

## 1. óra

### Leíró statisztika (1)

#### 1. Példa:

Matematika A2 év végi eredmények a hallgatók között.

| jegy | gyakoriság | jel   | jegy*db | rel. gyak     |
|------|------------|-------|---------|---------------|
| 5    | 7          | $v_5$ | 35      | $7/55=0,12$   |
| 4    | 10         | $v_4$ | 40      | $10/55=0,18$  |
| 3    | 23         | $v_3$ | 69      | $23/55=0,44$  |
| 2    | 15         | $v_2$ | 30      | $15/55=0,27$  |
| summ | 55         |       | 174     | $174/55=3,16$ |

A jegyek: **diszkrét változó**, értéke csak 2-3-4-5 lehet, pl. 3.2 nem.

**gyakoriság:** a megfigyelt esemény előfordulásának száma (pl. ötös 7 db.; négyes 10 db.)

**relatív gyakoriság:** gyakoriság/összes események száma (pl. ötös esetén  $7/55$ ; négyes esetén  $10/55$ )

A megfigyelés-sorozat legegyszerűbb jellemzője az **Átlag:**

$\xi_1 ; \xi_2 ; \xi_3 ; \dots ; \xi_{55}$  (megfigyelt jegyek sorozat 55 hallgató esetében)

$$\bar{\xi} = \text{átlag} = \frac{1}{55} \sum_{i=1}^{55} \xi_i$$

Általában:

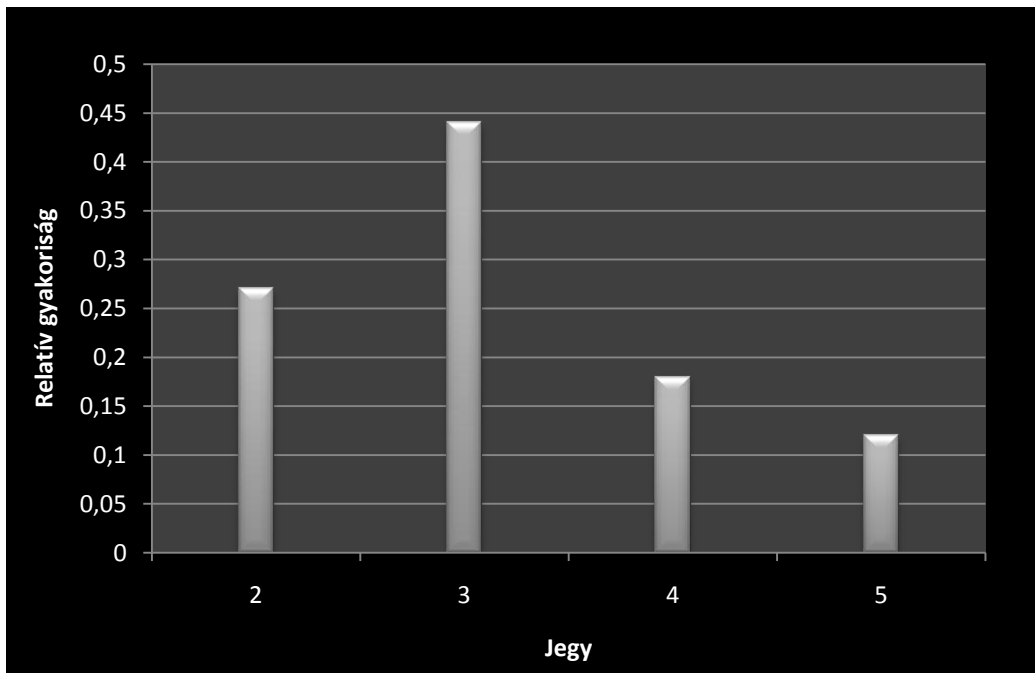
$$\bar{\xi} = \frac{1}{n} \sum_{i=1}^n \xi_i =$$

Egyszerűbb számolni, ha csoportokba foglalom:

$$\bar{\xi} = \frac{1}{n} (v_5 * \xi_5^* + \dots + v_2 * \xi_2^*)$$

$$\bar{\xi} = \frac{1}{n} \sum_{j=2}^5 v_j \xi_j^* = \sum_{j=2}^5 \frac{v_j}{n} \xi_j^* = 3.16$$

A jegyek eloszlását mutatja a **tapasztalati sűrűségfüggvény, v. hisztogram**. A változó értékeihez felmérem a relatív gyakoriságot.



hisztogram (- tapasztalati sűrűségfüggvény) diszkrét változó esetén

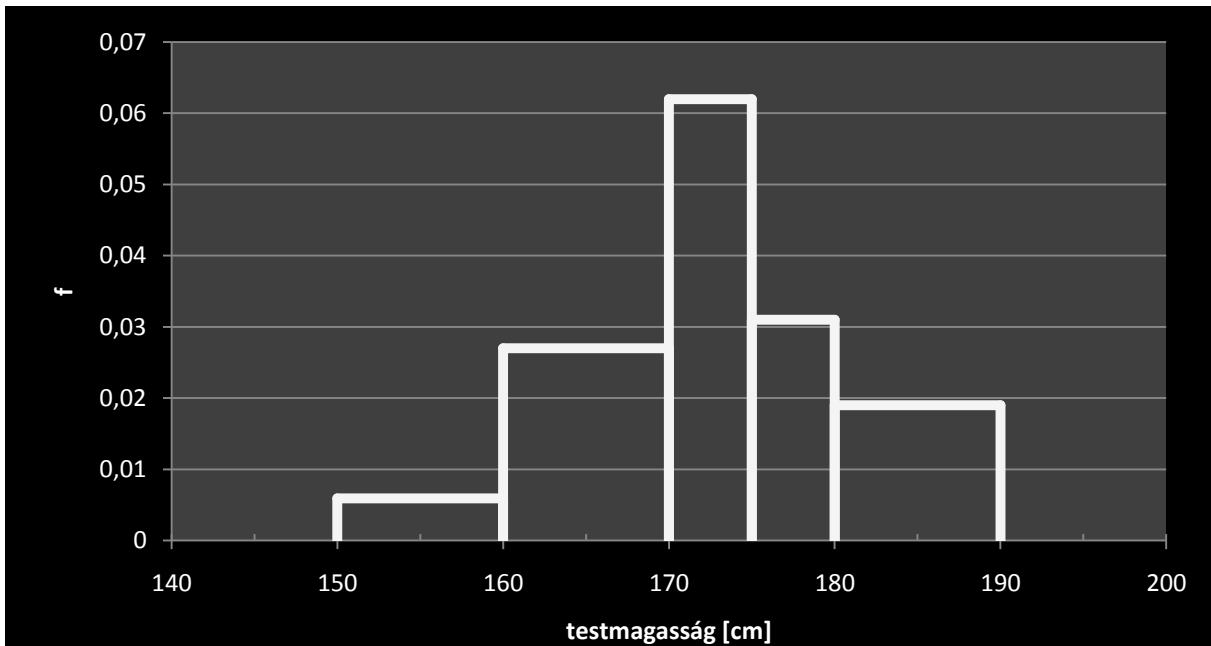
## 2. Példa:

Folytonos változó: pl. a hallgatók magassága

| magasság cm-ben | gyakoriság | relatív gyakoriság | f      |
|-----------------|------------|--------------------|--------|
| 150-160         | 3          | 0,059              | 0,0059 |
| 160-170         | 14         | 0,27               | 0,027  |
| 170-175         | 16         | 0,31               | 0,062  |
| 175-180         | 8          | 0,155              | 0,031  |
| 180-190         | 10         | 0,19               | 0,019  |
| 190-            | 0          | 0                  | 0      |

Intervallumok fölé téglalapokat rajzolunk, amik területe ( $T_j$ ) az intervallumba esés relatív gyakorisága. Ha az intervallum szélessége  $\Delta x_j$ , akkor a téglalap magassága ( $f_j$ ):


$$f_j = \frac{T_j}{\Delta x_j} = \frac{v_j/n}{\Delta x_j}$$



Hisztogram folytonos változó esetén

A felmérés csalóka, mert a fiúk és a lányok nem lettek külön felmérve, pedig az átlag magasságuk eltér.

**Tapasztalati eloszlásfüggvény:** (lépcsős függvény)



$$F(x) = \frac{v_1 + v_2 + \dots + v_n}{n}$$

Kapcsolat a tapasztalati sűrűségfüggvény, és a tapasztalati eloszlásfüggvény között:

$$\frac{v_1}{n} + \frac{v_2}{n} + \dots + \frac{v_n}{n} = \sum f_j \Delta x_j$$

Ha van n db. megfigyelésünk, hogyan választjuk az intervallumok számát és a határait? Gyakorlati tapasztalat, hogy a részintervallumok száma:

$$J = \text{intervallumok száma} \cong \sqrt{n} \text{ (ha } n \leq 100)$$

$$J = 1 + \log_2 n \text{ (ha } n > 100)$$

**median:** megfigyelés sorozat azon eleme, amely alatt ugyanannyi elem van, mint felette. Legyen n a megfigyelések száma,

ha  $n$  páratlan, akkor az  $m$ -edik elem a medián, ahol  $m=(n+1)/2$

ha  $n$  páros, akkor a medián a „két középső” elem átlaga

$$\tilde{\xi} = \frac{1}{2}(\xi_{\frac{n}{2}} + \xi_{\frac{n}{2}+1})$$

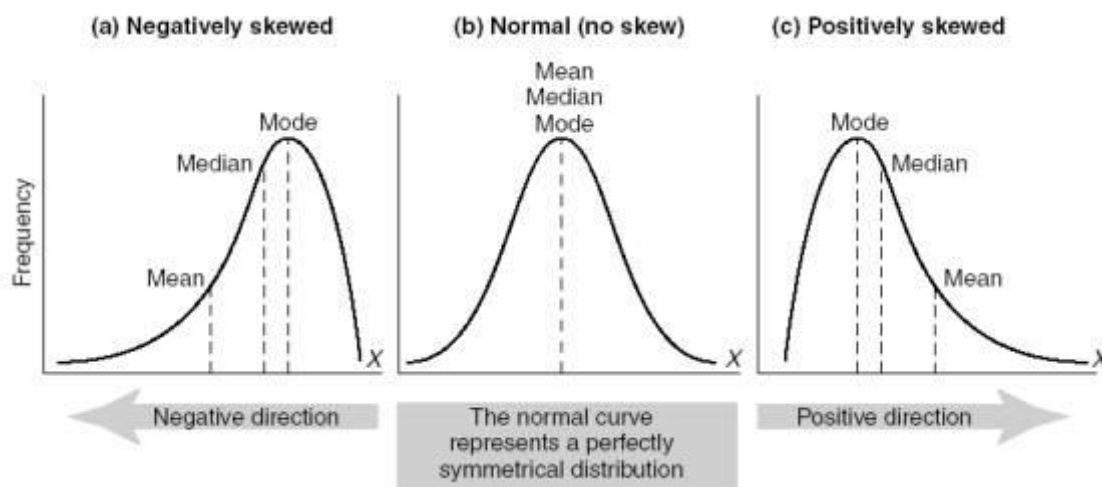
median és átlag kapcsolata:

ha az eloszlás szimmetrikus, akkor  $\tilde{\xi} \cong \bar{\xi}$

ha az eloszlás „ferde”,

ha „jobbra” dől (Negatively skewed), akkor a medián  $>$  átlag


ha „balra” dől (Positively skewed), akkor a medián  $<$  átlag



### Boxplot:

megfigyelési sorozat ábrázolása. Jellemző vonalai:

- **medián** ( $\bar{\xi}$ ), ez két részre vágja a megfigyelési sorozatot.
- Az alsó mintafél mediánja az alsó negyedelő vagy **alsó kvartilis** ( $\tilde{\xi}_{1/4}$ ),
- a felső mintafél mediánja a felső negyedelő vagy **felső kvartilis** ( $\tilde{\xi}_{3/4}$ ).
- Legkisebb mintaelem  $\xi_1^*$
- a legnagyobb mintaelem:  $\xi_4^*$



## Fogalmak:

### Gyakoriság:

Az  $f_i$  gyakoriság (abszolút gyakoriság) azt mutatja, hogy a sokaságnak hány egysége tartozik az  $i$ -edik osztályba.

$n$  - kísérletek száma

$k=f_i$  - bennünket érdeklő események darabszáma

(például  $n=45$  hallgató vizsgázott, és  $k=3$  kapott 5-öst)

### Relatív gyakoriság:

A gyakoriságból  $g_i=f_i/N$  vagy  $k/n$  módon nyerhető relatív gyakoriság nem más, mint az  $f_i$  abszolút gyakoriságból számított hányados. Gyakran %-os formában fejezzük ki.

### Diszkrét változó:

Ezekben az esetekben a változó csak megadott értékeket vehet fel, például az osztályzatok csak 1, 2, 3, 4, vagy 5 értéket vehetnek fel

### Folytonos változó:

A változó egy intervallumon belül bármely értéket felvehet (A diszkrét változóval ellentétben köztes értékek is felvehetőek. Például a magasság, mely, fél értékeket is felvehet. 170-180 centis tartományon belül lehet valaki 173, de 179,5 centis is.)

### Tapasztalati eloszlásfüggvény $F_n(x)$ :

Tetszőleges  $x$  értéket felvéve, megszámláljuk, hogy hány megfigyelt érték kisebb, mint az  $x$ . Ebből relatív gyakoriságot számolunk, és ezt a relatív gyakoriságot mérjük fel  $x$ -hez. Lépcsősfüggvény, amely minden megfigyelési értéknél (legalább)  $1/n$ -et lép felfelé.

### Tapasztalati sűrűségfüggvény (hisztogram) $f_n(x)$ :

Diszkrét változó esetén a változó értékéhez felmérjük az értékhez tartozó relatív gyakoriságot.

Folytonos változó esetén intervallumokra bontjuk azt a tartományt, ahova a megfigyelt értékek esnek. Minden intervallum fölé olyan téglalapot rajzolunk, amelynek területe egyenlő az intervallumba esés relatív gyakoriságával.

### Medián:

A nagysága szerint sorba rendezett értékek közül a középső érték. Vagyis az az érték, amelynél kisebb, illetve nagyobb értékek gyakorisága megegyező.