

# Slučajni vektori

# Uvod

Zanima nas više slučajnih varijabli vezanih uz istu pojavu.

Neka je  $(\Omega, \mathcal{F}, \mathbb{P})$  vjerojatnosni prostor i neka su  $X, Y : \Omega \rightarrow \mathbb{R}$  dvije slučajne varijable. **Dvodimenzionalni slučajni vektor** je funkcija  $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ , dana s  $(X, Y)(\omega) = (X(\omega), Y(\omega))$ .

Uočimo da za sliku od  $(X, Y)$  vrijedi  $R(X, Y) \subseteq R(X) \times R(Y)$ .

## Shematski zapis

U slučaju da je

$$X \sim \begin{pmatrix} x_1 & x_2 & \dots \\ p_1 & p_2 & \dots \end{pmatrix} \quad \text{i} \quad Y \sim \begin{pmatrix} y_1 & y_2 & \dots \\ q_1 & q_2 & \dots \end{pmatrix},$$

onda je  $(X, Y)$  **diskretni dvodimenzionalni slučajni vektor** i njegovu raspodjelu zapisujemo pomoću sheme:

$$(X, Y) \sim \begin{pmatrix} X \setminus Y & y_1 & y_2 & \dots & y_m \\ x_1 & p_{11} & p_{12} & \dots & p_{1m} \\ x_2 & p_{21} & p_{22} & \dots & p_{2m} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_n & p_{n1} & p_{n2} & \dots & p_{nm} \end{pmatrix},$$

gdje su  $R(X, Y) \subseteq R(X) \times R(Y) = \{(x_i, y_j) : x_i \in R(X), y_j \in R(Y)\}$   
i

$$p_{ij} = \mathbb{P}((X, Y) = (x_i, y_j)) = \mathbb{P}(X = x_i, Y = y_j)$$

za  $x_i \in R(X)$  i  $y_j \in R(Y)$ .

# Funkcija vjerojatnosti i funkcija raspodjele

**Funkcija vjerojatnosti**  $f : \mathbb{R}^2 \rightarrow \mathbb{R}$  od  $(X, Y)$  je dana s

$$f(x, y) = \begin{cases} p_{ij}, & x = x_i, y = y_j \\ 0, & \text{inače,} \end{cases}$$

a **funkcija raspodjele**  $F : \mathbb{R}^2 \rightarrow [0, 1]$  je dana s

$$F(x, y) = \mathbb{P}(X \leq x, Y \leq y) = \sum_{\substack{x_i \leq x, x_i \in R(X) \\ y_j \leq y, y_j \in R(Y)}} p_{ij}.$$

Očito,  $p_{ij} = f(x_i, y_j)$  i  $R(X, Y) = \{(x, y) \in \mathbb{R}^2 : f(x, y) > 0\}$ .

# Marginalne raspodjele

Uočimo

$$\sum_{y_j \in R(Y)} p_{ij} = \sum_{y_j \in R(Y)} \mathbb{P}(X = x_i, Y = y_j) = \mathbb{P}(X = x_i) = p_i$$

i slično

$$\sum_{x_i \in R(X)} p_{ij} = \sum_{x_i \in R(X)} \mathbb{P}(X = x_i, Y = y_j) = \mathbb{P}(Y = y_j) = q_j.$$

Dakle, ako zbrojimo sve elemente po  $y_j$  dobijemo raspodjelu od  $X$  i ako zbrojimo sve elemente po  $x_i$  dobijemo raspodjelu od  $Y$ . Te se raspodjele zovu **marginalne raspodjele** od  $(X, Y)$ .

Slučajne varijable  $X$  i  $Y$  su nezavisne ako i samo ako je  $p_{ij} = p_i q_j$ , tj.  $f(x, y) = f_X(x)f_Y(y)$ .

## Primjer

Bacamo dvije kocke. Neka je  $X$  zbroj brojeva koji su pali, a  $Y$  veći od brojeva koji su pali. Raspodjela od  $(X, Y)$  je dana s

$X \setminus Y$	1	2	3	4	5	6	$p_i$
2	$\frac{1}{36}$	0	0	0	0	0	$\frac{1}{36}$
3	0	$\frac{2}{36}$	0	0	0	0	$\frac{2}{36}$
4	0	$\frac{1}{36}$	$\frac{2}{36}$	0	0	0	$\frac{3}{36}$
5	0	0	$\frac{2}{36}$	$\frac{2}{36}$	0	0	$\frac{4}{36}$
6	0	0	$\frac{1}{36}$	$\frac{2}{36}$	$\frac{2}{36}$	0	$\frac{5}{36}$
7	0	0	0	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{6}{36}$
8	0	0	0	$\frac{1}{36}$	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{5}{36}$
9	0	0	0	0	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{4}{36}$
10	0	0	0	0	$\frac{1}{36}$	$\frac{2}{36}$	$\frac{3}{36}$
11	0	0	0	0	0	$\frac{2}{36}$	$\frac{2}{36}$
12	0	0	0	0	0	$\frac{1}{36}$	$\frac{1}{36}$
$q_j$	$\frac{1}{36}$	$\frac{3}{36}$	$\frac{5}{36}$	$\frac{7}{36}$	$\frac{9}{36}$	$\frac{11}{36}$	1

$$p_{ij} = \mathbb{P}(X = x_i, Y = y_j), \quad p_i = \mathbb{P}(X = x_i) \text{ i } q_j = \mathbb{P}(Y = y_j).$$

□

## Neprekidni slučajni vektori – funkcija gustoće

Neka su  $X, Y : \Omega \rightarrow \mathbb{R}$  neprekidne slučajne varijable. Dvodimenzionalni slučajni vektor  $(X, Y) : \Omega \rightarrow \mathbb{R}^2$  je **neprekidni slučajni vektor** ako postoji (izmjeriva) funkcija  $f : \mathbb{R}^2 \rightarrow \mathbb{R}$  za koju vrijedi:

(i)  $f(x, y) \geq 0$

(ii)  $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dx dy = 1$

(iii)  $\mathbb{P}((X, Y) \in (-\infty, a] \times (-\infty, b]) = \int_{-\infty}^a \int_{-\infty}^b f(x, y) dx dy.$

Funkciju  $f(x, y)$  zovemo **funkcija gustoće** od  $(X, Y)$ .

## Neprekidni slučajni vektori – funkcija raspodjele

Funkcija raspodjele  $F : \mathbb{R}^2 \rightarrow [0, 1]$  od  $(X, Y)$  je dana s

$$F(x, y) = \mathbb{P}(X \leq x, Y \leq y) = \int_{-\infty}^x \int_{-\infty}^y f(s, t) ds dt.$$

Kada je funkcija gustoće neprekidna, vrijedi

$$\frac{\partial^2}{\partial x \partial y} F(x, y) = \frac{\partial^2}{\partial y \partial x} F(x, y) = f(x, y).$$

Kao i u diskretnom slučaju imamo

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

$$\text{te } \lim_{y \rightarrow \infty} F(x, y) = F_X(x) \quad \text{i} \quad \lim_{x \rightarrow \infty} F(x, y) = F_Y(y).$$

Integriranjem po  $y$  dobivamo raspodjelu od  $X$ , a integriranjem po  $x$  dobivamo raspodjelu od  $Y$ , tj. **marginalne raspodjele** od  $(X, Y)$ .

Slučajne varijable  $X$  i  $Y$  su nezavisne ako i samo ako je  $f(x, y) = f_X(x)f_Y(y)$  i  $F(x, y) = F_X(x)F_Y(y)$ .

## Neprekidni slučajni vektori – primjer

Marko i Ivan dogovorili su sastanak na *Trgu bana Josipa Jelačića* u 12 h. Pretpostavimo da je njihov dolazak slučajan trenutak između 12 i 13 h. Neka slučajne varijable  $X$  i  $Y$  označavaju dolazak Marka i Ivana, redom.

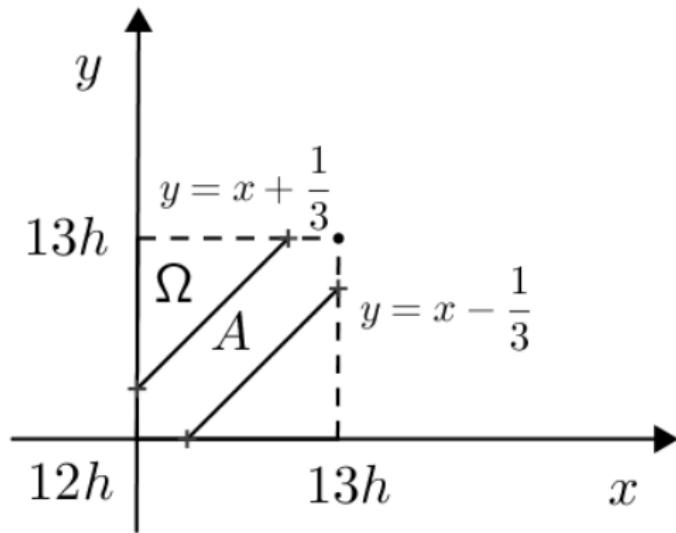
Pretpostavimo da je funkcija gustoće od  $(X, Y)$  dana s

$$f(x, y) = \begin{cases} 1, & x, y \in [12, 13] \\ 0, & \text{inače.} \end{cases}$$

Uočimo,  $f_X(x) = \int_{12}^{13} f(x, y) dy = 1$  i  $f_Y(y) = \int_{12}^{13} f(x, y) dx = 1$ . Dakle,  $X \sim U(12, 13)$  i  $Y \sim U(12, 13)$ . Nadalje, pretpostavimo da onaj koji stigne na dogovorenou mjestu prvi čeka onog drugog 20 min. Kolika je vjerojatnost da se sretnu?

## Neprekidni slučajni vektori – primjer

Neka je  $\Omega = [12, 13]^2$ . Označimo s  $A$  događaj "Marko i Ivan su se sreli", tj.  $A = \{\omega \in \Omega : |X(\omega) - Y(\omega)| \leq 1/3\}$ .



Dakle,  $\mathbb{P}(A) = \iint_A f(x, y) dx dy = \frac{5}{9}$ .

## Očekivanje funkcije neprekidnog slučajnog vektora

Neka je  $(X, Y)$  dvodimenzionalan slučajni vektor i  $g : \mathbb{R}^2 \rightarrow \mathbb{R}$  neka funkcija. Tada je  $g(X, Y)$  slučajna varijabla. Zanima nas prosjek  $g(X, Y)$ . Pokazuje se da to možemo izravno izračunati iz zajedničke raspodjele. Ako donja suma i integral postoje, onda imamo

$$\mathbb{E}(g(X, Y)) = \sum_{x_i \in R(X)} \sum_{y_j \in R(Y)} g(x_i, y_j) p_{ij}$$

za diskretan slučajni vektor te

$$\mathbb{E}(g(X, Y)) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f(x, y) dx dy$$

za neprekidan slučajni vektor. U slučaju diskretnih slučajnih vektora funkcija  $g(x, y)$  može biti proizvoljna.

## Očekivanje funkcije neprekidnog slučajnog vektora – primjer

Poludjeli stroj za proizvodnju vaza na slučajan način proizvodi vase radijusa  $R \sim U(7.5, 12.5)$  i visine  $H \sim U(25, 35)$ , gdje su obje dimenzije izražene u centimetrima. Pretpostavimo da su  $R$  i  $H$  nezavisne. Odredimo očekivani volumen slučajno odabrane vase.

Označimo s  $V$  volumen slučajno proizvedene vase. Imamo

$$\begin{aligned}\mathbb{E}(V) &= \mathbb{E}(R^2\pi H) = \\&= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} r^2\pi h f_H(h) f_R(r) dr dh \\&= \pi \int_{25}^{35} \int_{7.5}^{12.5} r^2 h \cdot \frac{1}{10} \cdot \frac{1}{5} dr dh = \\&= \frac{\pi}{50} \int_{25}^{35} h dh \int_{7.5}^{12.5} r^2 dr = 9621.127 \text{ cm}^3. \square\end{aligned}$$

# Kovarijanca slučajnih varijabli

Za slučajne varijable  $X$  i  $Y$  vrijedi  $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y)$ . Ako su  $X$  i  $Y$  još i nezavisne, onda je  $\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y)$ .

Što ako  $X$  i  $Y$  nisu nezavisne? Imamo

$$\begin{aligned}\text{Var}(X + Y) &= \mathbb{E}((X + Y - \mathbb{E}(X + Y))^2) \\ &= \mathbb{E}(((X - \mathbb{E}(X)) + (Y - \mathbb{E}(Y)))^2) \\ &= \mathbb{E}((X - \mathbb{E}(X))^2 + (Y - \mathbb{E}(Y))^2 + 2(X - \mathbb{E}(X))(Y - \mathbb{E}(Y))) \\ &= \text{Var}(X) + \text{Var}(Y) + 2\mathbb{E}((X - \mathbb{E}(X))(Y - \mathbb{E}(Y))).\end{aligned}$$

Izraz  $\mathbb{E}((X - \mathbb{E}(X))(Y - \mathbb{E}(Y)))$ , u oznaci  $\text{Cov}(X, Y)$ , nazivamo **kovarijancom** od  $X$  i  $Y$ . Uočimo

$$\text{Cov}(X, Y) = \mathbb{E}(XY - \mathbb{E}(X)Y - \mathbb{E}(Y)X + \mathbb{E}(X)\mathbb{E}(Y)) = \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y).$$

# Koreliranost slučajnih varijabli

U slučaju nezavisnosti  $\mathbb{E}(XY) = \mathbb{E}(X)\mathbb{E}(Y)$ , iz čega slijedi da je  $\text{Cov}(X, Y) = 0$ .

- Ako je  $\text{Cov}(X, Y) > 0$  kažemo da su  $X$  i  $Y$  **pozitivno korelirane**,
- za  $\text{Cov}(X, Y) < 0$  kažemo da su  $X$  i  $Y$  **negativno korelirane**,
- a za  $\text{Cov}(X, Y) = 0$  kažemo da su  $X$  i  $Y$  **nekorelirane**.

Pozitivna koreliranost znači da  $X$  i  $Y$  imaju sklonost odstupanja od očekivanja u istu stranu, a u slučaju negativne koreliranosti imaju sklonost odstupanja na različite strane od očekivanja. Napomenimo da nekoreliranost ne znači nezavisnost.

## Nekoreliranost ne povlači nezavisnost

Neka je  $X \sim \begin{pmatrix} -1 & 0 & 1 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{pmatrix}$ . Tada imamo  $X^2 \sim \begin{pmatrix} 0 & 1 \\ \frac{1}{3} & \frac{2}{3} \end{pmatrix}$  i  
 $X^3 \sim \begin{pmatrix} -1 & 0 & 1 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{pmatrix}$ . Dakle,  $\text{Cov}(X, X^2) = \mathbb{E}(X^3) - \mathbb{E}(X)\mathbb{E}(X^2) = 0$  pa  
su  $X$  i  $X^2$  nekorelirane.

S druge strane, vrijedi

$$\mathbb{P}(X = 0, X^2 = 0) = \mathbb{P}(X = 0) = \frac{1}{3} \neq \mathbb{P}(X = 0)\mathbb{P}(X^2 = 0) = \frac{1}{9}$$

pa  $X$  i  $X^2$  nisu nezavisne.

# Koeficijent korelacija slučajnih varijabli

Definiramo

$$\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma(X)\sigma(Y)}.$$

Broj  $\rho(X, Y)$  nazivamo **koeficijent korelacijske**.

Vrijedi  $\rho(rX + s, tY + u) = \rho(X, Y)$ .

Uočimo da  $\rho(X, Y)$  poprima vrijednosti između -1 i 1, a značenje predznaka je isto kao kod kovarijance.

## Stupanj linearne zavisnosti

Koeficijentom korelacije zapravo mjerimo stupanj linearne zavisnosti dviju slučajnih varijabli.

- (i)  $|\rho(X, Y)| = 1$  ako i samo ako postoje  $a, b \in \mathbb{R}$  t.d.  $Y = aX + b$  te  $\sigma(X) > 0, \sigma(Y) > 0$  (pa nužno  $a \neq 0$ )
- (ii) manji  $|\rho(X, Y)|$  znači “manji stupanj linearne zavisnosti” od  $X$  i  $Y$
- (iii)  $\rho(X, Y) = 0$  znači da su  $X - \mathbb{E}(X)$  i  $Y - \mathbb{E}(Y)$  “ortogonalne”.

# Dijagrami raspršenja za različite koeficijente korelacija

