

Matematika B4

I. gyakorlat

2006. február 16.

1. Egy-dimenziós adatrendszerek

Van valamilyen adatrendszer (számsorozat), amelyről szeretnénk kiszámolni bizonyos dolgokat. Az egyes értékeket jelöljük z_i -vel, a számukat pedig n -nel. Nézzünk egy konkrét példát: 1, 3, 2, 1, 4. A valószínűségszámításban és statisztikában legfontosabb mennyiségek a következők:

1. Átlag:

Az adatok átlaga: $\bar{z} = \frac{1}{n} \sum_{i=1}^n z_i$.

A példánkban: $\bar{z} = \frac{1}{5}(1 + 3 + 2 + 1 + 4) = 2.2$

2. Átlagos abszolút eltérés az átlagtól:

$\frac{1}{n} \sum_{i=1}^n |z_i - \bar{z}|$

A példánkban: $\frac{1}{5}(|1 - 2.2| + |3 - 2.2| + |2 - 2.2| + |1 - 2.2| + |4 - 2.2|) = 1.04$

3. Momentumok:

Az adatrendszer k -adik momentuma: $\frac{1}{n} \sum_{i=1}^n z_i^k$. Minden adatrendszerre a nulladik momentum 1, az első momentum pedig megegyezik az átlaggal.

A fenti példában a második momentum 6.2, a harmadik momentum 20.2.

4. Valamely c pontra vonatkozó momentumok

$\frac{1}{n} \sum_{i=1}^n (z_i - c)^k$

5. Szórásnégyzet:

Az adatok átlagos négyzetes eltérése az átlagtól. $\sigma^2 = \frac{1}{n} \sum (z_i - \bar{z})^2 = (\frac{1}{n} \sum_{i=1}^n z_i^2) - \bar{z}^2$.

A szórásnégyzet nem más, mint az átlagra vonatkozó második momentum.

A példánkban: $\sigma^2 = \frac{1}{5}(1^2 + 3^2 + 2^2 + 1^2 + 4^2) - 2.2^2 = 1.36$

6. Szórás:

A szórásnégyzet gyöke. $\sigma = \sqrt{\sigma^2}$.

Esetünkben $\sigma = \sqrt{1.36} = 1.17$

7. Medián:

Rendezzük nagyság szerint sorba az adatokat. Ha n páratlan, akkor a medián a középső elem, ha páros, akkor a két középső elem átlaga. A mediántól nagyobb és kisebb elemből is ugyanannyi van.

A fenti példában a medián a 2.

8. Relatív gyakoriság:

a) Egy elem relatív gyakoriságát úgy kapjuk meg, hogy előfordulási számát elosztjuk az adatrendszer összes elemeinek számával.


Esetünkben az 1 relatív gyakorisága $\frac{2}{5}$, a 2, 3, 4 relatív gyakorisága $\frac{1}{5}$.

b) Szokás az X -tengelyt intervallumokra is felosztani, ilyenkor egy intervallum relatív gyakoriságát úgy kapjuk meg, hogy az intervallumba eső adatok számát osztjuk az összes adat számával.

Például a $[0, 0.25]$ intervallum relatív gyakorisága $\frac{3}{5}$, a $(2.5, 5]$ relatív gyakorisága $\frac{2}{5}$.

9. Szemléltetés pálcikákkal

A relatív gyakoriságok grafikonja, ahol az X -tengelyen ábrázoljuk az előforduló értékeket, az Y -tengelyen pedig a hozzájuk tartozó relatív gyakoriságának megfelelő hosszúságú pálcikát.



1. ábra.

10. Hisztogram:


Ha az X -tengelyt diszjunkt intervallumokra bontjuk, akkor az intervallumok fölé rajzolhatunk téglalapokat úgy, hogy területük az intervallum relatív gyakoriságával egyezzen meg.

11. Eloszlásfüggvény:

Tetszőleges x érték esetén az $F(x)$ definíciója: $F(x) = \frac{x\text{-nél szigorúan kisebb elemek száma}}{n}$.

Az eloszlásfüggvény grafikonja mindig egy olyan lépcsős függvény, amely vízszintes darabokból és ugrásokból áll. Ugrások ott lesznek, ahol az adatok vannak, az ugrás nagysága az adott relatív gyakorisággal egyenlő.

A fenti példa eloszlásfüggvénye:



2. ábra.

Vegyünk 10 db egész számot 1 és 6 között. Ezek lehetnek kitalált számok, indexbeli jegyek, de használhatunk dobókockát is ezek generálásához. Ezek a számok alkotják az 1. adatrendszert.

A 2. adatrendszer elemei legyenek az 1. adatrendszer elemeinek kétszerese.

A 3. adatrendszer elemeit úgy kapjuk meg, hogy az 1. adatrendszer elemeihez hozzáadunk 10-et.

A 4. adatrendszer elemeit úgy kapjuk meg, hogy az 1. adatrendszer elemeit emeljük négyzetre.

A 5. adatrendszer elemeit úgy kapjuk meg, hogy az 1. adatrendszer elemeinek vesszük a reciprokát. Például:

| | | | | | | | | | | |
|-----------------|-----|----|-----|-----|-----|-----|-----|----|-----|-----|
| 1. adatrendszer | 3 | 1 | 6 | 2 | 3 | 3 | 3 | 1 | 4 | 5 |
| 2. adatrendszer | 6 | 2 | 12 | 4 | 6 | 6 | 6 | 2 | 8 | 10 |
| 3. adatrendszer | 13 | 11 | 16 | 12 | 13 | 13 | 13 | 11 | 14 | 15 |
| 4. adatrendszer | 9 | 1 | 36 | 4 | 9 | 9 | 9 | 1 | 16 | 25 |
| 5. adatrendszer | 1/3 | 1 | 1/6 | 1/2 | 1/3 | 1/3 | 1/3 | 1 | 1/4 | 1/5 |

2. Feladatok

1. Számoljuk ki az így kapott adatsorok átlagát, szórását, második és harmadik momentumát. Mit állapíthatunk meg az átlagról és a szórásról? Hogyan változnak az egyes sorozatok esetén? Igazoljuk az észrevételeket általán-

nos esetre!

Szemléltessük az adatrendszer

- a) "dróton"!
- b) "ablakpárkányon"!


2. A fenti sorozatok relatív gyakoriságait

- a) szemléltessük pálcikákkal
- b) rajzoljuk fel az eloszlásfüggvényeket
- c) rajzoljuk fel a hisztogramjaikat
- d) határozzuk meg a mediánt.

3. Bizonyítsuk be, hogy minden adatrendszerben az átlagtól való átlagos (előjeles) különbség 0.

4. Mit jelent az, hogy ha a szórás 0?

5. Az alábbi két ábrán pálcikákkal ábrázoltuk a relatív gyakoriságot. Számoljuk ki a mediánt és átlagot mindkét esetben!



3. ábra.

6. Készítsünk olyan adatsort, ahol

- a) a medián megegyezik az átlaggal!
- b) a medián nagyobb az átlagtól!
- c) a medián kisebb az átlagtól!

7. Lehet-e nagyobb az átlagos abszolút eltérés a szórástól? És fordítva?

8. 1000 adatot gyűjtünk össze. Az első 600 szám átlaga 9, a maradék 400 átlaga 5. Mennyi a teljes adatrendszer átlaga?

9. Vegyük a következő adatrendszer: 5, 5, 10, 25, 35.

- a) Mi az a szám, amit minden elemhez hozzáadva 20 lesz az átlag?
- b) Mennyivel kell megszorozni a számokat, hogy az új adatrendszer szórása 6 legyen?
- c) Centralizáljuk az adatrendszer, azaz toljuk el az elemeket úgy, hogy az új adatrendszer átlaga 0 legyen.
- d) Standarizáljuk a fenti számsorozatot, azaz miután eltoltuk úgy, hogy 0 legyen az átlag szorozzuk be az elemeket egy számmal, hogy az új adatrendszer szórása 1 legyen.

10. Adottak a következő számok: $x_1 = 3$, $x_2 = 7$, $x_3 = 21$. Keressük meg, hogy mely c -re lesz a $\sum_{i=1}^3 |z_i - c|$ kifejezés minimális! Mi a megoldás általános esetben?

11. Oldjuk meg az elő feladatot abszolút érték helyett négyzettel, azaz mely c érték mellett lesz a $\sum_{i=1}^3 (x_i - c)^2$ minimális? Mi az általános megoldás?

12. Generáljunk 20 db véletlen számot a zsebszámológép segítségével (az RND gomb használatával). Osszuk fel
- 2 egyenlő részre az intervallumot.
 - 4 egyenlő részre az intervallumot.
 - 10 egyenlő részre az intervallumot.


Ábrázoljuk az adatrendszert dróton, ablakpárkányon, számoljuk ki az eloszlásfüggvényét. Ábrázoljuk a relatív gyakoriságokat pálcikákkal és hisztogrammal is.

13. Legyen RND_1 és RND_2 két számológéppel generált szám. A fenti feladatot számoljuk végig úgy is, hogy minden egyes adatot $\frac{RND_1 + RND_2}{2}$ utasítással definiálunk.
14. Egy adatrendszerben csak két féle érték szerepel: 0 és 1. Tudjuk, hogy az átlag 0.3, adjuk meg a relatív gyakoriságokat!

3. Többdimenziós adatrendszerek

Kétdimenziós adatrendszerek esetén külön számolhatunk átlagot és szórást koordinátánként, de felmerül, hogy mi a kapcsolat ezen koordináták között. u_i -vel és v_i -vel jelölöm az adatok koordinátáit, például u_i az i . hallgató HáRe jegye, v_i pedig a B4 jegye.

| | | | | | | |
|------|---|---|---|---|---|---|
| HáRe | 1 | 2 | 2 | 3 | 2 | 1 |
| B4 | 2 | 4 | 5 | 4 | 1 | 2 |



4. ábra.

1. Kovariancia:

$$c = \frac{1}{n} \sum_{i=1}^n (u_i - \bar{u})(v_i - \bar{v})$$

A fenti példában a B4 és HáRe jegyek kovarianciája pozitív, 0.5. Ez intuitíve azt jelenti, hogy a nagyobb jobb HáRe jegyhez "általában" jobb B4 jegy is párosul.

2. Korrelációs együttható:

$$r = \frac{c}{\sigma_U \cdot \sigma_V}$$

Esetünkben a korrelációs együttható: 0.51, mivel a HáRe esetén a szórás 0.69, B4 esetén 1.41.

4. Feladatok

Adott a következő táblázat:

| Név | Hal Otmár | K. Bea | Lepi Pál | Saaanyi |
|--------------|-----------|--------|----------|---------|
| Magasság (U) | 182 | 165 | 171 | 195 |
| Súly (V) | 87 | 62 | 95 | 117 |

15. Számoljuk ki a magasság és súly kovarianciáját és korrelációs együtthatóját.

16. Keressük meg azt a(z)

- a) origón átmenő
- b) konstans
- c) általános

$v = l(u)$ egyenest, amelyre a $\sum_{i=1}^n (v_i - l(u_i))^2$ érték minimális lesz! (Ezek az egyenesek lesznek a négyzetes értelemben vett legjobb becslések U ismeretében V-re, ha figyelembe vesszük a feltételeket.)

17. Oldjuk meg az előző feladatot úgy is, hogy U és V szerepét felcseréljük (azaz olyan, mintha V ismeretében szeretnénk becsülni U-et)!

18. Készítsünk 3 adatból álló adatrendszert, amelyben a korrelációs együttható értéke:

- a) $r = 0$
- b) $r = 1$
- c) $r = -1$
- d) $r = 0.5$
- e) $r = -0.5$
- f) $r = 0.8$
- g) $r = -0.8$

19. Ellenőrizzük az eddigi példákon, hogy $c^2 \leq \sigma_U \sigma_V$ és vele együtt $|r| \leq 1$ egyenlőtlenség mindig teljesül.

Próbáljuk meg belátni, hogy $c^2 \leq \sigma_U \sigma_V$ mindig fennáll.

Ötlet: A tétel Cauchy-Schwarz egyenlőtlenség felhasználásával ($\sum_{i=1}^n (a_i b_i)^2 \leq \sum_{i=1}^n a_i^2 \sum_{i=1}^n b_i^2$) könnyű, a Cauchy-Schwarz pedig egy kis számolás után kijön a $0 \leq \sum (a_i - t \cdot b_i)^2$ kibontásából és diszkriminánsa vizsgálatából.