

# Verjetnost:

$$\binom{n}{k} = \frac{n!}{k!(n-k)!}$$

1

Distributivnost:  $(A \cap B) \cup C = (A \cup C) \cap (B \cup C)$   
 $(A \cup B) \cap C = (A \cap C) \cup (B \cap C)$

$$\binom{n}{1} = n \quad \text{in} \quad \binom{n}{0} = 1$$

De Morganovi pravili:  $\overline{A \cup B} = \bar{A} \cap \bar{B}$   
 $\overline{A \cap B} = \bar{A} \cup \bar{B}$

Popoln sistem dogodkov:

$$A_i \neq \emptyset, A_i \cap A_j = \emptyset \quad i \neq j, \bigcup_{i=1}^n A_i = \Omega$$

Verjetnost dogodka:  $P(A) = \frac{k}{n}$  - klasična definicija  
st. ugodnih izidov / st. vseh izidov

$P(A) = \frac{m(A)}{m(S)}$  - geometrijska definicija  
neka mera

relativna frekvenca dogodka  $A$

$f_n(A) = \frac{k}{n} \rightarrow P(A)$  - statistična definicija  
velika st. poskusov (Bernoullijev zakon stabilnosti)

Verjetnost je preslikava  $P: S \rightarrow R$ , ki ustreza naslednjim aksiomom: - aksiomatična definicija

1.  $P(A) \geq 0$  za vsak  $A \in S$

2.  $P(\Omega) = 1$

3. za  $A$  in  $B$  (nezveljivost)  $(A \cap B = \emptyset)$  velja:  $P(A \cup B) = P(A) + P(B)$

Posledice:

1.  $P(\bar{A}) = 1 - P(A)$

$$P(A \cap \bar{B}) = P(A) - P(A \cap B)$$

2.  $P(\emptyset) = 0$

3.  $A \subseteq B \rightarrow P(A) \leq P(B)$

4.  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$

5.  $P(A \cup B \cup C) = P(A) + P(B) + P(C) - P(A \cap B) - P(A \cap C) - P(B \cap C) + P(A \cap B \cap C)$

Pogojna verjetnost:

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

$\rightarrow$  Verjetnost, da se je zgodil A pri pogoju, da se je zgodil B.

če  $P(B) \neq 0$ , potem:  $P(A \cap B) = P(B) P(A|B)$

če  $P(A) \neq 0$ , potem:  $P(A \cap B) = P(A) P(B|A)$

• Neodvisnost dogodkov:  $P(A|B) = P(A)$  oz.  $P(B|A) = P(B)$

Dogodka A in B sta neodvisna natanko tedaj, ko velja produktna formula:  $P(A \cap B) = P(A)P(B)$   
 ↳ Nezdružljiva pa sta, če:  $P(A \cap B) = 0$ . Ni isto!!!

• Popolna verjetnost:  $H_1, \dots, H_n$  - popoln sistem dogodkov  $\rightarrow H_i \neq \emptyset, H_i \cap H_j = \emptyset \text{ } i \neq j$   
 $\bigcup_{i=1}^n H_i = \Omega$

$P(A) = \sum_{i=1}^n P(H_i) P(A|H_i)$   $\rightarrow$  Uporabimo pri dvofaznem poskusu.

produktna formula

Denimo, da se je dogodek A zgodil. Zanima nas, kolikšna je verjetnost, da se je pred tem zgodila hipoteza  $H_k$ ?

• Bayesov obrazec:

$P(H_k|A) = \frac{P(H_k) P(A|H_k)}{\sum_{i=1}^n P(H_i) P(A|H_i)}$   
 ↳ formula o popolni verjetnosti

diskretne (točke) / zvezna (interval)

Določena je z izlogo vrednosti ( $Z_x$ ) in porazdelitvenim zakonom.

• Slučajna spremenljivka X: funkcija, ki vsakemu izidu poskusa priredi neko realno število.

↳  $X: \Omega \rightarrow \mathbb{R}$  in  $g: \mathbb{R} \rightarrow \mathbb{R} \rightarrow$  potem tudi  $Y = g(X): \Omega \rightarrow \mathbb{R}$  slučajna spremenljivka!

• Porazdelitvena funkcija:  $F_X: \mathbb{R} \rightarrow [0,1]$  in  $F_X(x) = P(X \leq x)$

Lastnosti: 1.  $0 \leq F_X(x) \leq 1$

2.  $\lim_{x \rightarrow -\infty} F_X(x) = 0$  in  $\lim_{x \rightarrow \infty} F_X(x) = 1$

3.  $P(x_1 < X < x_2) = F_X(x_2) - F_X(x_1)$

4.  $x_1 < x_2 \rightarrow F_X(x_1) \leq F_X(x_2)$  ↑ monoton, naraščajoča

5.  $\lim_{h \rightarrow 0} F_X(x+h) = F_X(x)$   
 $h > 0$  ↳ z desne zvezna (lahko skok)

• Verjetnostna funkcija: (za diskretne X)

$p_k = P(X = x_k), k = 1, 2, \dots \rightarrow p_k \geq 0$  in  $\sum_{k=1}^{\infty} p_k = 1$

↳ Verjetnostna shema:  $X: \begin{pmatrix} x_1 & x_2 & \dots & x_k & \dots \\ p_1 & p_2 & \dots & p_k & \dots \end{pmatrix}$

če  $x_j < x_k$ , potem:  $F_X(x_k) = P(X \leq x_k) = \sum_{i=1}^k p_i$

Geometrijska vrsta:  
 $\sum_{n=0}^{\infty} a q^n = \frac{a}{1-q}$

• Matematično upanje:

$E(X) = \sum_{i=1}^{\infty} x_i p_i$  - "uteženo povprečje" vrednosti (pričakovana vrednost)  
 ↳ ne obstaja vedno!

Lastnosti: 1.  $E(g(X)) = \sum_{i=1}^{\infty} g(x_i) p_i$

2.  $E(X+Y) = E(X) + E(Y)$

3.  $E(aX+b) = aE(X) + b$

4.  $E((X-E(X))^2) = E(X^2) - E(X)^2$

(varianca)

• Disperzija in standardni odklon:  
 ↳ Graepričnost

$D(X) = E((X-E(X))^2) = \sum_{i=1}^{\infty} (x_i - E(X))^2 p_i = E(X^2) - E(X)^2 = \sum_{i=1}^{\infty} x_i^2 p_i - \left(\sum_{i=1}^{\infty} x_i p_i\right)^2$

$\sigma(X) = \sqrt{D(X)}$

Velja:  $D(aX+b) = a^2 D(X)$

Standardizirana slučajna spremenljivka:  $X^* = \frac{X - E(X)}{\sigma(X)}$ , velja:  $E(X^*) = 0$  in  $D(X^*) = 1$

• Enakomerna diskretna porazdelitev:

$$X \sim \begin{pmatrix} x_1 & x_2 & \dots & x_n \\ \frac{1}{n} & \frac{1}{n} & \dots & \frac{1}{n} \end{pmatrix}$$

končno mnogo enakih verjetnih izidov

$$F_X(x) = \begin{cases} 0, & x \leq x_1 \\ \frac{i}{n}, & x_i \leq x \leq x_{i+1} \\ 1, & x > x_n \end{cases}$$

$$E(X) = \frac{n+1}{2} \quad \text{in} \quad D(X) = \frac{n^2-1}{12}$$

→ možna sta le dva izida: zgodil/ ne zgodil

• Bernoullijev obrazec:

n - število ponovitev  
k - A se zgodi tolikokrat

$$P_n(k) = \binom{n}{k} p^k (1-p)^{n-k}$$

Binomski simbol:

$$\binom{n}{k} = \frac{n!}{k!(n-k)!}$$

$$\binom{n}{0} = 1, \quad \binom{n}{1} = n$$

• Bernoullijeva porazdelitev:

ena ponovitev poskusa

$$F_X(x) = \begin{cases} 0, & x < 0 \\ 1-p, & 0 \leq x < 1 \\ 1, & x \geq 1 \end{cases}$$

$$X \sim \begin{pmatrix} 0 & 1 \\ 1-p & p \end{pmatrix}$$

$$E(X) = p$$

$$D(X) = (1-p) \cdot p$$

• Binomska porazdelitev  $B(n, p)$ :

(ponavljanje Bernoullija)

kolikokrat se je nekaj zgodilo? → končna

$$X \sim \begin{pmatrix} 0 & 1 & \dots & n \\ P_n(0) & P_n(1) & \dots & P_n(n) \end{pmatrix}$$

$$E(X) = n \cdot p, \quad D(X) = n \cdot p \cdot (1-p)$$

• Geometrijska porazdelitev:

kdaj se nekaj prvič zgodi? → neskončna

$$X \sim \begin{pmatrix} 1 & 2 & \dots & k & \dots \\ p_1 & p_2 & \dots & p_k & \dots \end{pmatrix}, \quad p_k = (1-p)^{k-1} \cdot p$$

$$E(X) = \frac{1}{p}, \quad D(X) = \frac{1-p}{p^2}$$

• Poissonova porazdelitev:

$$X \sim P(\lambda)$$

$$X \sim \begin{pmatrix} 0 & 1 & \dots & k & \dots \\ P_\lambda(0) & P_\lambda(1) & \dots & P_\lambda(k) & \dots \end{pmatrix}, \quad P_\lambda(k) = \frac{e^{-\lambda} \lambda^k}{k!}$$

$$E(X) = \lambda, \quad D(X) = \lambda$$

Poissonov izrek:  $\lambda \in \mathbb{R}^+$  in  $n \in \mathbb{N}$  in  $p = \frac{\lambda}{n}$ , potem:

$$\lim_{n \rightarrow \infty} \binom{n}{k} p^k (1-p)^{n-k} = \frac{e^{-\lambda} \lambda^k}{k!}$$

↓  
aproximirano lahko z binomskim

→ povprečno št. na enoto  
[vozil/min] ali [smrti/leto]  
(koeficient pojavitve na eno enoto)

Velik n ali majhen p garantirata dober rezultat tega postopka!

Slučajna zvezna spremenljivka X:

$P(x_1 < X \leq x_2) = P(x_1 \leq X \leq x_2) = P(x_1 \leq X < x_2) = P(x_1 < X < x_2)$  → vključitev robov ne vpliva na verjetnost

$P(X=x) = 0$  → ni pa nujno nemogoče (le X je neskončen)

Gostota verjetnosti: za poljubna  $x_1, x_2 \in \mathbb{R}$  ( $x_1 < x_2$ ) velja:  $P(x_1 < X \leq x_2) = \int_{x_1}^{x_2} p_X(x) dx$

$p_X$  - pozitivna integrabilna funkcija  
 izhaja iz verjetnostne funkcije za diskretne spremenljivke

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

Porazdelitvena funkcija:

$F_X(x) = P(X \leq x) = \int_{-\infty}^x p_X(t) dt$

- 1.  $0 \leq F_X(x) \leq 1$
- 2. naraščajoča
- 3.  $P(a < X < b) = F_X(b) - F_X(a)$

Matematično upanje:

$E(X) = \int_{-\infty}^{\infty} x \cdot p_X(x) dx$  — nepravi integral →  $E(X) = \lim_{a \rightarrow -\infty} \int_a^0 x \cdot p_X(x) dx + \lim_{b \rightarrow \infty} \int_0^b x \cdot p_X(x) dx$   
 zato  $E(X)$  ne obstaja vedno!

Disperzija in standardni odklon:

$D(X) = E(X^2) - E(X)^2 = \int_{-\infty}^{\infty} x^2 p_X(x) dx - \left( \int_{-\infty}^{\infty} x p_X(x) dx \right)^2$

$\sigma(X) = \sqrt{D(X)}$

Velja:  $D(aX+b) = a^2 D(X)$

$D(X) = E((X-E(X))^2) = \int_{-\infty}^{\infty} (x-E(X))^2 p_X(x) dx$

Standardizirana slučajna spremenljivka:  $Z = \frac{X-E(X)}{\sigma(X)}$ ,  $E(Z) = 0$ ,  $D(Z) = 1$

→ vse točke  $Z_X = [a, b]$  enako verjetne

Enakomerna zvezna porazdelitev:

$p_X(x) = \begin{cases} \frac{1}{b-a}, & a \leq x \leq b \\ 0, & \text{sicer} \end{cases}$

$F_X(x) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & x > b \end{cases}$

$E(X) = \frac{a+b}{2}$  in  $D(X) = \frac{(b-a)^2}{12}$

→ X je čakalna doba do 1. pojavitve s parametrom  $\lambda$  na  $Z_X = [0, \infty]$  → nima spomina

Eksponentna porazdelitev: (podobnost = geometrijsko porazdelitvijsko)

$p_X(x) = \lambda e^{-\lambda x}$ ,  $F_X(x) = 1 - e^{-\lambda x}$

$E(X) = \frac{1}{\lambda}$  in  $D(X) = \frac{1}{\lambda^2}$

→  $\lambda$  - povprečno št. pojavitev na enoto


Por partes:  $\int u dv = uv - \int v du$

L'Hopitalovo pravilo:  
 $\lim_{b \rightarrow \infty} b e^{-\lambda b} = \lim_{b \rightarrow \infty} \frac{b}{e^{\lambda b}} \stackrel{\text{odvod po b}}{=} \lim_{b \rightarrow \infty} \frac{1}{\lambda e^{\lambda b}} = 0$

(podobnost + binomska porazdelitev)

• Normalna ali Gaussova porazdelitev :  $X \sim N(\mu, \sigma)$

$z_x = (-\infty, \infty)$



$$p_x(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

$$E(X) = \mu \quad \text{in} \quad D(X) = \sigma^2$$

Vsota velikega števila neodvisnih slučajnih spremenljivk limitira proti normalni porazdelitvi!

(5)

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

Standardizirana normalna porazdelitev :  $Z \sim N(0, 1)$

$$F_z(z) = \Phi(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{1}{2}t^2} dt$$

→ tabele

$$P(a < Z \leq b) = \Phi(b) - \Phi(a)$$

$$(\Phi(-z) = 1 - \Phi(z))$$

Kvantile, percentile :  $P(X \leq x_p) = p$  - p-ta kvantila zvečne porazdelitve X

- mediana :  $x_{0,5} = \mu$

- decile :  $x_{0,1}, x_{0,2}, \dots, x_{0,9}$

- kvartile :  $x_{0,25}, x_{0,5}, x_{0,75}$

- interkvartilni razpon :  $x_{0,75} - x_{0,25}$

• Lognormalna porazdelitev :  $X = e^Y$ , kjer  $Y \sim N(\mu, \sigma)$ ,  $z_x = (0, \infty)$

$$p_x(x) = \frac{1}{\sigma x \sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{\ln x - \mu}{\sigma}\right)^2}$$

$$F_x(x) = F_y(\ln x) = \Phi\left(\frac{\ln x - \mu}{\sigma}\right)$$

$$E(X) = e^{\mu + \frac{\sigma^2}{2}} \quad \text{in} \quad D(X) = e^{2\mu + \sigma^2}(e^{\sigma^2} - 1)$$

Produkt velikega števila neodvisnih slučajnih spremenljivk limitira proti lognormalni porazdelitvi!

• Porazdelitev hi-kvadrat :  $X \sim \chi^2(n)$ ,  $z_x = (0, \infty)$ , n-št. prostostnih stopenj

$$p_x(x) = \frac{1}{2^{\frac{n}{2}} \Gamma\left(\frac{n}{2}\right)} x^{\frac{n}{2}-1} e^{-\frac{x}{2}}$$

$$\Gamma(r) = \int_0^{\infty} t^{r-1} e^{-t} dt$$

→ Pri velikih n se približuje normalni porazdelitvi!

$$E(X) = n \quad \text{in} \quad D(X) = 2n$$

• Studentova t-porazdelitev :  $z_T = (-\infty, \infty)$ , n-št. prostostnih stopenj

$$p_T(x) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{n\pi} \Gamma\left(\frac{n}{2}\right)} \left(\frac{n}{n+x^2}\right)^{\frac{n+1}{2}}$$

$$\text{za } n > 1 : E(T) = 0$$

$$\text{za } n > 2 : D(T) = \frac{n}{n-2}$$

Slučajni vektor:  $X = (X_1, X_2, \dots, X_n) \rightarrow n$ -terica slučajnih spremenljivk

Porazdelitvena funkcija:  $F_X(x_1, x_2, \dots, x_n) = F(x_1, x_2, \dots, x_n) = P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n)$

↳ naraščajoča in zvežna z desne

1)  $F_{(x,y)}(-\infty, -\infty) = 0$  in  $F_{(x,y)}(+\infty, +\infty) = 1 \rightarrow 0 \leq F_{(x,y)}(x,y) \leq 1$  vsebinsko porazdelitvi (x,y)

2)  $F_{(x,y)}(-\infty, y) = F_{(x,y)}(x, -\infty) = 0$  in  $F_{(x,y)}(+\infty, y) = F_Y(y)$ ,  $F_{(x,y)}(x, +\infty) = F_X(x)$

3)  $P((X,Y) \in [a,b] \times [c,d]) = F_{(x,y)}(b,d) - F_{(x,y)}(a,d) - F_{(x,y)}(b,c) + F_{(x,y)}(a,c)$

Diskreten slučajni vektor:  $\rightarrow$  diskretne stereo mnoge točke  $\cdot z_{(x,y)}$

Verjetnostna funkcija slučajnega vektorja:  $p_{ij} = P(X=x_i, Y=y_j)$ ,  $i, j \in \mathbb{N}$

$p_{ij} \geq 0$  in  $\sum_{i=1}^{\infty} \sum_{j=1}^{\infty} p_{ij} = 1$

Robni porazdelitvi X in Y:  $q_i = P(X=x_i) = \sum_{j=1}^{\infty} p_{ij}$  seštejemo po x in  $r_j = P(Y=y_j) = \sum_{i=1}^{\infty} p_{ij}$  seštejemo po y

Pogojne porazdelitve:  $r_k \neq 0 \rightarrow p_{ik} = P(X=x_i | Y=y_k) = \frac{p_{ik}}{r_k}$

$p_{ik} \geq 0$  in  $\sum_{i=1}^{\infty} p_{ik} = 1$

Pogojno matematično upanje:  $E(X | y_k) = \sum_{i=1}^{\infty} x_i p_{ik} = \frac{1}{r_k} \sum_{i=1}^{\infty} x_i p_{ik}$

$E(X) = \sum_{k=1}^{\infty} E(X | y_k) r_k$

Neodvisnost slučajnih spremenljivk:

X in Y neodvisni, če:  $F_{(x,y)}(x,y) = F_X(x) F_Y(y)$

$P(X=x, Y=y) = P(X=x) P(Y=y)$

$p_{ij} = q_i r_j$

$p_{ik} = q_i$

neodvisni sta, če velja vsaj eden od teh pogojev

• zvezen slučajni vektor:  $\rightarrow Z_{(x,y)} = Z_x \times Z_y \subseteq \mathbb{R}^2$  (7)

Gostota verjetnosti slučajnega vektorja: je taka integrabilna funkcija  $p(x,y)$ , da velja:

$$F_{(x,y)}(x,y) = P(X \leq x, Y \leq y) = \int_{-\infty}^x \int_{-\infty}^y p(x,y)(u,v) du dv$$

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} p(x,y)(u,v) du dv = 1 \quad \text{in} \quad P((X,Y) \in (a,b] \times (c,d]) = \int_a^b \int_c^d p(x,y)(u,v) du dv$$

Robni gostoti verjetnosti:  $p_x(x) = \int_{-\infty}^{\infty} p(x,y)(x,y) dy$  in  $p_y(y) = \int_{-\infty}^{\infty} p(x,y)(x,y) dx$

Pogojne porazdelitve:  $p_{X|Y}(x) = \frac{p(x,y)(x,y)}{p_y(y)}$

$$\int_{-\infty}^{\infty} p_{X|Y}(x) dx = 1 \quad \text{in} \quad P(a \leq X \leq b | Y=y) = \int_a^b p_{X|Y}(x) dx = \int_a^b \frac{p(x,y)(x,y)}{p_y(y)} dx$$

Pogojno matematično upanje:  $E(X|Y=y) = \int_{-\infty}^{\infty} x p_{X|Y}(x) dx = \frac{1}{p_y(y)} \int_{-\infty}^{\infty} x p(x,y)(x,y) dx$

*regresijska enačba*

$$E(X) = \int_{-\infty}^{\infty} E(X|Y=y) p_y(y) dy$$

Neodvisnost slučajnih spremenljivk:  $X$  in  $Y$  sta neodvisni če:

$$- F_{(x,y)}(x,y) = F_x(x) F_y(y)$$

$$- p_{(x,y)}(x,y) = p_x(x) p_y(y)$$

$$- p_{X|Y}(x) = p_x(x)$$

je izpolnjen vsaj eden od teh pogojev

• Funkcije slučajnega vektorja:  $Z(z) = g(X(z), Y(z))$  oz.  $Z = g(X, Y)$

Diskreten vektor:  $P(Z = z_k) = \sum_{i,j: g(x_i, y_j) = z_k} p_{ij}$  in  $E(Z) = \sum_{i=1}^{\infty} \sum_{j=1}^{\infty} g(x_i, y_j) p_{ij}$

zvezen vektor:  $F_z(z) = \iint_{g(x,y)=z} p(x,y)(x,y) dx dy$

Vedno velja:

$$E(Z) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x,y) p(x,y)(x,y) dx dy$$

$$E(Z) = E(X) + E(Y)$$

• Kovarianca: če sta  $X$  in  $Y$  neodvisni slučajni spremenljivki, velja:

$E(XY) = E(X)E(Y)$  in  $D(X+Y) = D(X) + D(Y)$

če imata  $X$  in  $Y$  končni matematični upanji in končni disperziji, potem:

$Cov(X, Y) = \sigma_{xy} = K(X, Y) = E((X - E(X))(Y - E(Y)))$

- Lastnosti:
- $Cov(X, X) = D(X)$
  - $Cov(X, Y) = E(XY) - E(X)E(Y)$
  - $Cov(X, Y) = Cov(Y, X)$
  - $D(X+Y) = D(X) + D(Y) + 2Cov(X, Y)$
  - $Cov(a+bX, c+dY) = bdCov(X, Y)$
  - $|Cov(X, Y)| \leq \sigma(X)\sigma(Y)$

• Korelacija:  $\rho(X, Y) = Corr(X, Y) = r(X, Y) = \frac{Cov(X, Y)}{\sigma(X)\sigma(Y)}$

- Lastnosti:
- $-1 \leq \rho(X, Y) \leq 1$
  - če  $Cov(X, Y) = 0$ , potem  $\rho(X, Y) = 0 \rightarrow X, Y$  nekorelirani, sicer korelirani
  - $|\rho(X, Y)| = 1 \rightarrow X$  in  $Y$  linearno korelirani

• Matematično upanje:  $E(X) = (E(x_1), \dots, E(x_n))$

• Disperzija (kovariančna matrika):  ~~$K = Cov(X, X)$~~   $K_{ij} = Cov(x_i, x_j)$

- Lastnosti:
- $K_{ii} = D(x_i)$
  - vse lastne vrednosti  $K$  so nenegativne
  - $K_{ji} = K_{ij}$

• Dvovarščina normalna porazdelitev in standardna dvovarščina normalna porazdelitev:

Glej liste, predavanj!

$(X, Y)$  je dvovarščina normalna porazdelitev s parametri:

regresijski krivulji sta premici

robni porazdelitvi

$\mu_x, \mu_y, \sigma_x, \sigma_y, \rho \rightarrow X \sim N(\mu_x, \sigma_x)$  in  $Y \sim N(\mu_y, \sigma_y)$

Velja, da če sta  $X$  in  $Y$  neodvisni, sta tudi nekorelirani in obratno!

Standardna dvovarščina normalna porazdelitev:  $X, Y \sim N(0, 1)$



• Meenakost Čebiseva:

če za  $X$  obstaja  $E(X)$  in  $D(X)$  potem:  $P[E(X) - k\sigma(X) < X < E(X) + k\sigma(X)] \geq 1 - \frac{1}{k^2}$   
Ocene verjetnosti, da se  $X$  nahaja na teh intervalih

• Meenakost Markova: za  $X$  obstaja  $E(X)$  in  $Z_x \subseteq [0, \infty)$ :  $P[X \geq kE(X)] \leq \frac{1}{k}$

• Zaporedje slučajnih spremenljivk:

$E(S_n) = n \cdot E(X)$   
 $E(\bar{X}_n) = E(X)$   
 $D(S_n) = n \cdot D(X)$   
 $D(\bar{X}_n) = \frac{D(X)}{n}$

(načeloma lahko zaporedje  
obkrožnava vsot potisk  
s spremenljivko  $S_n$ )

$\bar{X}_n = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$  → povprečje  
 $S_n = X_1 + X_2 + \dots + X_n$  → delna vsota  
 $Z_n = \frac{S_n - E(S_n)}{\sigma(S_n)}$  → standardizacija delne vsote

• Zakon velikih števil:

če  $n \rightarrow \infty$ , potem se vedno približujemo  $E(\bar{X}_n) = E(X) = \mu$ !

če so  $X_i$  medsebojno neodvisne in enako porazdeljene z  $E(X_i) = \mu < \infty$  in  $D(X_i) < \infty$ , potem z za vsak  $\epsilon > 0$ :

$\lim_{n \rightarrow \infty} P(|\bar{X}_n - \mu| < \epsilon) = 1$

• Centralni limitni izrek:

če so  $X_i$  medsebojno neodvisne in enako porazdeljene z  $E(X_i) < \infty$  in  $D(X_i) < \infty$ , potem:

če  $n \rightarrow \infty$ , potem se ne glede na porazdelitev slučajnih spremenljivk bližamo normalni porazdelitvi:

$\lim_{n \rightarrow \infty} P(Z_n \leq x) = \Phi(x)$  Gaussov integral

Binomska porazdelitev  $X \sim B(n, p)$  → veliki  $n$  normalna porazdelitev.

Poissonova porazdelitev  $X \sim P(\lambda)$  → veliki  $\lambda$  normalna porazdelitev.

Hi-kvadrat porazdelitev  $X \sim \chi^2(n)$  → veliki  $n$  normalna porazdelitev.

Studentova porazdelitev  $T$  z  $m$  p.s. → veliki  $m$  standardna normalna porazdelitev.

# Statistika:

statistična enota - predmet proučevanja

statistična spremenljivka  $X$  - lastnost enote, ki nas zanima

populacija  $\mathcal{P}$  - množica vseh enot

parameter  $\theta$  - značilnost populacije

vzorec  $a_1, \dots, a_n \in \mathcal{P}$  - del populacije

vzorčna statistika  $Y = f(X_1, \dots, X_n)$  - značilnost vzorca

cenilka  $\hat{\theta}$  parametra  $\theta$  - vzorčna statistika, katere porazdelitev je odvisna le od  $\theta$

↳  $\theta$  ne moremo določiti na vzorcu, zato uporabljamo cenilke!

Vzorčenje: Vzorcju ustreza slučajni vektor  $(X_1, \dots, X_n)$ .

Enostaven slučajni vzorec -  $X_i$  med seboj neodvisne in enako porazdeljene slučajne spremenljivke.

Reprezentativen - dovolj velik in nepristransko izbran.

primerjava z delno vsoto zaporedja slučajnih spremenljivk

Vzorčno povprečje:  $\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$

če je  $(X_1, \dots, X_n)$  enostaven slučajni vzorec z  $E(X_i) = \mu$  in  $D(X_i) = \sigma^2$ ,  $i=1, \dots, n$ , potem:

$$E(\bar{X}) = \mu \quad \text{in} \quad D(\bar{X}) = \frac{\sigma^2}{n}$$

Porazdelitev vzorčnega povprečja: če je  $X \sim N(\mu, \sigma)$ , potem:  $\bar{X} \sim N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$

Tudi če  $X$  ni  $N(\mu, \sigma)$  po centralnem limitnem izreku za  $n > 30$  velja:

$$\bar{X} \sim N\left(\mu, \frac{\sigma}{\sqrt{n}}\right) \quad \text{oz.} \quad \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$$

standardizirano vzorčno povprečje

Vzorčna disperzija:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

↳  $S^2$  je slučajna spremenljivka, saj je pri isti populaciji vzorec vedno različen!

če je  $(X_1, \dots, X_n)$  enostaven slučajni vzorec z  $E(X_i) = \mu$  in  $D(X_i) = \sigma^2$ ,  $i=1, \dots, n$ , potem:

$$E(S^2) = \sigma^2$$

Vzorčna standardna deviacija:  $S = \sqrt{S^2}$

Porazdelitev vzorčne disperzije: če  $X \sim N(\mu, \sigma)$ , potem:  $\frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$

Centralni limitni izreka,  $n > 30$ :  $S^2 \sim N\left(\sigma^2, \sqrt{\frac{2}{n-1}} \sigma^2\right)$

• Standardizirano vzorčno povprečje:  $\sigma^2$  ne poznamo, nadomestimo z  $S^2$

(11)

$X \sim N(\mu, \sigma)$  →  $T = \frac{\bar{x} - \mu}{\sqrt{\frac{S^2}{n}}}$  - Studentova t-porazdelitev z  $(n-1)$  prost. stopnjami

• Vzorčna korelacija:  $(X_1, Y_1), \dots, (X_n, Y_n)$  je enostaven slučajni vzorec slučajnega vektorja  $(X, Y)$ .

$$R = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

• Ocenjevanje parametrov:
 

- intervalsko ocenjevanje → ocenimo interval, ki s predpisano verjetnostjo vsebuje parameter (podano razpon)
- točkasto ocenjevanje → parameter  $\theta$  ocenimo s številsko vrednostjo cenilke  $\hat{\theta}$  (podana napaka)

Lastnosti cenilk:
 

- $\hat{\theta}$  je nepristranska cenilka za  $\theta$ , če je  $E(\hat{\theta}) = \theta$ .
- $\hat{\theta}$  je asimptotično nepristranska cenilka za  $\theta$ , če je  $\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta$ .
- od cenilk  $\hat{\theta}_1$  in  $\hat{\theta}_2$  za  $\theta$  je učinkovitejša  $\hat{\theta}_1$ , če  $D(\hat{\theta}_1) < D(\hat{\theta}_2)$ .
- $\nabla(\hat{\theta}) = SE(\hat{\theta})$  - standardna napaka cenilke  $\hat{\theta}$ .
- $\hat{\theta}$  je dosledna cenilka, če za vsak  $\epsilon > 0$ :  $\lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| \geq \epsilon) = 0$ .

Primeri cenilk:
 

- $\bar{X}$  cenilka za  $\mu$  (vzorčno povprečje) - nepristranska, dosledna
- $S^2$  cenilka za  $\sigma^2$  (vzorčna disperzija) - pristranska, asimptotično nepristranska
- $S$  cenilka za  $\sigma$  (vzorčna standardna deviacija)

• Momenti višjega reda: moment reda  $k$  glede na točko  $a \in \mathbb{R}$  je:  $m_k(a) = E((X-a)^k) = \int_{\mathbb{R}} (x-a)^k p_X(x) dx$

$a=0$  → začetni moment  $z_k = m_k(0)$  npr:  $z_1 = E(X)$

$a=E(X)$  → centralni moment  $m_k = m_k(E(X))$  npr:  $m_2 = D(X)$

↳ Uporabljamo za izbiro metode modela!

• Metoda momentov (MoM):

$z_k = E(X^k)$  -  $k$ -ti začetni moment  $X$

$\hat{z}_k = \frac{1}{n} \sum_{i=1}^n X_i^k$  -  $k$ -ti vzorčni moment  $(X_1, \dots, X_n)$

$\hat{z}_k$  je cenilka za  $z_k$

če se parameter izraža z momenti kot:  $\theta_i = f_i(z_1, z_2, \dots, z_m)$   
 potem je cenilka po MoM:  $\hat{\theta}_i = f_i(\hat{z}_1, \hat{z}_2, \dots, \hat{z}_m)$

• Metoda največjega verjetja (ML):

za  $(x_1, \dots, x_n)$  je porazdelitev podana s  $p(x, \theta)$ , ki je odvisna od  $\theta = (\theta_1, \theta_2, \dots, \theta_m)$ .

Cenilka po ML je vrednost  $\hat{\theta}$ , pri kateri  $L(\theta)$  doseže maksimum:  $L(\theta) = p(x_1, \theta) \cdot p(x_2, \theta) \cdot \dots \cdot p(x_n, \theta)$   
(funkcija verjetja)  
 $\prod_{i=1}^n p_i = \prod_{i=1}^n P(Y = (x_1, \dots, x_n))$

• Intervalsko ocenjevanje parametrov:  $\rightarrow$  kvalitativna ocena cenilke ukega parametra

Interval zaupanja  $[A, B]$ , ki s predpisano verjetnostjo (stopnjo zaupanja)  $1-\alpha$  vsebuje  $\theta$ :

$P(\theta \in [A, B]) = 1 - \alpha$  stopnja tvegovanja

• Intervali zaupanja za  $\mu$ : enostaven slučajni vzorec  $(x_1, \dots, x_n)$  z  $E(x_i) = \mu$  in  $D(x_i) = \sigma^2$ .

$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$  - nep rstransko cenilka za  $\mu$

Interval zaupanja (simetričen):

Za velike  $n$ :  $z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$  z-test

$P(-z(\alpha/2) \leq z \leq z(\alpha/2)) = 1 - \alpha$

-  $\sigma^2$  poznano:

1. izberemo  $\alpha$ ,
2. določimo  $z(\alpha/2) = z_{1-\alpha/2}$ :  $\Phi(z(\alpha/2)) = 1 - \alpha/2$
3. izračunamo  $\bar{X}$ .

Interval zaupanja:  $[\bar{X} - z(\alpha/2) \sqrt{\frac{\sigma^2}{n}}, \bar{X} + z(\alpha/2) \sqrt{\frac{\sigma^2}{n}}]$   
s stopnjo zaupanja  $(1-\alpha)$

-  $\sigma^2$  ne poznano:

nepoznani  $\sigma^2$  nadomestimo s cenilko:  $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2$

za  $n > 30$ : enako kot prej, le da  $s^2$  namesto  $\sigma^2$

za  $n < 30$ : Studentova porazdelitev z  $(n-1)$  prostostnimi stopnjami:  $T = \frac{\bar{X} - \mu}{s/\sqrt{n}}$  T-test

$t(\alpha/2) = t_{1-\alpha/2} \Leftrightarrow P(T > t(\alpha/2)) = \alpha/2$

Interval zaupanja:  $[\bar{X} - t(\alpha/2) \sqrt{\frac{s^2}{n}}, \bar{X} + t(\alpha/2) \sqrt{\frac{s^2}{n}}]$   
s stopnjo zaupanja  $(1-\alpha)$

• Enostranski interval zaupanja: imamo samo eno mejo  $-z(\alpha)$  oz  $z(\alpha)$ , druga je  $-\infty$  oz  $\infty$ .

Spodnja meja zaupanja za  $\mu$  s stopnjo zaupanja  $(1-\alpha)$ :  $\bar{X} - z(\alpha) \sqrt{\frac{\sigma^2}{n}} \leq \mu$

Zgornja meja zaupanja za  $\mu$  s stopnjo zaupanja  $(1-\alpha)$ :  $\bar{X} + z(\alpha) \sqrt{\frac{\sigma^2}{n}} \geq \mu$   $\Phi(z(\alpha)) = 1 - \alpha$

• Interval zaupanja za  $\sigma$ : če je  $[A, B]$  i.z. za  $\sigma^2$  s stopnjo z.  $(1-\alpha)$ , potem je  $[\sqrt{A}, \sqrt{B}]$  i.z. za  $\sigma$  z enako stopnjo z.  $(1-\alpha)$ !

- $\mu$  poznano:
  1. vzamemo cenilko:  $\hat{D} = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$
  2. če je  $X_i \sim N(\mu, \sigma)$ , potem:  $\chi^2 = \frac{n\hat{D}}{\sigma^2} \sim \chi^2(n)$
  3. porazdelitev ni simetrična, zato iščemo ustrezna a in b:
 
$$P(\chi^2 > b) = P(\chi^2 < a) = \alpha/2 \rightarrow a = \chi^2_{\alpha/2} \text{ in } b = \chi^2_{1-\alpha/2}$$

Interval zaupanja:  $\left[ \frac{n\hat{D}}{b}, \frac{n\hat{D}}{a} \right]$   
s stopnjo zaupanja  $(1-\alpha)$

- $\mu$  ne poznano:
  1. cenilki za  $\mu$  in  $\sigma^2 \rightarrow \bar{X}$  in  $S^2$ .
  2. če  $X_i \sim N(\mu, \sigma)$ , potem:  $\chi^2 = \frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$
  3. iščemo:  $P(\chi^2 > b) = P(\chi^2 < a) = \alpha/2 \rightarrow a = \chi^2_{\alpha/2} \text{ in } b = \chi^2_{1-\alpha/2}$

Interval zaupanja:  $\left[ \frac{(n-1)S^2}{b}, \frac{(n-1)S^2}{a} \right]$   
s stopnjo zaupanja  $(1-\alpha)$

• Normalna aproksimacija binomske porazdelitve:

n - velikost vzorca

X - št. elementov vzorca ki ustrezajo kriteriju

iščemo verjetnost p, da slučajen element populacije ustreza danemu kriteriju!

$X \sim B(n, p)$ ,  $E(X) = np$  in  $D(X) = np(1-p)$

če je  $n \gg p$ , potem:  $z = \frac{X - np}{\sqrt{np(1-p)}} \sim N(0, 1)$

V praksi za  $np > 5$  in  $n(1-p) > 5$  ta aproksimacija ustreza.

• Interval zaupanja za delež populacije:

cenilka za p je:  $\hat{p} = \frac{X}{n}$

1. Določimo  $z(\alpha/2)$  z:  $\Phi(z(\alpha/2)) = 1 - \alpha/2$ .

$z = \frac{\hat{p} - p}{\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}} \sim N(0, 1)$   
SE(p)

2. Neznani p v SE(p) nadomestimo s  $\hat{p}$ . velik vzorec!

Interval zaupanja:  $\left[ \hat{p} - z(\alpha/2) \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}, \hat{p} + z(\alpha/2) \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \right]$   
s stopnjo zaupanja  $(1-\alpha)$

$(\epsilon = |p - \hat{p}| > |z(\alpha/2) SE(\hat{p})|)$

• Statistična domneva ali hipoteza: izjava o porazdelitvi neke slučajne spremenljivke.

$H_0$  - ničelna domneva  $\rightarrow$  to preizkušamo

$\downarrow$  govori o lastnosti populacije!

$H_A$  - alternativne domneve

• Testna statistika:  $T: (X_1, \dots, X_n) \rightarrow \mathbb{R}$  z zlogo vrednosti:  $Z(T) \subseteq \mathbb{R}$

$W_0 \subseteq Z(T)$  - kritično območje testa ( $H_0$  zavrneemo)

$Z(T) \setminus W_0$  - sprejemljivo območje testa ( $H_0$  ne zavrneemo)

• Lastnosti testov:

Napaka I. vrste - zavrneemo pravilno domnevo  $H_0$ . Maksimalna verjetnost te napake je  $\alpha$  oz. stopnja značilnosti / tveganje testa.

Napaka II. vrste - ne zavrneemo  $H_0$ , čeprav je napačna. Verjetnost te napake  $\beta$  je odvisna od parametrov, velikosti vzorca...

Moc testa - verjetnost zavrnitve  $H_0$ , ki je napačna je  $1 - \beta$ .

$\alpha < p \rightarrow H_0$  ne zavrneemo  
 $\alpha > p \rightarrow H_0$  zavrneemo

p-vrednost - najmanjša stopnja značilnosti  $\alpha$ , pri kateri  $H_0$  se zavrneemo.

Splošni postopek:

1. Postavimo  $H_0$  in  $H_A$
2. Izberemo stopnjo značilnosti  $\alpha$ .
3. Določimo ustrezno testno statistiko  $T$ .
4. Poiščemo kritično območje  $W_0$ , da bo:  $P(T \in W_0 | H_0) = \alpha$ .
5. Izračunamo vrednost testne statistike  $T$  na vzorcu.
6. Če  $T \in W_0$  domnevo  $H_0$  s stopnjo značilnosti  $\alpha$  zavrneemo ozi. obratno ne zavrneemo.

• Preiskujemo je  $\mu$  normalne porazdelitve:  $(X_1, \dots, X_n)$ ;  $X \sim N(\mu, \sigma)$

$H_0: \mu = \mu_0$

Testna statistika:  $z = \frac{\bar{X} - \mu_0}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$

$H_A: \mu \neq \mu_0$

$W_0 = (-\infty, -z(\alpha/2)) \cup (z(\alpha/2), \infty)$   $\leftarrow \Phi(z(\alpha/2)) = 1 - \alpha/2$

Enostranska domneva:  $H_A: \mu < \mu_0 \rightarrow W_0 = (-\infty, -z(\alpha))$

$H_A: \mu > \mu_0 \rightarrow W_0 = (z(\alpha), \infty)$

če  $\sigma^2$  ne poznamo, ga nadomestimo s  $S^2 \rightarrow$  studentova porazdelitev z  $(n-1)$  prost. stopnjami.

Če preizkušamo druge parametre, so zadeve zelo sorodne intervalom zaupanja!

• Prekušanje skladnosti ( $\chi^2$ -test):

$H_0$  je domneva o modelu porazdelitve za dano populacijo.

1. Slučajni vzorec  $n$  razdelimo na  $k$  razredov  $S_1, \dots, S_k$ .

$O_i$  - frekvenca razreda  $S_i$

$e_i = n \cdot P(X \in S_i | H_0)$

- domnevna frekvenca  $S_i$

2. Testna statistika: 
$$\chi_0^2 = \sum_{i=1}^k \frac{(O_i - e_i)^2}{e_i}$$

3. Če je  $H_0$  pravilna in je  $m$  <sup>neprazno</sup> št. parametrov domnevane porazdelitve, za velike  $n$  velja:

$$\chi_0^2 \sim \chi^2(k-m-1)$$

4.  $W_0 = (c_\alpha, \infty)$ :  $P(\chi^2(k-m-1) > c_\alpha) = \alpha$  oz.  $c_\alpha = \chi_{1-\alpha}^2$

5. Domnevo zavrnamo, če:  $\chi_0^2 > c_\alpha$ .

• Prekušanje neodvisnosti ( $\chi^2$ -test):

$H_0$  je domneva, da sta lastnosti populacije statistično neodvisni.

1. Vzorec velikosti  $n$  razdelimo v  $r$  oz.  $s$  razredov.

$O_{ij}$  - frekvenca  $i$ -tega razreda prve in  $j$ -tega razreda druge lastnosti

$e_{ij}$  - domnevne frekvence razredov

2. Testna statistika: 
$$\chi_0^2 = \sum_{i=1}^r \sum_{j=1}^s \frac{(O_{ij} - e_{ij})^2}{e_{ij}} \sim \chi^2((r-1)(s-1))$$

predpostavimo, da  $H_0$  drži

Če sta neodvisni, potem: 
$$e_{ij} = P(L_1 \in r_i \text{ in } L_2 \in s_j) = P[L_1 \in r_i] \cdot P[L_2 \in s_j]$$

3. Določimo  $c_\alpha$  in domnevo zavrnamo, če:  $\chi_0^2 > c_\alpha$

• Prekušanje  $\sigma^2$  normalne porazdelitve:  $(X_1, \dots, X_n) \sim N(\mu, \sigma)$

$H_0: \sigma^2 = \sigma_0^2$

$H_A: \sigma_A^2 \neq \sigma_0^2$

Poznamo  $\mu$ : 
$$D^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 \rightarrow D^2 \sim \chi^2(n)$$

Ne poznamo  $\mu$ : 
$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \rightarrow S^2 \sim \chi^2(n-1)$$

$$\chi_0^2 = \frac{(n-1) \cdot S^2}{\sigma_0^2} \sim \chi^2(n-1) \quad \text{oz.} \quad \chi_0^2 = \frac{n \cdot D^2}{\sigma_0^2} \sim \chi^2(n)$$

$$W_0 = \left( \chi_{1-\alpha}^2(n \text{ oz. } (n-1)) , \infty \right)$$