ocjenu 3 je $15/82$.
- *Rubna vjerojatnost* da bilo koji student ima ocjenu 3 je $22/82$, a rubna vjerojatnost da student bude muško je $60/82$

Dvodimenzionalne raspodjele

- Za kontinuirane slučajne varijable X, Y definiramo zduženu funkciju gustoće vjerojatnosti $f(x,y)$, tako da za bilo koji dvodimenzionalni interval $A \subseteq \mathbb{R} \times \mathbb{R}$ vrijedi:

$$P((X,Y) \in A) = \iint_A f(x,y) dx dy$$

- Zdužena funkcija gustoće vjerojatnosti mora zadovoljavati uvjete: $f(x,y) \geq 0, \quad \forall x,y \quad \iint_{\mathbb{R} \times \mathbb{R}} f(x,y) dx dy = 1$
- Rubne funkcije gustoće vjerojatnosti definiramo kao:

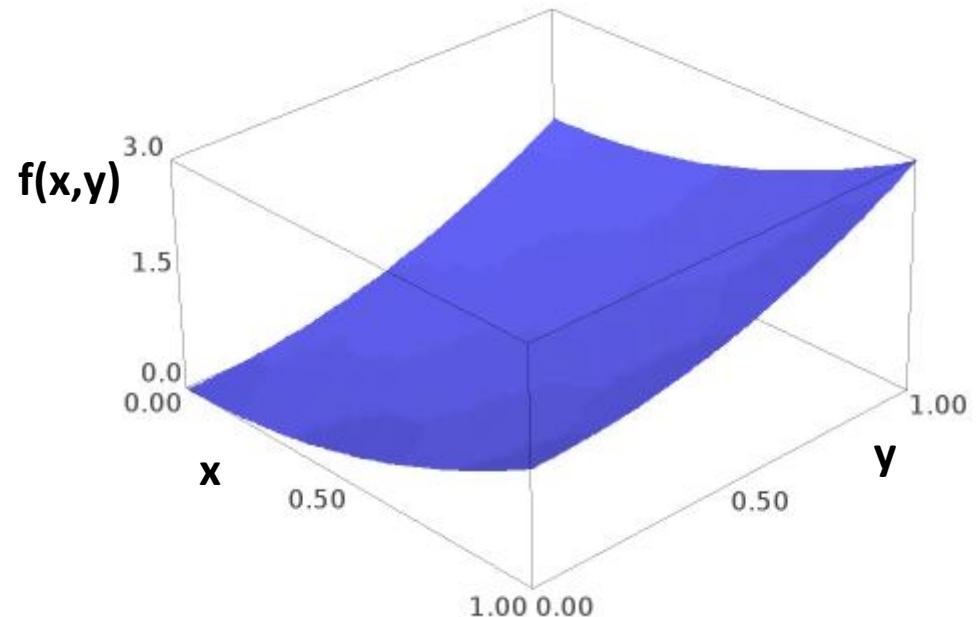
$$f_X(x) = \int_{-\infty}^{\infty} f(x,y) dy \quad f_Y(y) = \int_{-\infty}^{\infty} f(x,y) dx$$

Dvodimenzionalne raspodjele

- Primjer: zdržena funkcija gustoće vjerojatnosti je:

$$f(x,y) = \begin{cases} \frac{3}{2}(x^2 + y^2), & x \in [0,1], y \in [0,1] \\ 0, & \text{inače} \end{cases}$$

- Koja je vjerojatnost da je $X < 1/4$ i $Y < 1/4$?
- Koja je vjerojatnost da je $X < 1/4$ bez obzira na Y ?



Podsjetnik: uvjetna vjerojatnost i nezavisnost događaja

- Definicija: događaji A i B su nezavisni onda i samo onda kad vrijedi:

$$P(A|B) = P(A)$$

(Vjerojatnost da se dogodi A ne ovisi o tome da li se dogodio B)

- Iz definicije uvjetne vjerojatnosti slijedi:

$$P(A|B) = \frac{P(A \cap B)}{P(B)} = P(A)$$

- Iz toga slijedi:

$$P(A \cap B) = P(A)P(B)$$

Uvjetna vjerojatnost

- Neka su X i Y kontinuirane slučajne varijable sa zdrženom funkcijom gustoće vjerojatnosti $f(x,y)$ i rubnom funkcijom $f_X(x)$. Uvjetna funkcija gustoće vjerojatnosti za varijablu Y , ako je $X=x$ je:

$$f_{(Y|X)} = \frac{f(x,y)}{f_X(x)}$$

Uz uvjet da je $f_X(x) \neq 0$

- Analogno pomoću raspodjela vjerojanosti definiramo uvjetnu vjerojatnost za diskretne varijable:

$$p_{(Y|X)} = \frac{p(x,y)}{p_X(x)}$$

Nezavisne slučajne varijable

- Svaka slučajna varijabla predstavlja ishod nekog događaja, stoga možemo poopćiti definiciju nezavisnih događaja na nezavisne varijable
- Dvije slučajne varijable će biti nezavisne, ako *vrijednost* jedne ne uvjetuje *vrijednost* druge, tj. ako vrijedi:

$$p_{(X|Y)} = \frac{p(x,y)}{p_Y(y)} = p_X(x)$$

- Iz toga slijedi da za nezavisne varijable vrijedi:

$$p(x,y) = p_X(x)p_Y(y)$$

Nezavisne slučajne varijable

- Općenito, slučajne varijable X i Y su nezavisne ako za svaki par vrijednosti x i y vrijedi:

$$p(x, y) = p_X(x)p_Y(y) \quad (\text{za diskrete varijable})$$

$$f(x, y) = f_X(x)f_Y(y) \quad (\text{za kontinuirane varijable})$$

- Na primjeru raspodjele studenata po ocjeni i po spolu vidimo da te varijable *nisu nezavisne*

Nezavisne slučajne varijable

- Primjer: istovremeno bacanje kocke i novčića
 - slučajna varijabla X opisuje ishod na kocki
 - Slučajna varijabla Y opisuju ishod na novčiću

Ishod	1	2	3	4	5	6	UKUPNO
P	1/12	1/12	1/12	1/12	1/12	1/12	1/2
G	1/12	1/12	1/12	1/12	1/12	1/12	1/2
UKUPNO	1/6	1/6	1/6	1/6	1/6	1/6	1

- Vidi se da za svaki par vrijednosti x i y vrijedi:
$$p(x, y) = p_X(x)p_Y(y)$$
- Dakle varijable su nezavisne!

Momenti dvodimenzionalne raspodjele

- Pomoćni moment:

$$m_{rs} = \sum_{x \in D_X} \sum_{y \in D_Y} x^r y^s p(x, y) \quad \text{Za diskretne varijable}$$

$$m_{rs} = \iint_{\mathbb{R} \times \mathbb{R}} x^r y^s f(x, y) dx dy \quad \text{Za kontinuirane varijable}$$

- Centralni moment:

$$M_{rs} = \sum_{x \in D_X} \sum_{y \in D_Y} (x - \mu_X)^r (y - \mu_Y)^s p(x, y) \quad \text{Za diskretne varijable}$$

$$M_{rs} = \iint_{\mathbb{R} \times \mathbb{R}} (x - \mu_X)^r (y - \mu_Y)^s f(x, y) dx dy \quad \text{Za kontinuirane varijable}$$

Očekivanje

- Pomoćni momenti m_{01} i m_{10} :

$$m_{10} = \sum_{x \in D_X} \sum_{y \in D_Y} x p(x, y) = \sum_{x \in D_X} x p_X(x) = \mu_X$$

$$m_{01} = \sum_{x \in D_X} \sum_{y \in D_Y} y p(x, y) = \sum_{y \in D_Y} y p_Y(y) = \mu_Y$$

- Ovi pomoćni momenti odgovaraju **očekivanjima** diskretnih slučajnih varijabli X odn. Y
- Analogno vrijedi i za kontinuirani slučaj

Varijanca

- Središnji momenti M_{20} i M_{02} odgovaraju varijancama:

$$\begin{aligned} M_{20} &= \sum_{x \in D_X} \sum_{y \in D_Y} (x - \mu_X)^2 p(x, y) \\ &= \sum_{x \in D_X} (x - \mu_X)^2 p_X(x) = V(X) \\ M_{02} &= \sum_{x \in D_X} \sum_{y \in D_Y} (y - \mu_Y)^2 p(x, y) \\ &= \sum_{y \in D_Y} (y - \mu_Y)^2 p_Y(y) = V(Y) \end{aligned}$$

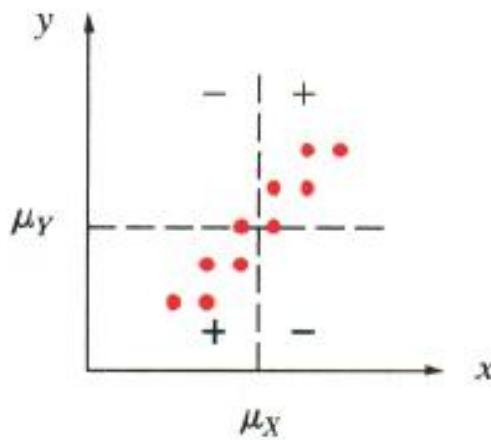
Kovarijanca

- Kovarijanca je veličina koja govori o zavisnosti varijabli X i Y :

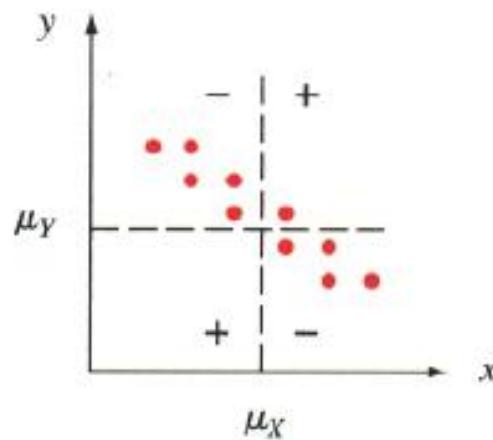
$$\text{Cov}(X, Y) = \sigma_{XY} = M_{11}$$

- Izražena pomoću pomoćnih momenata ova relacija postaje:

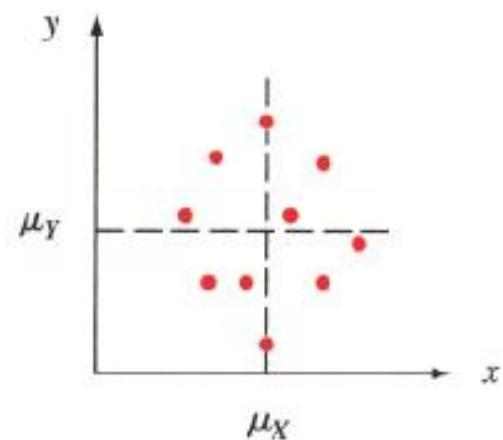
$$\text{Cov}(X, Y) = m_{11} - m_{10}m_{01} = E(XY) - E(X)E(Y)$$



$$\text{Cov}(X,Y) > 0$$



$$\text{Cov}(X,Y) < 0$$



$$\text{Cov}(X,Y) \sim 0$$

Kovarijanca nezavisnih varijabli

- Po definiciji za kovarijancu vrijedi:

$$\sigma_{xy} = E(XY) - E(X)E(Y)$$

- Prvi pribrojnik možemo pisati kao:

$$E(XY) = \sum_x \sum_y xy p(x, y)$$

- Za nezavisne varijable:

$$= \sum_x \sum_y xy p_x(x)p_y(y) = \sum_x xp_x(x) \sum_y yp_y(y)$$

- Slijedi: $E(XY) = E(X)E(Y)$

- Dobivamo da je kovarijanca nezavisnih varijabli: $\boxed{\sigma_{xy} = 0}$

Korelacija

- Kovarijanca ovisi o veličinama koje mjerimo i njihovim jedinicama
→ nije pogodno za usporedbu povezanosti različitih veličina
- Uvodimo bezdimenzionalnu veličinu – **korelaciju** – kao mjeru povezanosti, tj. zavisnosti varijabli
- **Koeficijent linearne korelacije** varijabli X i Y se definira kao:

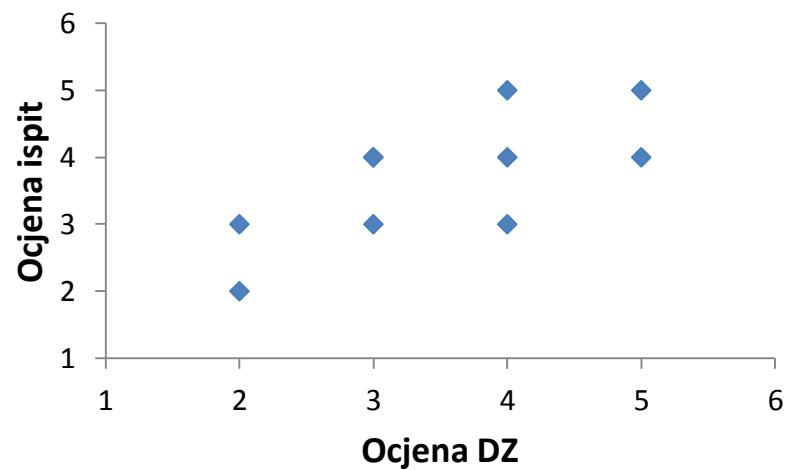
$$\text{Corr}(X, Y) = \rho_{X,Y} = \rho = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

(omjer kovarijance i produkta standardnih devijacija)

Korelacija

- Primjer 1: Za 10 studenata uspoređujemo ocjene iz domaće zadaće i ocjene na ispitu

Student	DZ	Ispit
1	5	5
2	4	5
3	4	4
4	2	3
5	5	4
6	2	2
7	3	4
8	3	3
9	4	3
10	3	4



$$\sigma_{DZ} = 1,02$$

$$\sigma_{ISPIT} = 0,90$$

$$\sigma_{DZ-ISPIT} = 0,65 \text{ (kovarijanca)}$$

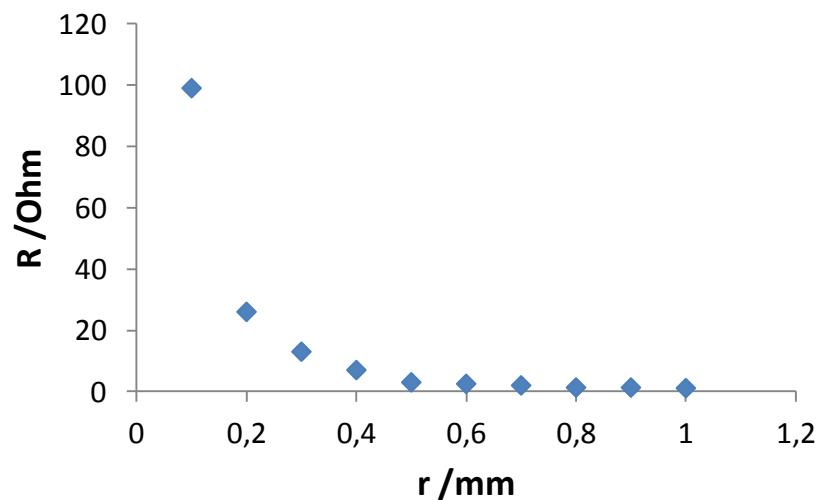
$$\rightarrow \rho = 0,7$$

Vidimo naznaku linearne ovisnosti

Korelacija

- Primjer 2: Studenti mjere otpor cilindričnog vodiča u ovisnosti o njegovom radijusu:

r /mm	R /Ω
0,1	99
0,2	26
0,3	13
0,4	7
0,5	3
0,6	2,5
0,7	2
0,8	1,30
0,9	1,30
1	1,10



Koeficijent korelacije $\rho = -0,68$

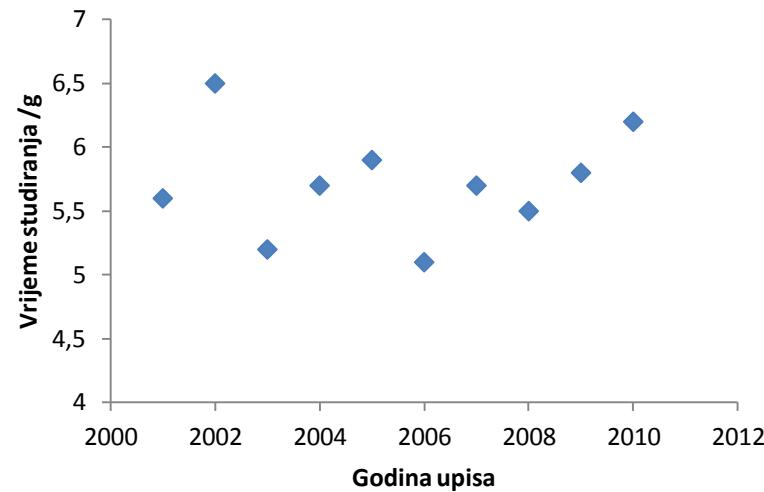
Vidimo izraženu obrnuto kvadratnu ovisnost,
što teorijski i očekujemo:

$$R = \frac{1}{\sigma} \frac{l}{\pi r^2}$$

Korelacija

- Primjer 3: promatramo vezu između godine upisa studija i trajanja studija

Godina	Trajanje /god
2001	5,6
2002	6,5
2003	5,2
2004	5,7
2005	5,9
2006	5,1
2007	5,7
2008	5,5
2009	5,8
2010	6,2



Koeficijent korelacije $\rho = 0,05$

Ne uočava se izražena ovisnost!

Korelacija

- Svojstva:
 1. $-1 \leq \rho \leq 1$
 2. Ako su X i Y nezavisne varijable onda je $\rho=0 \rightarrow$ primjer 3
(ali obrat ne vrijedi)
 3. Ako je ovisnost varijabli linearna $Y=aX+b$ onda i samo onda je $\rho=1$ ili $\rho=-1$ (za $a>0$ odn. $a<0$)
 4. Može se još pokazati da vrijedi:

$$\text{Corr}(aX + b, cY + d) = \text{Corr}(X, Y)$$

- Općenito ako je $|\rho|<0,5$ kažemo da je linearna korelacija slaba (primjer 3), a ako je $|\rho|>0,5$ kažemo da je linearna korelacija izražena (primjeri 1 i 2)
- Iz primjera 2 vidimo da imamo izrazito jaku kvadratnu korelaciju, no koeficijent je -0.68 obzirom da je on mjera linearne korelacija

Suma slučajnih varijabli

- Definiramo slučajnu varijablu $Y=X_1+X_2$

- Očekivanje** slučajne varijable Y :

$$E(Y) = E(X_1) + E(X_2)$$

- Dokaz:

$$\begin{aligned} E(X_1 + X_2) &= \sum_{x_1} \sum_{x_2} (x_1 + x_2)p(x_1, x_2) \\ &= \sum_{x_1} \sum_{x_2} x_1 p(x_1, x_2) + \sum_{x_1} \sum_{x_2} x_2 p(x_1, x_2) \\ &= \sum_{x_1} x_1 p_{x1}(x_1) + \sum_{x_2} x_2 p_{x2}(x_2) \\ &= E(X_1) + E(X_2) \end{aligned}$$

Suma slučajnih varijabli

- Definiramo slučajnu varijablu $Y=X_1+X_2$

- Varijanca** slučajne varijable Y :

$$V(Y) = V(X_1) + V(X_2) + 2\sigma_{x_1x_2}$$

- Dokaz:

$$\begin{aligned} V(X_1 + X_2) &= E\{(x_1 + x_2) - (\mu_1 + \mu_2)\}^2 \\ &= E\{(x_1 - \mu_1) + (x_2 - \mu_2)\}^2 \\ &= E[(x_1 - \mu_1)^2] + E[(x_2 - \mu_2)^2] \\ &\quad + 2E[(x_1 - \mu_1)(x_2 - \mu_2)] \end{aligned}$$

Linearna kombinacija slučajnih varijabli

- Za slučajne varijable X_1, X_2, \dots, X_n možemo definirati novu slučajnu varijablu:

$$Y = a_1X_1 + a_2X_2 + \dots + a_nX_n$$

gdje su $a_1 \dots a_n$ konstatne. Y se naziva linearom kombinacijom varijabli X .

- Poopćenje relacije za očekivanje:**

$$E(a_1X_1 + a_2X_2 + \dots + a_nX_n) = a_1E(X_1) + a_2E(X_2) + \dots + a_nE(X_n)$$

- Vrijedi bez obzira na to da li su varijable međusobno neovisne

Linearna kombinacija slučajnih varijabli

- Poopćenje relacije za varijancu:

$$V(a_1X_1 + a_2X_2 + \dots + a_nX_n) = a_1^2V(X_1) + a_2^2V(X_2) + \dots + a_n^2V(X_n) + \sum_i \sum_{j \neq i} a_i a_j Cov(X_i, X_j)$$

- Posebno, ako su varijable nezavisne, vrijedi:

$$V(a_1X_1 + a_2X_2 + \dots + a_nX_n) = a_1^2V(X_1) + a_2^2V(X_2) + \dots + a_n^2V(X_n)$$

- Važan primjer: varijanca razlike nezavisnih varijabli

$$V(X - Y) = V(X) + V(Y) = \sigma_x^2 + \sigma_y^2$$

Npr. mjerenje spektra s oduzimanjem pozadine.

Linearna kombinacija nezavisnih *normalnih* slučajnih varijabli

- Iz prethodnih razmatranja slijedi specijalni slučaj normalnih varijabli:

Neka su X_1, X_2, \dots, X_n nezavisne normalne slučajne varijable. Tada njihova linearna kombinacija

$$Y = a_1X_1 + a_2X_2 + \dots + a_nX_n$$

također ima normalnu raspodjelu s očekivanjem $\mu_Y = \sum_{i=1}^n a_i \mu_i$ i varijancom

$$\sigma_Y^2 = \sum_{i=1}^n a_i^2 \sigma_i^2.$$

- Dokaz preskaćemo