

# MEDICINSKA STATISTIKA SA INFORMATIKOM

Slučajne promjenljive

# Uvod

- U teoriji vjeroatnoće obilježju odgovara pojmu slučajne promjenljive
  - Funkcija koja svakom elementarnom ishodu dodjeljuje broj
  - Obilježavaju se velikim slovima, a njihove realizovane vrijednosti malim
  - Diskretne slučajne promjenljive uzimaju prebrojivo mnogo vrijednosti, a neprekidne neprebrojivo
  - Osnovni je problem odrediti raspodjelu slučajne promjenljive

# Primjer

- Ako je  $X$  broj na gornjoj strani kocke onda su moguće vrijednosti ove promjenljive 1, 2, 3, 4, 5, 6
- Ako je  $X$  broj palih šestica u tri bacanja kocke onda su moguće vrijednosti ove promjenljive 0, 1, 2, 3

# Raspodjela slučajne promjenljive

- Osnovni je problem odrediti raspodjelu slučajne promjenljive, odnosno odrediti skup njenih vrijednosti i vjerovatnoće sa kojim se ove vrijednosti pojavljuju
- Diskretna slučajna veličina - tabela
- Neprekidna slučajna veličina – funkcija gustine  $\varphi$ 
  - Vjerovatnoća  $P(a < X < b)$  jednaka je površini ispod grafika funkcije gustine nad intervalom  $(a, b)$

# Raspodjela diskretne slučajne promjenljive

- Diskretna slučajna promjenljiva  $X$  određena je skupom vrijednosti

$$x_1, x_2, \dots, x_n, \dots$$

i odgovarajućim vjerovanoćama

$$p_1, p_2, \dots, p_n, \dots$$

gdje je

$$p_i = P(X = x_i), \quad i = 1, 2, \dots,$$

što zapisujemo u obliku šeme

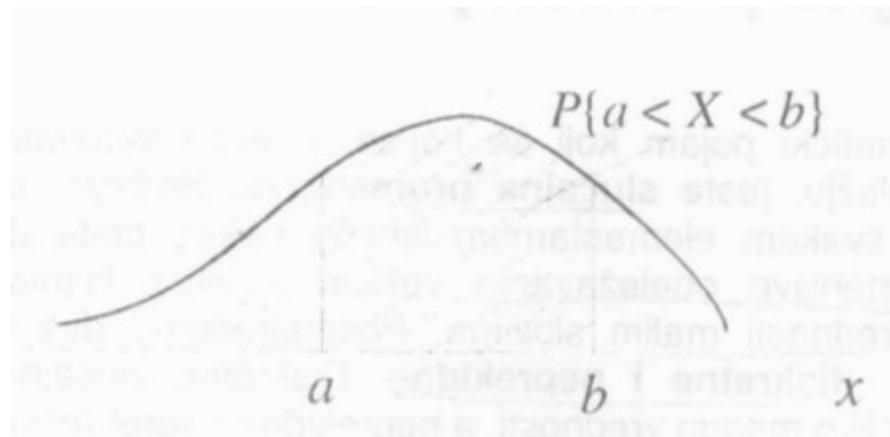
$$X : \begin{pmatrix} x_1 & x_2 & \cdots & x_n & \cdots \\ p_1 & p_2 & \cdots & p_n & \cdots \end{pmatrix}.$$

# Raspodjela neprekidne slučajne promjenljive

- Neprekidna slučajna promjenljiva  $X$  određena je svojom funkcijom gustine  $\varphi_x$ , koja je nenegativna i važi

$$\int_{-\infty}^{\infty} \varphi_x(x) dx = 1$$

- Vjerovatnoća  $P\{a < X < b\}$  jednaka je površini ispod funkcije gustine nad intervalom  $(a, b)$ , pri čemu su  $a, b \in \mathbb{R}$



# Numeričke karakteristike slučajnih promjenljivih

	Diskretne	Neprekidne
Srednja vrednost $m = E(X)$	$E(X) = \sum_{k=1}^{\infty} x_i p_i$	$E(X) = \int_{-\infty}^{\infty} x \varphi_X(x) dx$
Običan moment reda $r$ , $r = 1, 2, \dots$ $m_r = E(X^r)$	$E(X^r) = \sum_{k=1}^{\infty} x_i^r p_i$	$E(X^r) = \int_{-\infty}^{\infty} x^r \varphi_X(x) dx$
Centralni moment reda $r$ , $r = 1, 2, \dots$ $\mu_r = E((X - m)^r)$	$\mu_r = \sum_{k=1}^{\infty} (x_i - m)^r p_i$	$\mu_r = \int_{-\infty}^{\infty} (x - m)^r \varphi_X(x) dx$

# Numeričke karakteristike slučajnih promjenljivih (2)

Disperzija, Centralni moment reda $r = 2$ $\mu_2 = \sigma^2$	$D(X) = \sum_{k=1}^{\infty} (x_i - m)^2 p_i$	$D(X) = \int_{-\infty}^{\infty} (x - m)^2 \varphi_X(x) dx$
Standardna devijacija $\sigma$	$\sigma = \sqrt{D(X)}$	
Koeficijenat asimetrije	$K_A = \frac{\mu_3}{\mu_2^{3/2}} = \frac{E(X - E(X))^3}{[E(X - E(X))^2]^{3/2}}$	
Koeficijenat ekscesa	$K_E = \frac{\mu_4}{\mu_2^2} = \frac{E(X - E(X))^4}{[E(X - E(X))^2]^2}$	

# Numeričke karakteristike slučajnih promjenljivih (3)

- Mod  $M_o$ 
  - diskretne slučajne promjenljive je vrijednost sa najvećom vjerovatnoćom
  - neprekine slučajne promjenljive je vrijednost u kojoj funkcija gustine dostiže maksimum
- Medijana  $M_e$ 
  - diskretne promjenljive je ona vrijednost za koju važi

$$P\{X < M_e\} \leq \frac{1}{2}, \quad \text{i} \quad P\{X > M_e\} \leq \frac{1}{2}.$$

- neprekidne promjenljive je ona vrijednost za koju važi

$$P\{X < M_e\} = P\{X \geq M_e\} = \frac{1}{2}$$

# Uniformna diskretna raspodjela

- Svaka vrijednost slučajne promjenljive ima istu vjerovatnoću pojavljivanja, ako ima n različitih vrijednosti pripadajuće vjerovanoće su  $1/n$
- Primjer, bacanje kocke za igru

$$X : \begin{pmatrix} x_1 & x_2 & \dots & x_n \\ \hline 1 & 1 & \dots & 1 \\ \hline n & n & \dots & n \end{pmatrix}.$$

# Binomna raspodjela

- Broj pojavljivanja događaja A koji ima vjerovatnoću  $p=P(A)$  u nizu od n nezavisnih eksperimenata
  - Oznaka A :  $B(n, p)$
- Vrijednosti ove promjenljive su 0, 1, 2, ..., n a odgovarajuće vjerovatnoće računaju se po formuli

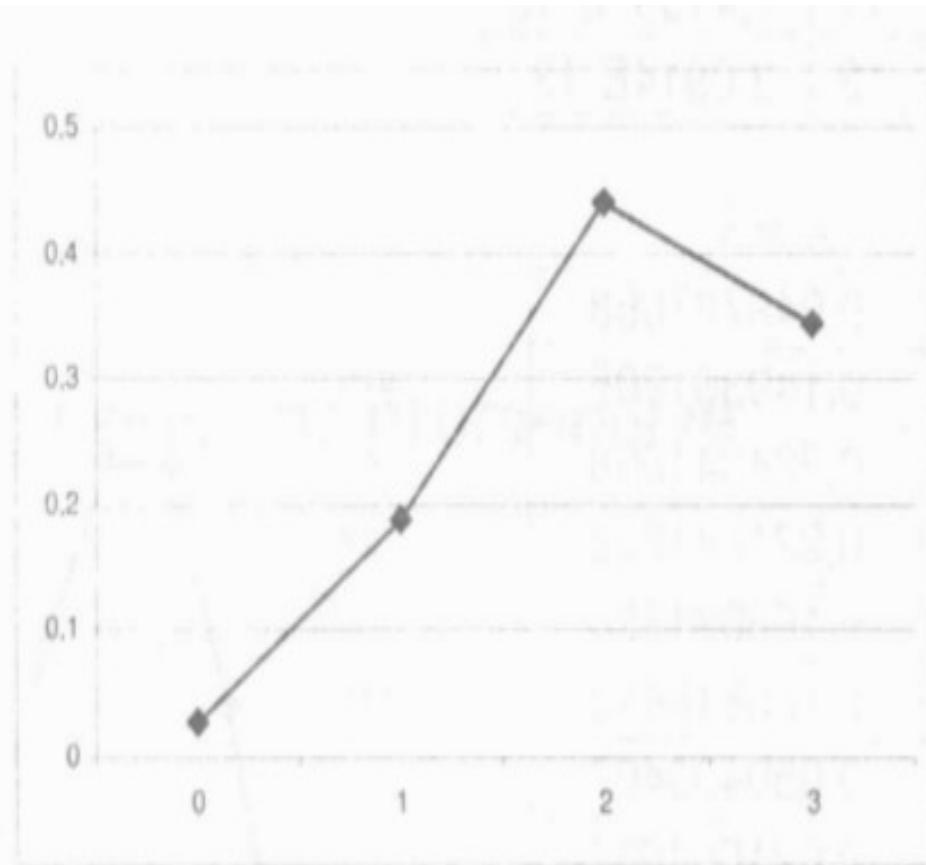
$$P\{X = k\} = \binom{n}{k} p^k q^{n-k}, \quad k = 0, 1, 2, \dots, n$$

- Primjer, broj palih šestica u tri bacanja kocke za igru
- Važi  $E(A) = n*p$ ,  $D(A) = n * p * (1 - p)$

# Binomna raspodjela 2

$$B(3, 0.7)$$

0	0,027
1	0,189
2	0,441
3	0,343



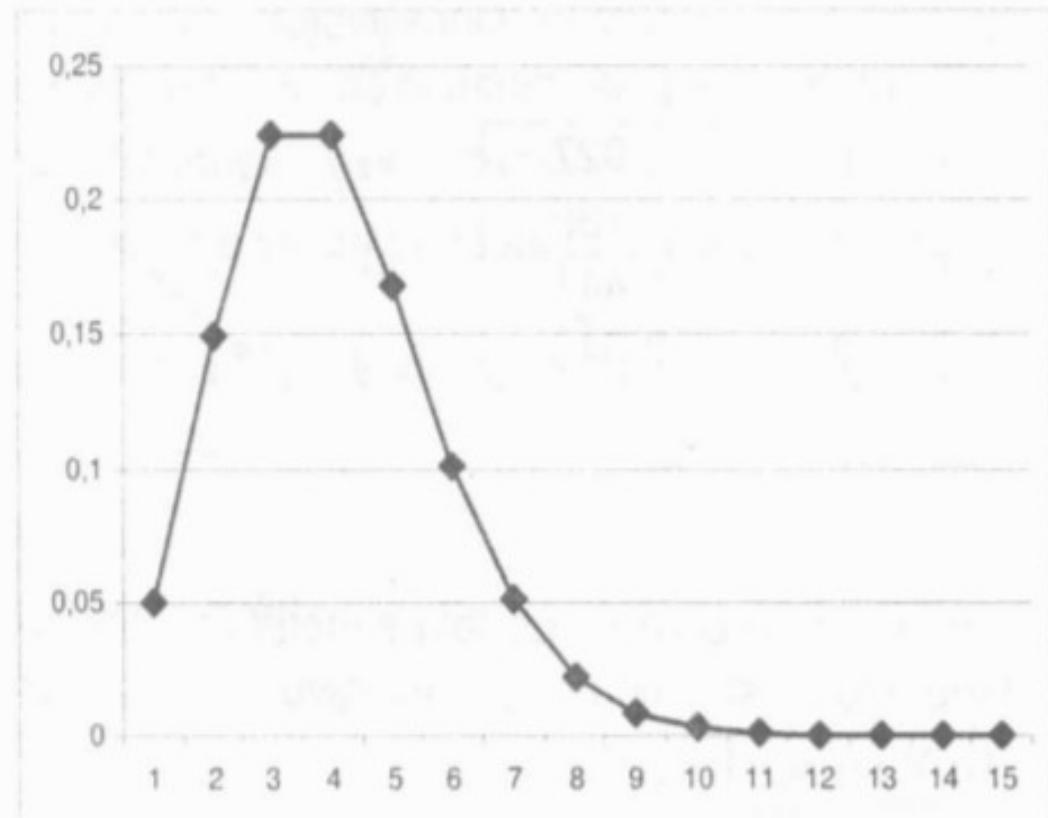
# Puasonova raspodjela

- Slučajna promjenljiva A ima Puasonovu raspodjelu ako je  $P(A=k)=\lambda^k / k!$ ,  $\lambda>0$ ,  $k=0, 1, \dots$
- Primjer, broj poziva u telefonskoj centrali u toku jednog minuta, pri čemu je  $\lambda$  prosječan broj poziva u toku jednog minuta
- Važi  $E(A) = D(A) = \lambda$

# Puasonova raspodjela 2

$$\lambda = 3$$

0	0,049787068
1	0,149361205
2	0,224041808
3	0,224041808
4	0,168031356
5	0,100818813
6	0,050409407
7	0,021604031
8	0,008101512
9	0,002700504
10	0,000810151
11	0,00022095
12	5,52376E-05
13	1,27471E-05
14	2,73153E-06



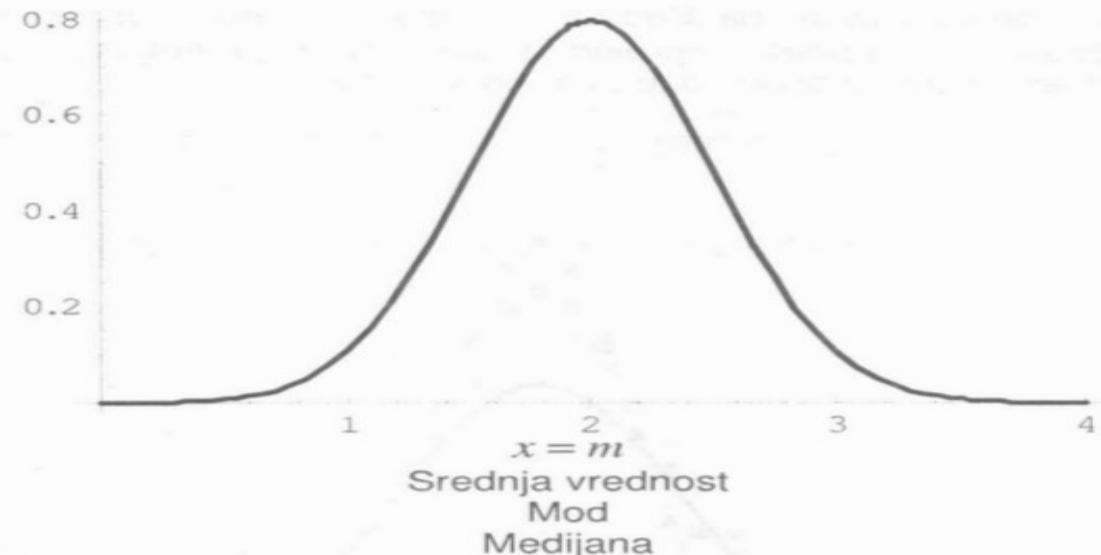
# Normalna raspodjela

- Normalna raspodjela  $N(m, \sigma^2)$  ima funkciju gustine

$$\varphi(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-m)^2}{2\sigma^2}}, \quad x \in \mathbb{R}$$

Srednja vrednost	$m$
Moda	$m$
Medijana	$m$
Disperzija	$\sigma^2$
$K_A$	0
$K_E$	3

- Gustina normalne raspodjele simetrična je oko prave  $x=m$

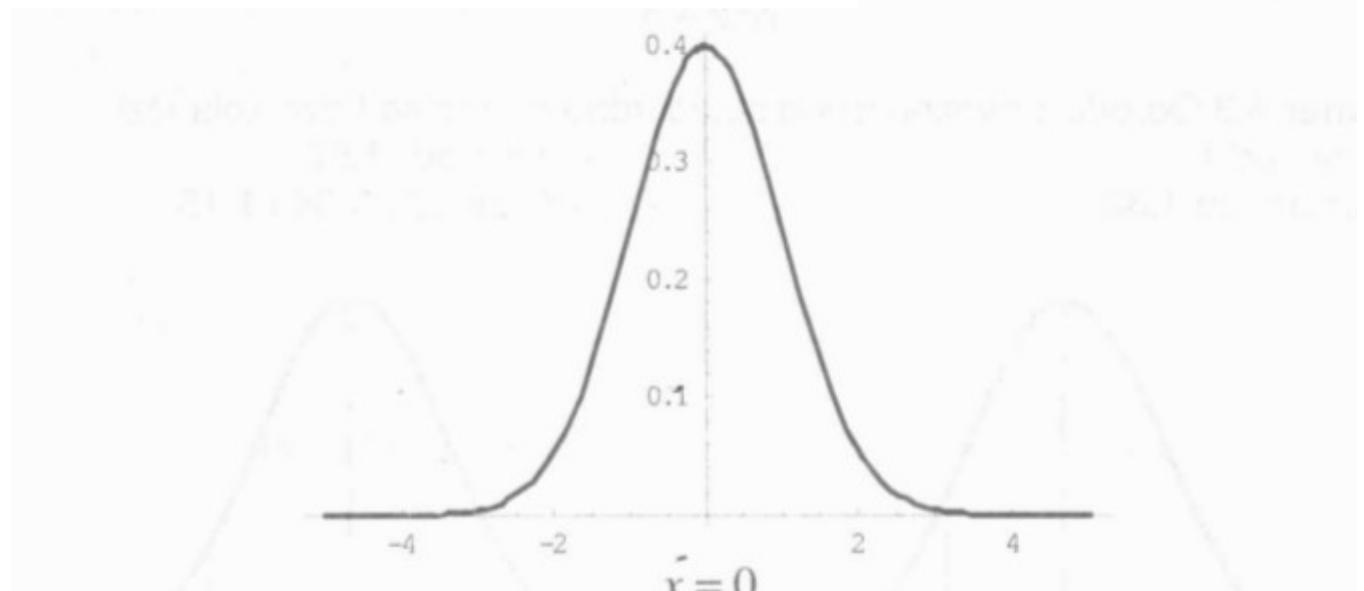


# Standardizovana normalna raspodjela

- Normalna raspodjela  $N(0, 1)$  zadata je gustinom

$$\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}, \quad x \in \mathbb{R}$$

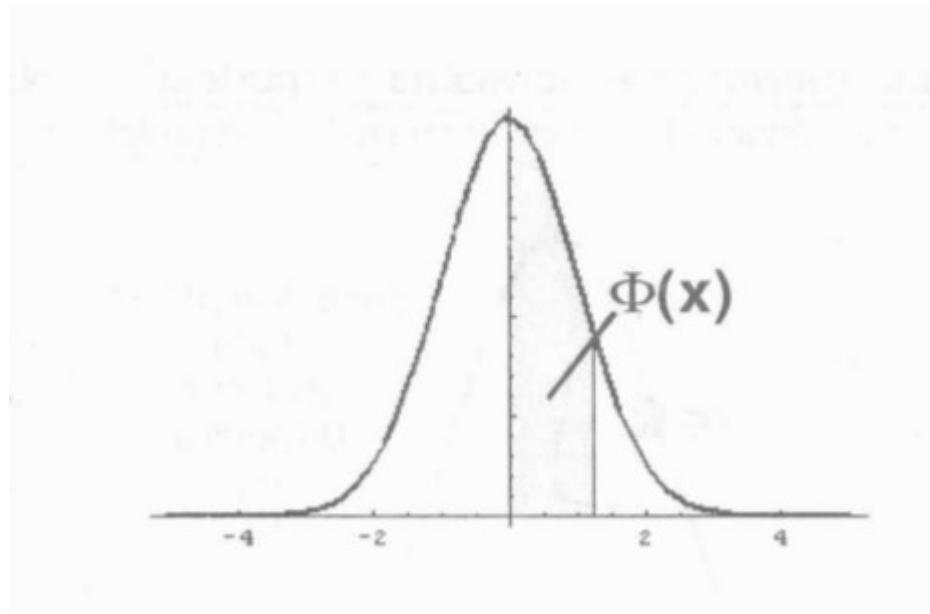
Srednja vrednost	0
Moda	0
Medijana	0
Disperzija	1
$K_A$	0
$K_E$	3



# Standardizovana normalna raspodjela 2

- Za izračunavanje vjerovatnoća oblika  $P\{a < X < b\}$  koristi se funkcija

$$\Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx,$$





# Primjer 1

- Odrediti površinu ispod standardne normalne krive koja leži
  - Lijevo od 1, rješenje 0.8413
  - Desno od 1.32, rješenje 0.0934
  - Lijevo od -1.62, rješenje 0.0526
  - Između 0.34 i 1.15, rješenje 0.2418

# Z-skor

- Ako slučajna promjenljiva  $X$  ima normalnu raspodjelu  $N(m, \sigma^2)$ , tada njen z-skor, slučajna promjenljiva  $Z = (X - m) / \sigma$  ima normalnu raspodjelu  $N(0, 1)$
- Ovo nam omogućava da određujemo vrijednosti  $P\{a < X < b\}$  po fomuli

$$P\{a < X < b\} = P\left(\frac{a-m}{\sigma} < Z < \frac{b-m}{\sigma}\right) = \Phi\left(\frac{b-m}{\sigma}\right) - \Phi\left(\frac{a-m}{\sigma}\right)$$

# Primjer 2

- Ako visina studenta ima normalnu raspodjelu sa parametrima  $m = 162$  i  $\sigma = 11.2$  odrediti
  - Koji procenat populacije ima visinu između 156cm i 171 cm, rješenje 0.4935
  - Koji je procenat populacije viši od 165cm, rješenje 0.3936
  - Od koje visine je niže 75% populacije, rješenje 169.504
  - U kom intervalu leži 95% populacije, rješenje (140.1, 183.9), ovakav interval nije jedinstven, obično se uzima onaj koji je simetričan u odnosu na srednju vrijednost  $m$

# Diskrete dvodimenzione slučajne promjenljive

- Često se u eksperimentu registruju dvije ili više karakteristika
- Diskretna slučajna promjenljiva ( $X, Y$ ) zadaje se pomoću parova svojih vrijednosti  $(x_i, y_j)$ ,  $i, j = 1, 2, 3, \dots$  i odgovarajućih vjerovatnoća

$$p_{ij} = p(x_i, y_j) = P\{X = x_i, Y = y_j\}, \quad i, j = 1, 2, \dots$$

# Primjer 3

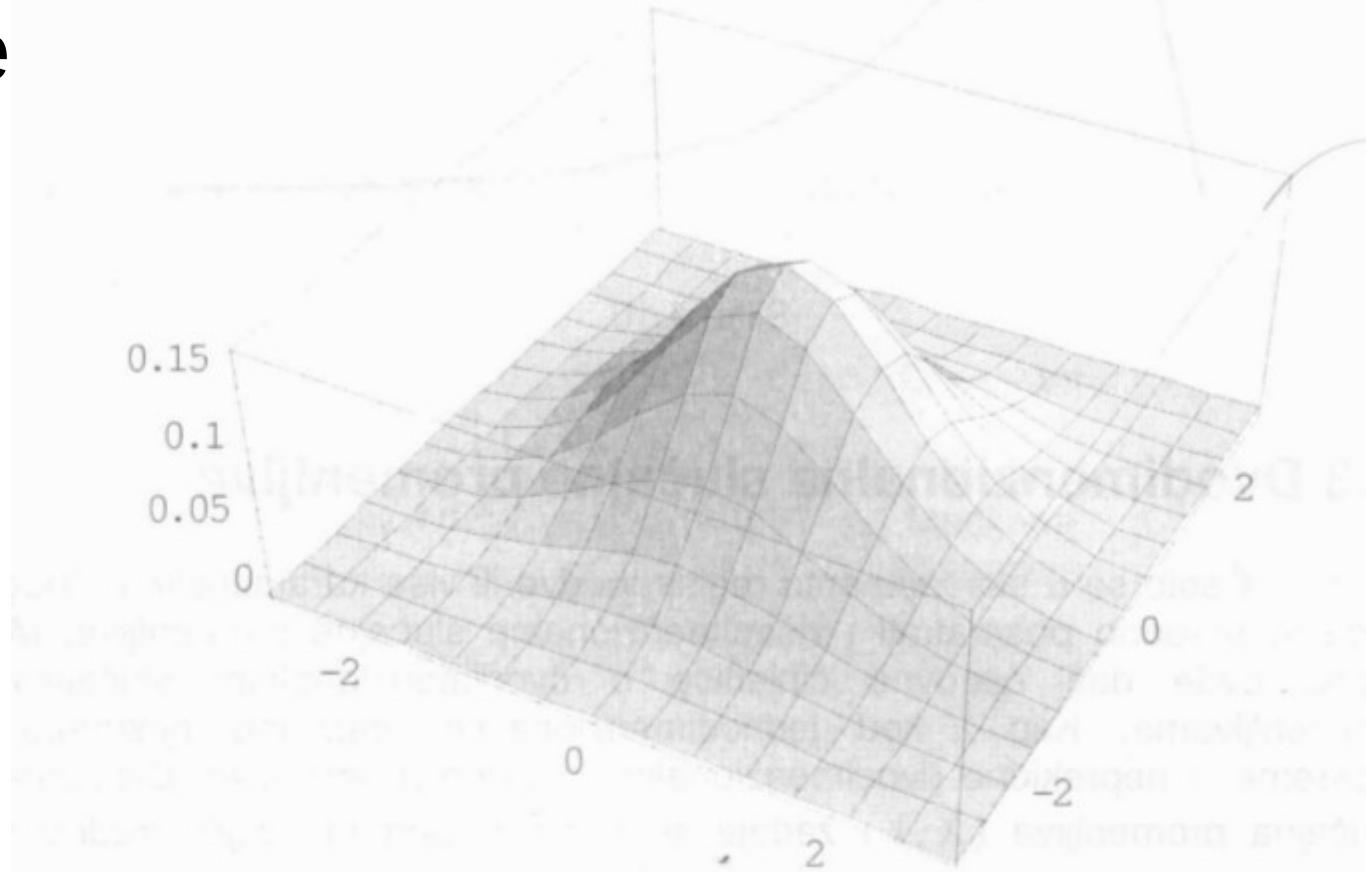
- U kutiji se nalaze 3 zelene i 3 crvene kuglice. Igrač bira 3 kuglice iz kutije i baca pravilnu kocku onoliko puta koliko je izvukao zelenih kuglica. Neka je  $X$  slučajna promjenljiva koja označava broj izvučenih zelenih kuglica, a  $Y$  slučajna promjenljiva koja označava broj pojavljivanja 6. Naći raspodjelu promjenljive  $(X, Y)$ .

# Rješenje

$X \setminus Y$	0	1	2	3
0	1/20	0	0	0
1	3/8	3/40	0	0
2	5/16	1/8	0	0
3	25/864	5/288	1/288	1/4320

# Neprekidne dvodimenzione slučajne promjenljive

- Neprekidna slučajna promjenljiva ( $X, Y$ ) zadaje se funkcijom gustine  $\varphi(x, y)$ .
- Najpoznatija je dvodimenzionalna normalna raspodjelja



# Koeficijent korelaciјe

- Koeficijent korelaciјe pokazuje stepen linearne povezanosti dvije slučajne promjenljive

$$\rho(X, Y) = \frac{E((X - m_X)(Y - m_Y))}{\sqrt{D(X)D(Y)}} = \frac{E(XY) - m_X m_Y}{\sqrt{D(X)D(Y)}}$$

- Osobine

$$-1 \leq \rho(X, Y) \leq 1$$

pozitivna korelaciјa – ako raste X raste i Y

negativna korelaciјa – ako raste X opada Y

ako je korelaciјa 0 – ne postoji linearна povezanost

ako je  $\rho(X, Y) = 1$ , tada je  $Y = a + bX$ ,  $b > 0$

ako je  $\rho(X, Y) = -1$ , tada je  $Y = a + bX$ ,  $b < 0$

ako promjenljiva (X, Y) ima dvodimenzionalnu normalnu raspodjelu i ako je  $\rho=0$ , slučajne promjenljive X i Y su nezavisne

## Slučajne promjenljive, zadaci za vježbu

1. Pravilan dinar baca se 2 puta. Ako oba puta padne ista strana, izvodi se još jedno bacanje. Naći raspodjelu slučajne promjenljive  $X$  koja predstavlja broj grbova.
2. Prvog dana cijena nekog proizvoda je 5. Svakog dana cijena može da poraste za 1 sa vjerovatnoćom 0.8 ili da se smanji za 1 sa vjerovatnoćom 0.2. Naći raspodjelu cijene  $S$  tog proizvoda trećeg dana. Naći vjerovatnoću da je cijena najviše 5.
3. Vjerovatnoća da je proizvod neispravan je 0.2. Radi kontrole kvaliteta iz serije se bira uzorak od 4 elementa, a serija se odbacuje ako je u uzorku bar dva neispravna proizvoda. Naći raspodjelu broja nepravnih proizvoda u uzorku, kao i vjerovatnoću da se serija odbaci.
4. Slučajna promjenljiva  $X$  ima normalnu raspodjelu sa parametrima  $m = 0$  i  $\sigma^2 = 1$ . Odrediti vjerovatnoće:
  - a)  $P\{X < 2\}$
  - b)  $P\{0 < X < 1.42\}$
  - c)  $P\{-1.79 < X < 0.54\}$ .
5. Dimenzija prečnika šrafa je slučajna promjenljiva sa normalnom raspodjelom sa parametrima  $m = 2.5\text{mm}$  i  $\sigma^2 = 0.01\text{mm}^2$ . Kolika je vjerovatnoća da će prečnik biti između 2.35 i 2.8 mm?
6. Odrediti numeričke karakteristike slučajne promjenljive  $X$  koja predstavlja broj grbova u tri bacanja novčića.