

# BIOSTATISTIKA (studij Nutricionizam)

## (formule za prvi parcijalni ispit)

### Deskriptivna statistika


$\text{Im}X = \{a_1, a_2, \dots, a_i, \dots\} \Rightarrow$  skup svih vrijednosti koje  $X$  može poprimiti

$f_i =$  frekvencija (učestalost) pojavljivanja elementa  $a_i$  u nizu podataka

broj  $f_{r_i} = \frac{f_i}{n}$  : relativna frekvencija od  $a_i$  ( $n$  je broj ponavljanja pokusa)

**Histogram:**

- svaka 2 susjedna stupića se dodiruju i svaki ima težište u vrijednosti visina  $f_i$  ili  $f_{r_i}$
- površina svakog stupića jednaka je relativnoj frekvenciji pa je površina ispod cijelog grafa jednaka je 1



broj razreda (okvirno:  $\sqrt{n}$ )

**Aritmetička sredina uzorka** je broj

$$\bar{x} := \frac{1}{n}(x_1 + x_2 + \dots + x_n).$$

Ako je  $\text{Im}X = \{a_1, a_2, \dots, a_k\}$  i pritom se  $a_i$  u uzorku ponavlja  $f_i$  puta, tada

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k f_i \cdot a_i, \quad n = \sum_{i=1}^k f_i.$$

**Medijan uzorka** je broj za koji vrijedi da je 50% svih podataka manje od ili jednako njemu i 50% svih podataka veće od ili jednako njemu.

Ako je broj podataka neparan, tj  $n = 2k - 1$ ,  $k \in \mathbf{N}$ , tada je  $m = x_{(k)}$ . Za paran  $n$  ( $n = 2k$ ), vrijedi

$$m = \frac{x_{(k)} + x_{(k+1)}}{2}.$$

Općenito,  $m = x_{(\frac{n+1}{2})}$ . Vrijedi

$$x_{(\frac{p}{q})} = x_{(k+\frac{r}{q})}$$
$$x_{(\frac{p}{q})} := x_{(k)} + \frac{r}{q} (x_{(k+1)} - x_{(k)})$$

**Mod** je ona vrijednost statističkog obilježja koja se u uzorku javlja s najvećom frekvencijom.

- **BIMODALNI UZORAK:** uzorak u kojem postoje 2 vrijednosti s jednakom frekvencijom
- **UNIMODALNI UZORAK:** uzorak u kojem postoji samo jedan mod
- Ako svi podaci imaju istu frekvenciju pojavljivanja u uzorku, tada uzorak nema mod.

Neka je  $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$  uređeni niz podataka. Broj

$$d = x_{(n)} - x_{(1)}$$

naziva se **raspon uzorka**.

**Donji kvartil**  $q_L$  je ona vrijednost uzroka za koju vrijedi da je 25% svih podataka manje ili jednako od nje i 75% svih podataka veće ili jednako od nje.


$$q_L = x_{(\frac{n+1}{4})}$$

**Gornji kvartil**  $q_U$  je ona vrijednost uzroka za koju vrijedi da je 75% svih podataka manje ili jednako od nje i 25% svih podataka veće ili jednako od nje.

$$q_U = x_{(\frac{3(n+1)}{4})}$$

**Interkvartil:**  $d_q = q_U - q_L$

Uređenu petorku  $(x_{(1)}, q_L, m, q_U, x_{(n)})$  zovemo **karakteristična petorka uzorka**. Pomoću nje crtamo tzv. **"box and whisker" dijagram**, odnosno dijagram pravokutnika.



Sve što je izvan  $3d_q$  označava se točkom i smatra se "ekstrmnom vrijednošću", tj. "outlier".

**Koeficijent kvartilne varijacije:**

$$v_q = \frac{d_q}{q_L + q_U}$$

**Uzoračka varijanca:**

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

**Uzoračka standardna devijacija:**

$$s = +\sqrt{s^2}$$

Vrijedi:

$$s^2 = \frac{1}{n-1} \left( \sum_{i=1}^n x_i^2 - n\bar{x}^2 \right)$$

Ako se u uzroku  $x_1, x_2, \dots, x_n$  vrijednosti  $a_1, a_2, \dots, a_k$  pojavljuju s frekvencijom  $f_1, f_2, \dots, f_k$ , onda vrijedi:

$$s^2 = \frac{1}{n-1} \sum_{i=1}^k (a_i - \bar{x})^2 \cdot f_i = \frac{1}{n-1} \left( \sum_{i=1}^k f_i \cdot a_i^2 - n\bar{x}^2 \right)$$

**DECILI:** k-ti uzorački decil je broj  $D_k = x_{(\frac{k(n+1)}{10})}$ ,  $k = 1, 2, \dots, 9$  (k/10 podataka je manje ili jednako njemu)

**PERCENTILI:** k-ti uzorački percentil je broj  $P_k = x_{(\frac{k(n+1)}{100})}$ ,  $k = 1, 2, \dots, 99$  (k% podataka je manje ili jednako njemu)

**Uzorački k-ti centralni moment**,  $k \in \mathbb{N}$ :

$$\mu_k = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^k$$

Specijalno,

$$\mu_1 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}) = \frac{1}{n-1} \sum_{i=1}^n x_i - \frac{n\bar{x}}{n-1} = \frac{n\bar{x}}{n-1} - \frac{n\bar{x}}{n-1} = 0$$

$$\mu_2 = s^2$$

$$\mu_3 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^3$$

**Koeficijent asimetrije uzorka** (skewness) definiran je s:

$$\alpha_3 = \frac{\mu_3}{s^3} = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s} \right)^3 = \frac{1}{n-1} \sum_{i=1}^k f_i \cdot \left( \frac{a_i - \bar{x}}{s} \right)^3$$

Vrijedi:

- (i)  $\alpha_3 = 0 \Rightarrow$  uzorak je SIMETRIČAN
- (ii)  $\alpha_3 > 0 \Rightarrow$  uzorak je POZITIVNO ASIMETRIČAN
- (iii)  $\alpha_3 < 0 \Rightarrow$  uzorak je NEGATIVNO ASIMETRIČAN

**Linearna regresija:**

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \left( \sum_{i=1}^n x_i^2 - n\bar{x}^2 \right)$$

$$s_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n-1} \left( \sum_{i=1}^n y_i^2 - n\bar{y}^2 \right)$$

$$s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n-1} \left( \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \right)$$

$$\hat{\beta} = \frac{s_{xy}}{s_x^2}, \quad \hat{\alpha} = \bar{y} - \hat{\beta}\bar{x}.$$

**Pearsonov koeficijent korelacije:**

$$r = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \cdot \frac{y_i - \bar{y}}{s_y} \right) = \frac{s_{xy}}{s_x \cdot s_y}, \quad -1 \leq r \leq 1.$$

Ako je  $y_i = \alpha + \beta x_i$  za sve  $i = 1, \dots, n$  (tj. ako su  $x$  i  $y$  u egzaktnoj linearnoj vezi), tada je  $r = \frac{\beta}{|\beta|}$ .

1.  $r = 0$  nema korelacije
2.  $r = 1 (> 0)$  pozitivna korelacija (ako  $x$  raste, i  $y$  u pravilu raste)
3.  $r = -1 (< 0)$  negativna korelacija (ako  $x$  raste,  $y$  u pravilu pada)

# Osnove teorije vjerijatnosti

**Slučajni pokus** je pokus s više (mogućih) ishoda. Ishode slučajnog pokusa zovemo **dogadajima**. Dogadaje koje ne možemo razložiti na jednostavnije događaje zovemo **elementarnim dogadajima**.

**Matematički**, skup elementarnih događaja označavamo s  $\Omega$  i zovemo **prostorom elementarnih događaja**, a njegove elemente (elementarne događaje) s  $\omega_1, \omega_2, \dots$ :

$$\Omega = \{\omega_1, \omega_2, \dots\}.$$

Događaji su podskupovi od  $\Omega$  i označavaju se velikim slovima abecede:  $A, B, C, \dots$

Događaj  $C$  je **suprotan** događaj događaju  $A$  ako je  $C = A^c = \Omega \setminus A$ .

**Laplaceov model vjerojatnosti:**  $P(A) = \frac{k(A)}{k(\Omega)}$

Neka je  $A$   $n$ -člani skup i neka je  $r \in \mathbf{N}$  takav da je  $r \leq n$ . **Varijacija  $r$ -tog razreda** u skupu  $A$  jest svaka uređena  $r$ -torka  $(a_1, a_2, \dots, a_r)$  čije su sve komponente  $a_1, \dots, a_r$  međusobno različiti elementi skupa  $A$ .

$$V_n^{(r)} = n(n-1) \dots (n-r+1)$$

**Permutacija** u  $n$ -članom skupu  $A$  je svaka varijacija  $n$ -tog razreda u skupu  $A$ .

$$P_n = n!$$

Neka je  $A$  skup od  $n$  elemenata i neka je  $r \in \mathbf{N}$ . **Varijacija s ponavljanjem  $r$ -tog razreda** u skupu  $A$  je svaka uređena  $r$ -torka elemenata iz skupa  $A$  (budući da članovi te  $r$ -torke mogu biti međusobno jednaki, može biti  $r > n$ )

$$\bar{V}_n^{(r)} = [k(A)]^r$$

**Permutacije s ponavljanjem:** Označimo sa  $\bar{P}_n^{(n_1, \dots, n_k)}$  ukupan broj permutacija od  $n$  elemenata među kojima je  $n_1$  prve vrste,  $n_2$  druge vrste,  $\dots$ ,  $n_k$   $k$ -te vrste ( $n_1 + n_2 + \dots + n_k = n$ ). Tada vrijedi

$$\bar{P}_n^{(n_1, \dots, n_k)} = \frac{n!}{n_1! \cdot n_2! \cdot \dots \cdot n_k!}$$

Neka je  $A$   $n$ -člani skup i  $r \in \mathbf{N}$ ,  $r < n$ . **Kombinacija  $r$ -tog razreda** u skupu  $A$  jest svaki  $r$ -člani podskup od  $A$ .

$$C_n^{(r)} = \binom{n}{r} = \frac{n!}{(n-r)! \cdot r!} = \frac{n(n-1) \dots (n-r+1)}{r!}$$

Neka je  $A$   $n$ -člani skup i  $r \in \mathbf{N}$ . **Kombinacija s ponavljanjem  $r$ -tog razreda** u skupu  $A$  je svaka **neuređena**  $r$ -torka  $(a_1, a_2, \dots, a_r)$  elemenata iz skupa  $A$  (u njoj elementi mogu biti međusobno jednaki)

$$\bar{C}_n^{(r)} = \binom{n+r-1}{r}$$

**Uvjetna vjerojatnost:**  $P(A|B) = \frac{P(A \cap B)}{P(B)}$

**Formula potpune (totalne) vjerojatnosti:**

$$P(A) = P(A \cap \Omega) = P(\cup_{i=1}^n A \cap H_i) = \sum_{i=1}^n P(A \cap H_i) = \sum_{i=1}^n P(H_i)P(A|H_i).$$

**Bayesova formula (aposteriorne vjerojatnosti hipoteza):**

$$P(H_i|A) = \frac{P(A \cap H_i)}{P(A)} = \frac{P(H_i)P(A|H_i)}{\sum_{i=1}^n P(H_i)P(A|H_i)}.$$

## Osnovni pojmovi vezani uz slučajnu varijablu

**Funkcija distribucije:**  $F_X(x) = P(X \leq x)$

**Funkcija gustoće vjerojatnosti:**  $p_X(a_i) := P(X = a_i) = p_i$

**Matematičko očekivanje:**  $E[X] = \sum_{a_i \in \text{Im}X} a_i \cdot p_X(a_i)$

**Varijanca:**  $\text{Var}[X] := \sum_{a_i \in \text{Im}X} (a_i - EX)^2 \cdot p_X(a_i) = E[X^2] - (EX)^2$ .

Vrijedi:  $\text{Var}[aX + b] = a^2 \text{Var}X$

**Standardna devijacija:**  $\sigma_X := +\sqrt{\text{Var}[X]}$

**Čebiševljeva nejednakost:**  $P(|X - \mu| \geq \varepsilon) \leq \frac{1}{\varepsilon^2} \text{Var}[X]$

## Binomna slučajna varijabla

$$\text{Im}X = \{0, 1, 2, \dots, n\},$$

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

Oznaka:  $X \sim B(n, p)$ .

$$E[X] = np, \quad \text{Var}[X] = npq.$$

**Slabi zakon velikih brojeva:**  $P\left(\left|\frac{Y_n}{n} - p\right| < \varepsilon\right) \geq 1 - \frac{1}{4n\varepsilon^2}$