

Leíró statisztika (Štatistika)

A matematikai statisztika véletlen kísérletekkel; adatok gyűjtésével – beszerzésével foglalkozik; majd ezekből statisztikai állományok készít. Végül következtetéseket von le ezekből. Ezért a statisztikai tevékenységet néhány résztevékenységre oszthatjuk:

- a statisztikai mintavétel előkészítése
- mintavétel – adatok beszerzése
- a statisztikai minta feldolgozása
- kiértékelés
- az eredmények alkalmazása

statisztikai sokaság (štatistický súbor) – egy véges M halmaz, mely olyan statisztikai egységeket tartalmaz, amik bizonyos tulajdonságaikban megegyeznek, másokban pedig különböznek

pl. a WO Építőipari Szakközépiskola 1.A osztálya a 2019/2020 tanévben 2020.5.1. dátummal
→ felsoroltuk a közös tulajdonságokat, és ezzel egyértelműen meghatároztuk a statisztikai sokaságot

statisztikai egység (štatistická jednotka) – a statisztikai sokaság egy eleme, mely a statisztikai megfigyelés tárgyát képezi

pl. az adott osztály diákjai

statisztikai minta (základný štatistický súbor) – azon statisztikai egységek összessége, melyek a mintavételnél számításba jöhetnek

a statisztikai megfigyelés lehet:

teljes megfigyelés (úplné zisťovanie) – a minta összes egységét vizsgálja (munkaigényes, drága, esetleg megvalósíthatatlan)

kiválasztásos megfigyelés (výberové zisťovanie) – a mintának egy leszűkített egységeit vizsgálja (véletlenszerű választással)

a statisztikai sokaság nagysága (rozsah štatistického súboru) – a statisztikai egységek száma a statisztikai sokaságban: n

pl. $n = 24$ (az 1.A-nak akkor 24 diákja volt)

statisztikai ismerv/változó (štatistický znak) – azon tulajdonság, mely a vizsgáldás tárgyát képezi: x, y, z

pl. magasság, tömeg, a szem színe

a, **minőségi ismerv** (kvalitatívny štatistický znak) – nem lehet számmal kifejezni (mérni): nem, a szem színe

b, **menyiségi ismerv** (kvantitatívny štatistický znak) – számértéket vesz fel: magasság, tömeg

a statisztikai ismerv értéke (hodnota štatistického znaku) – az x ismerv statisztikai egységének az értéke: $x_1; x_2; x_3; \dots; x_n$

pl. x – nem: $x_1 = \text{lány}; x_2 = \text{fiú}; x_3 = \text{fiú}; \dots; x_{24} = \text{lány}$

abszolút gyakoriság (absolútna početnosť) – az a szám, ahányszor előfordul a statisztikai sokaságban az x_i érték: n_i

$n_1; n_2; n_3; \dots; n_r$

érvényes: $r \leq n$;

$$n_1 + n_2 + n_3 + \dots + n_r = n$$

pl. $n_1 = 6; n_2 = 18$

relatív gyakoriság (relatívna početnosť) – az abszolút gyakoriság elosztva a statisztikai sokaság nagyságával: $\frac{n_i}{n}$

Helyzetparaméterek/elhelyezkedési mutatók (charakteristiky úrovne/polohy)

A helyzetparaméterek megadják az ismerv „középső” értékét, mellyel az egész statisztikai sokaságot jellemezhetjük. Ide tartoznak a különböző átlagok, a módusz és a medián. Ezen jellemzők értéke mindig az ismerv legkisebb és legnagyobb értéke közé esik.

1, **a számtani közép** (aritmetický priemer) – a számok összegét elosztjuk a darabszámmal

$$\bar{x}_A = \frac{a_1 + a_2 + a_3 + \dots + a_n}{n} = \frac{1}{n} \sum_{i=1}^n a_i$$

2, **a mértani közép** (geometrický priemer) – a számok szorzatából annyiadik gyököt vonunk, amennyi a tényező

$$\bar{x}_G = \sqrt[n]{a_1 \cdot a_2 \cdot a_3 \cdot \dots \cdot a_n} = \sqrt[n]{\prod_{i=1}^n a_i}$$

3, **a harmonikus közép** (harmonický priemer) – a darabszámot elosztjuk a számok reciprokanak összegével

$$\bar{x}_H = \frac{n}{\frac{1}{a_1} + \frac{1}{a_2} + \frac{1}{a_3} + \dots + \frac{1}{a_n}} = \frac{n}{\sum_{i=1}^n \frac{1}{a_i}}$$

4, **a négyzetes/kvadratikus közép** (kvadratický priemer) – a számok négyzetéből számtani közepet számolunk, majd ebből gyököt vonunk

$$\bar{x}_Q = \sqrt{\frac{a_1^2 + a_2^2 + a_3^2 + \dots + a_n^2}{n}} = \sqrt{\frac{1}{n} \sum_{i=1}^n a_i^2}$$

5, **a módusz** (modus/modálna hodnota) – az ismerv leggyakoribb értéke, ha létezik (amennyiben két, vagy több értéknek is azonos az abszolút gyakorisága, akkor nem létezik): \hat{x}

6, **a medián/helyzeti középérték** (medián/stredná hodnota) – az ismerv sorba rendezett értékeiből a középső (páratlan számú statisztikai egység esetén ez egy konkrét érték; ha pedig páros számú, akkor a két középső érték számtani közepét jelenti): \tilde{x}

T. $\bar{x}_H \leq \bar{x}_G \leq \bar{x}_A \leq \bar{x}_Q$

M. Egyenlőség a középértékek között csak akkor áll fenn, ha minden érték (szám) azonos.

példa:

Egy statisztikai ismerv (osztályzatok matematikából) az alábbi értékekkel rendelkezik: 1; 3; 2; 2; 1; 4; 3; 2

$$\bar{x}_A = \frac{1+3+2+2+1+4+3+2}{8} = \frac{18}{8} = 2,25$$

$$\bar{x}_G = \sqrt[8]{1 \cdot 3 \cdot 2 \cdot 2 \cdot 1 \cdot 4 \cdot 3 \cdot 2} = \sqrt[8]{288} = 2,03$$

$$\bar{x}_H = \frac{8}{\frac{1}{1} + \frac{1}{3} + \frac{1}{2} + \frac{1}{2} + \frac{1}{1} + \frac{1}{4} + \frac{1}{3} + \frac{1}{2}} = \frac{8}{\frac{53}{12}} = \frac{96}{53} = 1,81$$

$$\bar{x}_Q = \sqrt{\frac{1^2+3^2+2^2+2^2+1^2+4^2+3^2+2^2}{8}} = \sqrt{\frac{1+9+4+4+1+16+9+4}{8}} = \sqrt{\frac{49}{8}} = 2,47$$

x_i	n_i
1	2
2	3
3	2
4	1

$$\hat{x} = 2$$

nagyság szerint rendezzük: 1; 1; 2; 2; 2; 3; 3; 4

két középső van → az ő számtani közepét számoljuk

$$\tilde{x} = \frac{2+2}{2} = 2$$

Szóródási mutatók (charakteristiky variability/premenlivosti)

A helyzetparaméterek a statisztikai sokaságok legegyszerűbb összehasonlítására szolgálnak. Természetesen, ha csak ezen szempontból vizsgálnánk az egyes ismérveket, akkor az alábbi két ismérvet akár hasonlóknak is mondhatnánk (a számtani közepet számoljuk):

x_i	y_i
98	40
99	70
100	110
101	130
102	150
$\bar{x} = 100$	$\bar{y} = 100$

Bárki láthatja, hogy ez a két ismérv teljesen különbözik egymástól, nem hasonlítanak egymásra. Ezért valamilyen módon (számokkal) szeretnénk kifejezni, hogy milyen „változatosak” az ismérv értékei. Pontosan ezt fejezik ki a szóródás mérőszámai.

7. **a szórás terjedelme/mintaterjedelem** (variačné rozpätie) – az ismérv legnagyobb és legkisebb értéke közötti különbség

8. **(tapasztalati) szórásnégyzet/variancia** (rozptyl/variancia) – az ismérv átlagos négyzetes eltérése a számtani középtől

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

9. **korrigált (tapasztalati) szórásnégyzet** (výberový rozptyl)

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

10. **(tapasztalati) szórás** (smerodajná/štandardná odchýlka) – a szórásnégyzet négyzetgyöke

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

$$\sigma_x = \sqrt{\sigma_x^2}$$

11. **korrigált (tapasztalati) szórás** (výberová smerodajná odchýlka)

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

$$s_x = \sqrt{s_x^2}$$

12. **relatív szórás/szórási együttható** (variačný koeficient) – a variabilitás relatív mértéke

$$V_x = \frac{\sigma_x}{\bar{x}}$$

13. **átlagos abszolút eltérés** (priemerná odchýlka) – az ismérv átlagos távolsága a számtani középtől

$$\bar{d}_x = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}|$$

példa:

Határozzuk meg az x és a y ismérvek szóródási mutatóit

x_i	$x_i - \bar{x}$	$ x_i - \bar{x} $	$(x_i - \bar{x})^2$	
98	-2	2	4	
99	-1	1	1	
100	0	0	0	
101	1	1	1	
102	2	2	4	
500	0	6	10	összeg
100	0	1,2	2	átlag

$$R_x = x_{\max} - x_{\min} = 102 - 98 = 4$$

$$\sigma_x^2 = \frac{10}{5} = 2$$

$$s_x^2 = \frac{10}{4} = 2,5$$

$$\sigma_x = \sqrt{2} = 1,414\ 2$$

$$s_x = \sqrt{2,5} = 1,581\ 1$$

$$V_x = \frac{\sqrt{2}}{100} = 0,014\ 1$$

$$\bar{d}_x = \frac{6}{5} = 1,2$$

y_i	$y_i - \bar{y}$	$ y_i - \bar{y} $	$(y_i - \bar{y})^2$	
40	-60	60	3 600	
70	-30	30	900	
110	10	10	100	
130	30	30	900	
150	50	50	2 500	
500	0	180	8 000	összeg
100	0	36	1 600	átlag

$$R_y = y_{\max} - y_{\min} = 150 - 40 = 110$$

$$\sigma_y^2 = \frac{8\ 000}{5} = 1\ 600$$

$$s_y^2 = \frac{8\ 000}{4} = 2\ 000$$

$$\sigma_y = \sqrt{1\ 600} = 40$$

$$s_y = \sqrt{2\ 000} = 44,721\ 4$$

$$V_y = \frac{40}{100} = 0,4$$

$$\bar{d}_y = \frac{180}{5} = 36$$

Láthatjuk, hogy ezekben a számokban már jelentős eltérések tapasztalhatók. Bár a számtani közepek megegyeznek, ezek a mérőszámok már mutatják, hogy az y ismérv értékei között nagy, nagyságrendekkel nagyobb az eltérés.

Az utóbbi időben ezeket a jellemzőket papíron már senki nem számolja. Azért is, mert a statisztikai sokaság, ami feldolgozásra kerül, hatalmas. Azok a cégek, akik statisztikai tevékenységgel foglalkoznak, nem engedhetik meg maguknak, hogy az egész folyamat hetekig tartson – főleg, ha a konkurencia egyéb segédeszközöket használ (speciális szoftvert a számítógépen).

Segítségünkre lehet a számológép, de már azt sem igazán használják. Egyrészt kevés statisztikai mutatót lehet velük számolni, másrészt nem ellenőrizhető a bevitt adatok helyessége – ha megtévedünk, és nem vesszük ezt észre, később már nem tudjuk kijavítani. De a kisebb számításokhoz elegendő a számológép is.

A tudományos számológépekben régóta megtalálható a statisztika üzemmód.



Az első lépés: átkapcsolni statisztikai számítások üzemmódjába – ez általában automatikusan törli a statisztikához használt memóriákat. Ha nem, akkor keressétek a **SAC** / **SC** függvényt (valószínűleg másodlagos funkció). Némelyik számológépen a statisztikai számítások üzemmódban még a sokaság típusát is meg kell választani.

a, első típus: a **MODE** megnyomása (akár többször is – ekkor a kijelzőn megjelenik az SD és a hozzá tartozó szám) / a számológépen feltüntetett szám vagy billentyű, amit utána kell megnyomni **STAT** / **SD** [**MODE** → **3**: **STAT** / **MODE** → **.**]

b, második típus: a **2nd F** billentyű és a **STAT** / **SD** [a billentyűzet másodlagos funkciója: **2ndF** → **↓** / **2ndF** → **On/C**]

M. Vigyázzunk! Ha kilépünk a statisztikai számítások üzemmódjából, elvesznek a bevitt adataink (általában).

A második lépés: az adatok bevitele:

a, első típus: az adatokat oszlopba visszük be, és minden adat után az **=** billentyűvel lépünk a következő sorba; végül az **AC** billentyűvel fejezzük be az adatbevítelt (láthatjuk az összes bevitt adatot az oszlopban – nyilakkal fel-le haladva)

b, második típus: az adat bevitele után megnyomjuk a **DATA** / **DT** billentyűt [az **M+** az elsődleges funkció]

M. Ha hibázunk, és rossz adatot viszünk be, azonnal kijavíthatjuk, esetleg később is, csak tudnunk kell, hogy mit javítsunk mire:

a, első típus: a nyilak segítségével rámegyünk a rosszul bevitt számra, beírjuk a jó adatot, majd megnyomjuk az **=**-t – ezzel átírja a számot

b, második típus: beírjuk a rosszul megadott számot, majd megnyomjuk a **DEL** / **CD** [**SHIFT** → **M+** / **2ndF** → **M+**] függvényt – ezzel töröljük őt; ezek után a fenti módon bevisszük a jó számot (2. lépés)

A harmadik lépés: a statisztikai mutatók előhívása:

számtani közép

a, **SHIFT** → **1**: **STAT** → **4**: **Var** → **2**: \bar{x} → **=**

b, **SHIFT** → **7**: \bar{x}

c, **x** → **M**: \bar{x}

szórás

a, **SHIFT** → **1**: **STAT** → **4**: **Var** → **3**: σ_X → **=**

b, **SHIFT** → **8**: σ_n

c, **2ndF** → **RM**: σ

korrigált szórás

a, **SHIFT** → **1**: **STAT** → **4**: **Var** → **4**: s_X → **=**

b, **SHIFT** → **9**: σ_{n-1}

c, **RM**: s

Még megtalálható néhány segédérték, amikből számolja a számológép ezen mutatókat: Σx ; Σx^2 ; n .

Ennél jobb eszközt kínál a számítógép az egyszerű statisztikai elemzéshez. Konkrétan az **Excel**.

Egy statisztikai ismérv értékeit például elrendezhetjük a táblázat egy oszlopába. Vagyis további ismérveket további oszlopokban adhatunk meg.

számtani közép: **AVERAGE**

mértani közép: **GEOMEAN**

harmonikus közép: **HARMEAN**

módusz: **MODE**

medián: **MEDIAN**

szórásnégyzet: **VAR.P** (**VARP** – régebbi verzió)

korrigált szórásnégyzet: **VAR.S** (**VAR** – régebbi verzió)

szórás: **STDEV.P** (**STDEVP** – régebbi verzió)

korrigált szórás: **STDEV.S** (**STDEV** – régebbi verzió)

átlagos abszolút eltérés: **AVEDEV**

Használhatunk más, ingyenes applikációt is, például **Libre Office** – pontosan ugyanazok a parancsok.

számtani közép: **AVERAGE**

mértani közép: **GEOMEAN**

harmonikus közép: **HARMEAN**

módusz: **MODE**

medián: **MEDIAN**

szórásnégyzet: **VAR.P**

korrigált szórásnégyzet: **VAR.S**

szórás: **STDEV.P**

korrigált szórás: **STDEV.S**

átlagos abszolút eltérés: **AVEDEV**