

# 2. rész

## A statisztika alapfogalmai

### Az információtömörítés módszertana

*Komputerstatisztika* kurzus

Barczy Máttyás és Ispány Márton 2010  
Informatikai Kar  
Debreceni Egyetem



#### Statisztikai elemzés

- statisztikai sokaság
- statisztikai változó
- mérési skálák
- statisztikai módszerek

#### Statisztikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

#### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

#### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

#### Függelék

#### Irodalomjegyzék

#### Összefoglalás

# A 2. rész témái

## 1 Statisztikai elemzés

## 2 Statisztikai minta

## 3 Leíró statisztikák

## 4 Grafikus elemzés

## 5 Függelék



### Statisztikai elemzés

- statisztikai sokaság
- statisztikai változó
- mérési skálák
- statisztikai módszerek

### Statisztikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



# A statisztikai elemzés

A statisztikai elemzéshez ismerni kell:

- az elemzés **tárgyát**, a vizsgálandó objektumokat,
- az elemzés **szempontjait**, mely tulajdonságokat (jellemzőket) vizsgálunk,
- az elemzés **módszerét**, milyen statisztikai eljárást használunk.

## Példa (tárgy és szempont)

- Debrecen város lakosságának testsúlya.
- A magyar népesség IQ-ja.
- Egy bank ügyfeleinek viselkedése.
- Egy mobiltelefon-hálózat kihasználtsága.
- Informatikai eszközök (processzorok, tároló kapacitások) időbeli fejlődése.

### Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

### Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



# Az elemzés tárgya: a statisztikai sokaság

A statisztikai elemzés tárgyával szembeni legfontosabb követelmény, hogy **elég nagy** legyen ahhoz, hogy **statisztikus (véletlenszerű) viselkedést** mutasson.

- Egy teljes körűen megfigyelhető sokaságot tökéletesen jellemezhetünk egyedeinek teljes felsorolásával, pl. egy gyakorlati csoport.
- Nem teljes körűen megfigyelhető sokaságnál, pl. egy város lakossága, bank ügyfelei, ez már nem vagy csak extrém költségek mellett tehető meg.

## Definíció (Statisztikai sokaság)

A statisztikai vizsgálat tárgyát képező objektumok (egyedek, egységek stb.) összességét statisztikai sokaságnak nevezzük. A statisztikai sokaságra használatos még a **populáció** elnevezés is.

### Statisztikai elemzés

#### statisztikai sokaság

statisztikai változó  
mérési skálák  
statisztikai módszerek

#### Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

#### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

#### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

#### Függelék

#### Irodalomjegyzék

#### Összefoglalás



## Statisztikai sokaság típusai:

- véges vagy végtelen,
- diszkrét vagy folytonos,
- valódi vagy fiktív.

## Példa

- Debrecen város lakossága egy véges, diszkrét és valódi sokaság.
- Egy kísérlet sorozatban való megisméltése végtelen, fiktív sokaság.
- A havi csapadék mennyiségek valódi, folytonos sokaság.

### Statisztikai elemzés

#### statisztikai sokaság

statisztikai változó

mérési skálák

statisztikai módszerek

### Statisztikai minta

minta, mintatér, rendezett

minta, a statisztika fogalma

tapasztalati

eloszlásfüggvény

mintavételi módszerek

gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla

Helyzetmutatók

Szóródási mutatók

Alakmutatók

### Grafikus elemzés

Hisztogramok

Decimális grafikon

Boxdiagram

Gauss-papír

QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



# Az elemzés szempontja: statisztikai változó

A vizsgálandó objektumok sokféle tulajdonságát elemezhetjük:

- súly, méret, életkor, szín, sebesség stb.

A vizsgált tulajdonság lehet kvantitatív (mennyiségi) vagy kvalitatív (minőségi), azonban lényeges, hogy **numerikusan kódolható** legyen. Másik fontos szempont, hogy a vizsgált jellemző statisztikus viselkedést mutasson.

## Példa

Emberi populációnál

- statisztikus jellemzők: nem, foglalkozás (egy véges halmazból választva), életkor, IQ;
- nem statisztikus jellemzők: személyi szám (minden ilyen típusú azonosító), lakcím.

### Statisztikai elemzés

statisztikai sokaság

statisztikai változó

mérési skálák

statisztikai módszerek

### Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



## Definíció (Statisztikai változó)

A statisztikai sokaság elemeinek egy tulajdonságát numerikusan jellemző mennyiséget **statisztikai változó**nak nevezzük.

Statisztikai változók osztályozása:

- Értékkészlet alapján: diszkrét illetve folytonos.
- Jellemzés alapján: kvantitatív (mennyiségi) illetve kvalitatív (minőségi).

Jelölések:

- statisztikai sokaságot felsoroljuk:  $\{1, \dots, N\}$  amennyiben véges;  $\mathbb{N} = \{1, 2, \dots\}$  amennyiben végtelen,
- statisztikai változók:  $X, Y, Z, \dots$ ,
- $X(i)$  az  $X$  statisztikai változó értéke az  $i$ -edik objektum esetén.

### Statisztikai elemzés

statisztikai sokaság

statisztikai változó

mérési skálák

statisztikai módszerek

### Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



# Mérési (szintek) skálák (Stevens, 1946)

**Mérés** alatt számoknak eseményekhez, dolgokhoz való hozzárendelését értjük valamilyen szabály alapján.

## Skálatípusok:

- névleges (nominális),
- sorrendi (ordinális),
- különbségi (intervallum),
- arány (hányados, ratio).

Tekintsünk két objektumot,  $A$ -t és  $B$ -t. Legyen  $X$  egy statisztikai változó, értékei az  $A$ , ill.  $B$  objektum esetén  $X(A)$ , ill.  $X(B)$ .

### Statisztikai elemzés

statisztikai sokaság

statisztikai változó

mérési skálák

statisztikai módszerek

### Statisztikai minta

minta, mintatér, rendezett

minta, a statisztika fogalma

tapasztalati

eloszlásfüggvény

mintavételi módszerek

gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla

Helyzetmutatók

Szóródási mutatók

Alakmutatók

### Grafikus elemzés

Hisztogramok

Decimális grafikon

Boxdiagram

Gauss-papír

QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás





**Névleges skála:** kizárólag az egyedekhez rendelt számértékek **egyező** vagy **különböző** voltát engedi meg az egyedeket ténylegesen is jellemző tulajdonságként elfogadni. Vagyis  $A$ -ról és  $B$ -ről csak annyit tudunk mondani, hogy  $X(A) = X(B)$  vagy  $X(A) \neq X(B)$ .

## Példa

Az emberek neme névleges, kvalitatív, diszkrét változó. Pl. férfi = 1, nő = 2 vagy férfi = 101, nő = 102, az értékek között nincs semmiféle kapcsolat, csak az számít, hogy különbözőek.

## Statistikai elemzés

statistikai sokaság

statistikai változó

mérési skálák

statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett

minta, a statistika fogalma

tapasztalati

eloszlásfüggvény

mintavételi módszerek

gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla

Helyzetmutatók

Szóródási mutatók

Alakmutatók

## Grafikus elemzés

Hisztogramok

Decimális grafikon

Boxdiagram

Gauss-papír

QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



**Sorrendi skála:** Nemcsak a skálaértékek azonos vagy nem azonos volta, hanem azok **sorrendisége** is értelmezhető a vizsgált egyedekre. Ebben az esetben azon kívül, hogy  $X(A) = X(B)$  vagy  $X(A) \neq X(B)$ , azt is tudjuk mondani, hogy  $X(A) > X(B)$  vagy  $X(A) < X(B)$ .

A skálaértékek bármilyen, az egyedek adott sorrendjét megtartó számértékek lehetnek, hiszen maguk a számértékek nem hordoznak információt, csak azok sorrendje.

## Példa

Az emberek iskolai végzettsége sorrendi kvalitatív, diszkrét változó.

### Statistikai elemzés

statistikai sokaság  
statistikai változó

#### mérési skálák

statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



**Különbségi skála:** a skálaértékek **különbségei** is valós információt nyújtanak a sokaság egyedeiről (egymáshoz való viszonyukról). A korábbiakon túl azt is mondhatjuk, hogy  $A$  a  $B$ -től  $X(A) - X(B)$  egységgel különbözik.

Az előző két skálával ellentétben e skálának általában már valamilyen mértékegység is szerves tartozéka. A skála kezdőpontjának – a 0 pontnak – a megválasztása önkényes, valamilyen konvención alapszik.

## Példa

A hőmérséklet különbségi, kvantitatív, folytonos változó (Fahrenheit ( $f$ )–, Celsius ( $c$ )–skála:  $f = 9c/5 + 32$ ).

## Statistikai elemzés

statistikai sokaság

statistikai változó

mérési skálák

statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett

minta, a statisztika fogalma

tapasztalati

eloszlásfüggvény

mintavételi módszerek

gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla

Helyzetmutatók

Szóródási mutatók

Alakmutatók

## Grafikus elemzés

Hisztogramok

Decimális grafikon

Boxdiagram

Gauss-papír

QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



**Arány skála:** a kezdőpont is egyértelműen adott, rögzített, a skálaértékek egymáshoz viszonyított **aránya** is hordoz információt. Ha  $X(A) > X(B)$ , akkor a korábbiakon túl azt is mondhatjuk, hogy  $A$   $X(A)/X(B)$ -szer nagyobb, mint  $B$ .

## Példa

A testsúly arány skálán mért kvantitatív, folytonos változó. A Kelvin-féle hőmérsékleti skálán (melynek 0 pontja az abszolút zérus hőmérséklet) mért hőmérséklet kvantitatív, folytonos változó.

Ez az **osztályozás hierarchikus felépítésű**, azaz minden skála rendelkezik az őt megelőző skála tulajdonságaival.

### Statistikai elemzés

statistikai sokaság

statistikai változó

mérési skálák

statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett

minta, a statisztika fogalma

tapasztalati

eloszlásfüggvény

mintavételi módszerek

gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla

Helyzetmutatók

Szóródási mutatók

Alakmutatók

### Grafikus elemzés

Hisztogramok

Decimális grafikon

Boxdiagram

Gauss-papír

QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



## Megjegyzés

Ha  $c_1$  és  $c_2$  Celsius-skálán mért hőmérsékletek,  $f_1$ , illetve  $f_2$  a nekik megfelelő Fahrenheit-skálán mért hőmérsékletek, akkor

$$c_2 - c_1 = \frac{5}{9}f_2 - 32 - \left( \frac{5}{9}f_1 - 32 \right) = \frac{5}{9}(f_2 - f_1),$$

$$\frac{c_2}{c_1} = \frac{\frac{5}{9}f_2 - 32}{\frac{5}{9}f_1 - 32}.$$

Így ha  $c_2 - c_1$  ismert, akkor  $f_2 - f_1$  egyértelműen meghatározott, míg ha  $c_2/c_1$  ismert, akkor  $f_2/f_1$  még nem egyértelműen meghatározott.

### Statisztikai elemzés

statisztikai sokaság

statisztikai változó

mérési skálák

statisztikai módszerek

### Statisztikai minta

minta, mintatér, rendezett

minta, a statisztika fogalma

tapasztalati

eloszlásfüggvény

mintavételi módszerek

gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla

Helyzetmutatók

Szóródási mutatók

Alakmutatók

### Grafikus elemzés

Hisztogramok

Decimális grafikon

Boxdiagram

Gauss-papír

QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



Ha pl.  $c_1 = 10^\circ\text{C}$  és  $c_2 = 30^\circ\text{C}$ , akkor  $f_1 = 50^\circ\text{F}$ ,  
 $f_2 = 86^\circ\text{F}$ ,  $c_2 - c_1 = 20^\circ\text{C}$ ,  $f_2 - f_1 = 36^\circ\text{F}$ ,  $c_2/c_1 = 3$  és  
 $f_2/f_1 = 1.72$ . Azt nem mondhatjuk, hogy a  $30^\circ\text{C}$ -os  
 hőmérséklet háromszor olyan magas, mint a  $10^\circ\text{C}$ -os  
 hőmérséklet, mivel a Fahrenheit–skálán ugyanennek a  
 két hőmérsékletnek az aránya 1.72.

Azt viszont mondhatjuk, hogy a  $30^\circ\text{C}$  távolsága a  
 $0^\circ\text{C}$ -tól háromszor akkora, mint a  $10^\circ\text{C}$ -é a  $0^\circ\text{C}$ -tól.  
 Ez igaz Fahrenheit–skálán is, ugyanis  
 $86^\circ\text{F} - 32^\circ\text{F} = 3(50^\circ\text{F} - 32^\circ\text{F})$ .

A Kelvin-féle hőmérsékleti skálán mondhatjuk azt, hogy a  
 $30^\circ\text{K}$  háromszor akkora, mint a  $10^\circ\text{K}$ .

## Statistikai elemzés

statistikai sokaság

statistikai változó

mérési skálák

statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett

minta, a statisztika fogalma

tapasztalati

eloszlásfüggvény

mintavételi módszerek

gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla

Helyzetmutatók

Szóródási mutatók

Alakmutatók

## Grafikus elemzés

Hisztogramok

Decimális grafikon

Boxdiagram

Gauss-papír

QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák

### statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# A statisztika módszerei

## Alapvető módszerek:

- **Mintavétel:** hogyan juthatunk a vizsgált statisztikai sokaságot jellemző mintához.
- **Becslések:** ismeretlen paraméterek, függvények meghatározása.
- **Hipotézisek:** döntés a minta eloszlására vonatkozó állításokról.

## Feladattípusok:

- Egy változó vizsgálata.
- Két változó összehasonlítása, kapcsolatuk vizsgálata.
- Többdimenziós adatállományok elemzése.

## A statisztika fejezetei:

- Paraméterbecslés,
- Statisztikai próbák (szórásanalízis),
- Regresszió és korreláció analízis,
- Minőségbiztosítás.



## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# A statisztikai minta (első definíció)

Mivel a statisztikai sokaságot teljes körűen nem tudjuk megfigyelni, ezért annak egy részét vesszük abban a reményben, hogy annak megfigyeléséből vissza tudunk következtetni a teljes sokaságra.

## Definíció (Megfigyelt minta)

Sokasági minta alatt a statisztikai sokaság egy  $n$  elemű részhalmazát értjük, ahol véges sokaság esetén  $1 \leq n \leq N$ , végtelen sokaság esetén pedig  $n \in \mathbb{N}$ . Az  $X$  statisztikai változóra vett  **$n$  elemű minta** (megfigyelt minta) alatt a sokasági minta elemeinek az  $X$  változó szerinti értékeit értjük.

A megfigyelt minta  **$n$  darab valós szám (vagy vektor)!**

Jelölések:

- sokasági minta:  $\{i_1, i_2, \dots, i_n\} \subset \{1, 2, \dots, N\}$ .  
(Pl. Debrecen lakosai közül 200 ember.)
- megfigyelt minta:  $x_1 = X(i_1), \dots, x_n = X(i_n)$ , röviden  $x_1, x_2, \dots, x_n$ . (Pl. a kiválasztott 200 ember súlya.)





## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma

tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# Mintatér és rendezett minta

Az összes lehetséges  $n$  elemű minta az  $n$ -dimenziós euklideszi tér  $(\mathbb{R}^n)$  egy  $\mathbb{X}^n$  részalmazát alkotja, amelyet **mintatérnek** nevezünk.

## Példa (Különböző mintaterek)

- $\{0, 1\}^n$ : a vizsgált emberek neme,
- $\mathbb{N}^n$ : a gyerekek száma a családban, ahol  $\mathbb{N}$  a nemnegatív egész számok halmazát jelöli,
- $(0, \infty)^n$ : a vizsgált emberek testsúlya,
- $\mathbb{R}^n$ : napi átlaghőmérséklet.

## Definíció (Rendezett minta)

Az  $x_1, \dots, x_n$   $n$  elemű minta  $x_1^* \leq \dots \leq x_n^*$  nagyság szerint növekvő sorrendbe rendezését rendezett mintának nevezzük.



## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# A statisztika fogalma

Statisztika alatt a minta **tömörítését** értjük, célunk az, hogy a mintában lévő információ minél nagyobb részét magyarázzuk a mintanagysághoz képest kevés számú mutatószámmal.

## Definíció (Statisztika)

Legyen  $T : \mathbb{X}^n \rightarrow \mathbb{R}^k$  egy függvény. Ekkor a  $T(x_1, \dots, x_n)$  vektort az  $x_1, \dots, x_n$  minta egy statisztikájának nevezzük. Magára a  $T$  leképezésre szintén használjuk a statisztika elnevezést.

A definícióban  $T$ -ről szinte semmit nem követeltünk meg, szintén nem követeltük meg, de a gyakorlatban  $k$  jóval kisebb, mint  $n$ .

## Példa (Egyszerű statisztikák)

- $\bar{x} := \frac{1}{n} \sum_{i=1}^n x_i$  mintaátlag,
- $(\min, \max) := (x_1^*, x_n^*)$  a legkisebb és a legnagyobb mintaelem.

# A tapasztalati eloszlásfüggvény (első definíció)

A mintából kinyerhető összes információt tartalmazza.

## Definíció (Tapasztalati eloszlásfüggvény)

Az  $x_1, \dots, x_n$   $n$  elemű minta  $F_n^* : \mathbb{R} \rightarrow [0, 1]$  tapasztalati eloszlásfüggvénye:

$$F_n^*(x) := \begin{cases} 0 & \text{ha } x \leq x_1^*, \\ k/n & \text{ha } x_k^* < x \leq x_{k+1}^*, \quad 1 \leq k < n, \\ 1 & \text{ha } x > x_n^*. \end{cases}$$

Ha valamilyen  $k$ -ra  $x_k^* = x_{k+1}^*$ , akkor  $(x_k^*, x_{k+1}^*) = \emptyset$ .  
Ilyenkor  $F_n^*$  az  $x_k^*$  pontban (legalább)  $2/n$ -et ugrik.



### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma

### tapasztalati eloszlásfüggvény

- mintavételi módszerek
- gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



A tapasztalati eloszlásfüggvény egy másik előállítás:

$$F_n^*(x) = \frac{1}{n} \sum_{k=1}^n I(x_k < x), \quad x \in \mathbb{R},$$

ahol  $I$  az indikátorfüggvényt jelöli. A tapasztalati eloszlásfüggvény annak a diszkrét valószínűségi változónak az eloszlásfüggvénye, amely minden egyes mintaelemet  $1/n$  valószínűséggel vesz fel (egybeeső mintaelemek esetén  $1/n$  megfelelő egész számú többszörösét).

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma

## tapasztalati eloszlásfüggvény

mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Példa

Tekintsük a 3, 2, 2, 4, 1 megfigyelt mintát. Ekkor a rendezett minta 1, 2, 2, 3, 4. A tapasztalati eloszlásfüggvény:

$$F_5^*(x) = \begin{cases} 0 & \text{ha } x \leq 1, \\ 0.2 & \text{ha } 1 < x \leq 2, \\ 0.6 & \text{ha } 2 < x \leq 3, \\ 0.8 & \text{ha } 3 < x \leq 4, \\ 1 & \text{ha } x > 4. \end{cases}$$

### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statistika fogalma

### tapasztalati eloszlásfüggvény

- mintavételi módszerek
- gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény

## **mintavételi módszerek**

gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# A mintavétel módszerei

A minta osztályozása nagyság szerint:

- kis minta: 50 alatt,
- átlagos mintanagyság: 50–1000,
- nagy minta: 1000 felett (adatbányászat).

A mintavétel alapproblémája:

gazdaságosság  $\leftrightarrow$  pontosság.

Módszerek:

- **egyszerű véletlen** (visszatevés nélküli, EV–minta),
- **független azonos eloszlású** (visszatevéses, FAE–minta),
- **szekvenciális** (sorozatos/folyamatos) mintavétel.  
Bevezetése Wald Ábrahám (1902 – 1950) nevéhez fűződik. Pl. veszünk egy 100 elemű mintát valamilyen hipotézis eldöntése céljából, de ha kiderül, hogy a vett minta alapján nem tudunk dönteni, akkor újabb mintát veszünk,



- rétegzett (egyenletes, arányos, Neumann–féle optimális). PI. a férfiak és nők aránya adott a társadalomban és azt szeretnénk, hogy a mintában is ez az arány legyen: arányos mintavétel. Az ún. **reprezentatív mintavétel** 4–féle módon rétegzett minta: a sokaság életkor, jövedelem, iskolai végzettség és lakóhely szerinti megoszlása tükröződik vissza a mintában,
- csoportos. A sokaságot csoportokra osztjuk és egyszerű véletlen mintavételezéssel kiválasztunk néhányat a csoportok közül majd a kiválasztott csoportokban mindenkit megfigyelünk,
- két– és többfokozatú (két– és többlépcsős). A kétlépcsős eljárás első lépcsője egy csoportos mintavétel, majd – ellentétben a csoportos mintavétellel – a kiválasztott csoportok elemeiből is mintát veszünk (valamilyen módszer szerint), azaz nem figyeljük meg teljeskörűen a kiválasztott csoportokat.

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény

## mintavételi módszerek

gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



# A gyorsrendezés algoritmus (quick sort)

Az **oszd meg és uralkodj** elv alkalmazása.

$A :=$  a mintaelemeket tartalmazó tömb,

$p :=$  az első elem indexe,

$r :=$  az utolsó elem indexe.

**Felosztás:** Az  $A[p..r]$  tömböt két, nemüres  $A[p..q]$  és  $A[q + 1..r]$  résztömbre osztjuk úgy, hogy az  $A[p..q]$  minden eleme kisebb vagy egyenlő  $A[q + 1..r]$  minden eleménél. A  $q$  index kiszámítása része ennek a felosztó eljárásnak.

**Uralkodás:** Az  $A[p..q]$  és  $A[q + 1..r]$  résztömböket a gyorsrendezés rekurzív hívásával rendezzük.

**Egyesítés:** Mivel a két résztömböt helyben rendeztük, nincs szükség egyesítésre: az  $A[p..r]$  tömb rendezett.

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



# Pszeudokód

```
RENDEZ(A,p,r)
  if p<r
    then q <- FELOSZT(A,p,r)
    RENDEZ(A,p,q)
    RENDEZ(A,q+1,r)
FELOSZT(A,p,r)
  x <- A[p]
  i <- p-1
  j <- r+1
  while i<j
    do repeat j <- j-1
      until A[j] <= x
    repeat i <- i+1
      until A[i] >= x
    if i < j
      then A[i] <-> A[j]
      else return j
```



## Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

## Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Megjegyzés

A

```
repeat utasítás  
until feltétel
```

vezérlési szerkezet jelentése: egyszer mindenképpen végrehajtódik az utasítás, utána ellenőrződik a feltétel. Ha a feltétel igaz, akkor kilépünk, ha nem, akkor újra végrehajtódik az utasítás, majd a feltétel ellenőrzésre kerül, stb. Az utasítás addig ismétlődik, amíg a feltétel nem lesz igaz, amikor igaz, akkor kilépünk. Felhívjuk a figyelmet, hogy az utasítás legalább egyszer végrehajtódik (akkor is, ha a feltétel az első alkalommal nem igaz). Ilyen vezérlési szerkezet van a Pascal-ban, de C-ben nincs ilyen.

### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek

### gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



## Megjegyzés

A  $\text{FELOSZT}(A, p, r)$  tulajdonképpen egyetlen műveletet végez: az  $x$ -nél kisebb elemeket a tömb elejére, míg az  $x$ -nél nagyobb elemeket a tömb végére helyezi.

Pontosabban: az  $A[q]$  elem és az előtte levők nem nagyobbak, mint  $x$ , az  $A[q]$  utáni elemek pedig nem kisebbek, mint  $x$ .

### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek

### gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



# 1. Példa, 1. rész

Minta:  $A = [5, 1, 3, 6, 6, 7, 2, 5, 1]$ .

Ekkor  $p = 1$  és  $r = 9$ .

FELOSZT( $A, 1, 9$ ) működése:

$$x = 5, \quad i = 0, \quad j = 10,$$

$$j = 9, \quad A[9] = 1 < 5,$$

$$i = 1, \quad A[1] = 5 \geq 5,$$

$$i = 1 < j = 9 \implies A[1] \leftrightarrow A[9], \quad [1, 1, 3, 6, 6, 7, 2, 5, 5],$$

$$j = 8, \quad A[8] = 5 \leq 5,$$

$$i = 2, \quad A[2] = 1 < 5,$$

$$i = 3, \quad A[3] = 3 < 5,$$

$$i = 4, \quad A[4] = 6 > 5,$$

$$i = 4 < j = 8 \implies A[4] \leftrightarrow A[8], \quad [1, 1, 3, 5, 6, 7, 2, 6, 5],$$

$$j = 7, \quad A[7] = 2 < 5,$$

$$i = 5, \quad A[5] = 6 > 5,$$

$$i = 5 < j = 7 \implies A[5] \leftrightarrow A[7], \quad [1, 1, 3, 5, 2, 7, 6, 6, 5].$$

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

## 1. Példa, 2. rész

$$j = 6, A[6] = 7 > 5,$$

$$j = 5, A[5] = 2 < 5,$$

$$i = 6, A[6] = 7 > 5,$$

$$i = 6 > j = 5 \implies \text{return } j = 5.$$

Tehát FELOSZT(A,1,9)=5, így

RENDEZ(A,1,5) és RENDEZ(A,6,9) kerül végrehajtásra.

FELOSZT(A,1,5) működése:  $A=[1,1,3,5,2,7,6,6,5]$ .

$$x = 1, i = 0, j = 6,$$

$$j = 5, A[5] = 2 > 1,$$

$$j = 4, A[4] = 5 > 1,$$

$$j = 3, A[3] = 3 > 1,$$

$$j = 2, A[2] = 1 \leq 1,$$

$$i = 1, A[1] = 1 \geq 1,$$

$$i = 1 < j = 2 \implies A[1] \leftrightarrow A[2], \quad [1,1,3,5,2,7,6,6,5].$$



### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek

### gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

## 1. Példa, 3. rész

$$j = 1, A[1] = 1 \leq 1,$$

$$i = 2, A[2] = 1 \geq 1,$$

$$i = 2 > j = 1 \implies \text{return } j = 1.$$

Tehát FELOSZT(A,1,5)=1, így  
RENDEZ(A,1,1) és RENDEZ(A,2,5) kerül végrehajtásra.

FELOSZT(A,6,9) működése:  $A=[1,1,3,5,2,7,6,6,5]$ .

$$x = 7, i = 5, j = 10,$$

$$j = 9, A[9] = 5 < 7,$$

$$i = 6, A[6] = 7 \geq 7,$$

$$i = 6 < j = 9 \implies A[6] \leftrightarrow A[9], [1,1,3,5,2,5,6,6,7],$$

$$j = 8, A[8] = 6 < 7,$$

$$i = 7, A[7] = 6 < 7,$$

$$i = 8, A[8] = 6 < 7,$$

$$i = 9, A[9] = 7 \geq 7,$$

$$i = 9 > j = 8 \implies \text{return } j = 8.$$

Tehát FELOSZT(A,6,9)=8, így  
RENDEZ(A,6,8) és RENDEZ(A,9,9) kerül végrehajtásra.

## 1. Példa, 4. rész

FELOSZT(A,2,5) működése:  $A=[1,1,3,5,2,5,6,6,7]$ .

$x = 1, i = 1, j = 6,$

$j = 5, A[5] = 2 > 1,$

$j = 4, A[4] = 5 > 1,$

$j = 3, A[3] = 3 > 1,$

$j = 2, A[2] = 1 \leq 1,$

$i = 2, A[2] = 1 \geq 1,$

$i = 2 = j = 2 \implies \text{return } j = 2.$

Tehát FELOSZT(A,2,5)=2, így

RENDEZ(A,2,2) és RENDEZ(A,3,5) kerül végrehajtásra.

Átgondolható, hogy mivel az 5, 6, 6, 7 minta már rendezett, FELOSZT(A,6,8)=6, így

RENDEZ(A,6,6) és RENDEZ(A,7,8) kerül végrehajtásra.

Hasonlóan, FELOSZT(A,7,8)=7, így

RENDEZ(A,7,7) és RENDEZ(A,8,8) kerül végrehajtásra.



### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek

### gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás

# 1. Példa, 5. rész

FELOSZT(A,3,5) működése:  $A=[1,1,3,5,2,5,6,6,7]$ .

$x = 3, i = 2, j = 6,$

$j = 5, A[5] = 2 < 3,$

$i = 3, A[3] = 3 \geq 3,$

$i = 3 < j = 5 \implies A[3] \leftrightarrow A[5], [1,1,2,5,3,5,6,6,7],$

$j = 4, A[4] = 5 > 3,$

$j = 3, A[3] = 2 < 3,$

$i = 4, A[4] = 5 > 3,$

$i = 4 > j = 3 \implies \text{return } j = 3.$

Tehát  $\text{FELOSZT}(A,3,5)=3$ , így

$\text{RENDEZ}(A,3,3)$  és  $\text{RENDEZ}(A,4,5)$  kerül végrehajtásra.



## Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

## Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás





# 1. Példa, 6. rész

FELOSZT(A,4,5) működése:  $A=[1,1,2,5,3,5,6,6,7]$ .

$x = 5, i = 3, j = 6,$

$j = 5, A[5] = 3 < 5,$

$i = 4, A[4] = 5 \geq 5,$

$i = 4 < j = 5 \implies A[4] \leftrightarrow A[5], [1,1,2,3,5,5,6,6,7],$

$j = 4, A[4] = 3 < 5,$

$i = 5, A[5] = 5 \geq 5,$

$i = 5 > j = 4 \implies \text{return } j = 4.$

Tehát  $\text{FELOSZT}(A,4,5)=4$ , így

$\text{RENDEZ}(A,4,4)$  és  $\text{RENDEZ}(A,5,5)$  kerül végrehajtásra.

A rendezett minta tehát:  $[1,1,2,3,5,5,6,6,7]$ .

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# Módosított gyorsrendezés

A FELOSZT(A,p,r) algoritmus más egy kicsit.

Input: (A,p,r).

Output: olyan  $j$  index és olyan átrendezett A tömb, hogy  $A[i] \leq A[j]$ , ha  $i < j$ , és  $A[k] \geq A[j]$ , ha  $k > j$ .

## MODFELOSZT(A,p,r) pszeudokódja:

```

pivot ← A[r]
left  ← p
right ← r-1
while left ≤ right do
    while (left ≤ right and A[left] ≤ pivot)
        do left ← left+1
    while (left ≤ right and A[right] ≥ pivot)
        do right ← right-1
    if (left < right)
        then exchange A[left] ↔ A[right]
exchange A[r] ↔ A[left]
return left

```



## Megjegyzés

A  $\text{MODFELOSZT}(A,p,r)$  abban tér el a  $\text{FELOSZT}(A,p,r)$ -től, hogy

- a minta végéről választ pivot elemet (strázsát),
- a pivot elemet csak a legvégén cseréli be. Emiatt ugyanarra a mintára nem feltétlenül ugyanazt adja outputként, mint a  $\text{FELOSZT}(A,p,r)$ .

Azonban, ha a  $\text{RENDEZ}(A,p,r)$ -t a  $\text{MODFELOSZT}(A,p,r)$ -el használjuk ugyanazt az output-ot kapjuk, mintha a  $\text{FELOSZT}(A,p,r)$ -el használjuk, azaz a rendezett mintát.

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek

### gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás

## 2. Példa, 1. rész

Minta:  $A = [6, 3, 7, 3, 2, 5, 7, 5]$ .

Ekkor  $p = 1$  és  $r = 8$ .

MODFELOSZT( $A, 1, 8$ ) működése:

$\text{pivot}=5$ ,  $\text{left}=1$ ,  $\text{right}=7$ ,  $A = [6, 3, 7, 3, 2, 5, 7, 5]$ .

$1 < 7$ ,  $A[1] = 6 > 5 \Rightarrow \text{left}=1$ ,  $A = [6, 3, 7, 3, 2, 5, 7, 5]$ ,

$1 < 7$ ,  $A[7] = 7 > 5 \Rightarrow \text{right}=6$ ,  $A = [6, 3, 7, 3, 2, 5, 7, 5]$ ,

$1 < 6$ ,  $A[6] = 5 = 5 \Rightarrow \text{right}=5$ ,  $A = [6, 3, 7, 3, 2, 5, 7, 5]$ ,

$1 < 5$ ,  $A[5] = 2 < 5 \Rightarrow \text{right}=5$ ,  $A = [6, 3, 7, 3, 2, 5, 7, 5]$ ,

$1 < 5 \Rightarrow A[1] \leftrightarrow A[5] \Rightarrow A = [2, 3, 7, 3, 6, 5, 7, 5]$ ,

$1 < 5$ ,  $A[1] = 2 < 5 \Rightarrow \text{right}=2$ ,  $A = [2, 3, 7, 3, 6, 5, 7, 5]$ ,



### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett  
minta, a statistika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás

## 2. Példa, 2. rész

$2 < 5$ ,  $A[2] = 3 < 5 \Rightarrow \text{left}=3$ ,  $A = [2, 3, 7, 3, 6, 5, 7, 5]$ ,

$3 < 5$ ,  $A[3] = 7 > 5 \Rightarrow \text{left}=3$ ,  $A = [2, 3, 7, 3, 6, 5, 7, 5]$ ,

$3 < 5$ ,  $A[5] = 6 > 5 \Rightarrow \text{right}=4$ ,  $A = [2, 3, 7, 3, 6, 5, 7, 5]$ ,

$3 < 4$ ,  $A[4] = 3 < 5 \Rightarrow \text{right}=4$ ,  $A = [2, 3, 7, 3, 6, 5, 7, 5]$ ,

$3 < 4$ ,  $A[3] \leftrightarrow A[4] \Rightarrow A = [2, 3, 3, 7, 6, 5, 7, 5]$ ,

$3 < 4$ ,  $A[3] = 3 < 5 \Rightarrow \text{left}=4$ ,  $A = [2, 3, 3, 7=7, 6, 5, 7, 5]$ ,

$4 = 4$ ,  $A[4] = 7 > 5 \Rightarrow \text{left}=4$ ,  $A = [2, 3, 3, 7=7, 6, 5, 7, 5]$ ,

$4 = 4$ ,  $A[4] = 7 > 5 \Rightarrow \text{right}=3$ ,  $A = [2, 3, 3, 7, 6, 5, 7, 5]$ ,

$4 > 3 \Rightarrow \text{right}=3$ ,  $A = [2, 3, 3, 7, 6, 5, 7, 5]$ ,

$4 > 3 \Rightarrow$  nincs csere és a „nagy” while ciklus folytatódik tovább,

$A[8] \leftrightarrow A[4]$ ,  $A = [2, 3, 3, 7, 6, 5, 7, 5]$ ,

return left=4.

Tehát MODFELOSZT(A,1,8) outputja:

$j = 4$  és  $A = [2, 3, 3, 7, 6, 5, 7, 5]$ .



### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek

### gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás

## 2. Példa, 3. rész

FELOSZT(A,1,8) működése:

$$x = 6, i = 0, j = 9,$$

$$j = 8, A[8] = 5 < 6,$$

$$i = 1, A[1] = 6 \geq 6,$$

$$i = 1 < j = 8 \implies A[1] \leftrightarrow A[8], [5,3,7,3,2,5,7,6],$$

$$j = 7, A[7] = 7 > 6,$$

$$j = 6, A[6] = 5 < 6,$$

$$i = 2, A[2] = 3 < 6,$$

$$i = 3, A[3] = 7 > 6,$$

$$i = 3 < j = 6 \implies A[3] \leftrightarrow A[6], [5,3,5,3,2,7,7,6],$$

$$j = 5, A[5] = 2 < 6,$$

$$i = 4, A[4] = 3 < 6,$$

$$i = 5, A[5] = 2 < 6,$$

$$i = 6, A[6] = 7 > 6,$$

$$i = 6 > j = 5 \implies \text{return } j = 5.$$

Tehát FELOSZT(A,1,8) outputja:

$$j = 5 \text{ és } A=[5,3,5,3,2,7,7,6].$$



### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek

### gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás

# Gyorsrendezés egy funkcionális nyelven

2. rész

© Barczy Mátyas  
és Ispány Márton  
2010



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

A Haskell funkcionális programozási nyelvben:

```
sort[] = []
```

```
sort(p:q) = sort [ y | y <- q, y < p ]  
           ++ [p]  
           ++ sort [ y | y <- q, y >= p ]
```

[ ] = üres lista,

++ = két lista összefűzése (sorozatok egymás után írása).

Ez az algoritmus listákon működik („véges sorozatok”), a korábbiak pedig tömbökön, ez a legfőbb különbség közöttük.



## A kód olvasata:

- ha egy üres listát rendezünk, akkor üres listát kapunk,
- egy nem üres listát, aminek az első eleme  $p$ , az összes többi eleme pedig a  $q$  lista, a következőképpen kell rendezni:
  - egy listába összegyűjtjük a  $q$ -ban szereplő,  $p$ -tól kisebb elemeket: `[ y | y <- q, y < p ]`,
  - egy másik listába összegyűjtjük a  $q$ -ban szereplő,  $p$ -tól nagyobb vagy egyenlő elemeket: `[ y | y <- q, y >= p ]`,
  - ezt a két listát rekurzívan rendezzük:  
`sort [ y | y <- q, y < p ]` és  
`sort [ y | y <- q, y >= p ]`,
  - az eredmény a három lista összefűzése (ahol `[ p ]` a  $p$ -t tartalmazó egyelemű lista).

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek

### gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás





## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# A gyorsrendezés véletlen változatai

**1. verzió.** Feltételezzük, hogy mielőtt a  $\text{RENDEZ}(A, p, r)$  megkezdene az átrendezést, véletlenszerűen átrendezi a bemeneti mintát, hogy ezzel biztosítsa a különböző permutációk azonos valószínűségét.

**2/a. verzió.** Feltételezzük, hogy rendelkezésünkre áll egy  $\text{RANDOM}$  nevű véletlenszám generátor. Ha  $a, b \in \mathbb{Z}$ , akkor a  $\text{RANDOM}(a, b)$  meghívásakor egy, az  $[a, b]$  intervallumba eső **egész** számot kapunk vissza oly módon, hogy minden  $[a, b]$ -beli egész szám ugyanolyan valószínűséggel fordul elő. A  $\text{RENDEZ}(A, p, r)$  minden lépésénél, a tömb felosztása előtt kicseréljük az  $A[p]$  elemet az  $A$  tömb egy véletlenszerűen választott elemével. Ez a módosítás biztosítja, hogy a strázsa elem, azaz  $x = A[p]$ , egyenlő eséllyel lehet a tömb bármelyik  $r - p + 1$  eleme.



A FELOSZT( $A, p, r$ ) helyett:

```
RANDOM-FELOSZT( $A, p, r$ )
   $i \leftarrow$  RANDOM( $p, r$ )
   $A[p] \leftarrow A[i]$ 
  return FELOSZT( $A, p, r$ ),
```

illetve a RENDEZ( $A, p, r$ ) helyett:

```
RANDOM-RENDEZ( $A, p, r$ )
  if  $p < r$ 
    then  $q \leftarrow$  RANDOM-FELOSZT( $A, p, r$ )
        RANDOM-RENDEZ( $A, p, q$ )
        RANDOM-RENDEZ( $A, q+1, r$ )
```

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

## Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

**2/b. verzió.** A Haskell-ben megírt gyorsrendezés véletlenített változata: minden egyes lépésben a  $(p : q)$  listában az első elemet  $(p-t)$  felcseréljük a lista egy véletlenszerűen választott elemével, majd az így kapott listát rendezzük a `sort` függvénnyel.

# A véletlenített gyorsrendezés átlagos futási ideje

A Haskell-ben megírt gyorsrendezés véletlenített változatát (2/b. verzió) elemezzük.

**Művelet:** két mintaelem összehasonlítása.

Felhívjuk a figyelmet, hogy az elemzések során két tömbindex összehasonlítását nem szokás műveletnek hívni, mely azzal kapcsolatos, hogy a tömbbeli számok valós számok, míg a tömbindexek mindig egészek.

$M_n$  : a műveletek **átlagos** száma  $n$  szám rendezésénél.

Jelölje a továbbiakban  $X_1, \dots, X_n$  az inputként kapott  $n$  számot.



## Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

## Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



A véletlenített algoritmus definíciójából adódóan tetszőleges  $i \in \{1, \dots, n\}$  esetén annak a valószínűsége, hogy az első csere után a rendezett minta  $i$ -edik tagja lesz a lista első eleme  $1/n$ , azaz

$$P(X_1 = X_i^*) = \frac{1}{n}, \quad i = 1, \dots, n.$$

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek

gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Rekurzió $M_n$ -re:

A teljes várható érték tétele alapján, ha  $\xi_n$  jelöli egy  $n$  elemű minta esetén a műveletek számát:

$$\begin{aligned}
 M_n = \mathbb{E}(\xi_n) &= \sum_{i=1}^n \mathbb{E}(\xi_n \mid X_1 = X_i^*) P(X_1 = X_i^*) \\
 &= \sum_{i=1}^n (n-1 + M_{i-1} + M_{n-i}) \frac{1}{n} \\
 &= n-1 + \frac{1}{n} \sum_{i=1}^n (M_{i-1} + M_{n-i}) \\
 &= n-1 + \frac{2}{n} \sum_{i=1}^n M_{i-1},
 \end{aligned}$$

ahol a kezdő érték  $M_0 := 0$ .

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek

### gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

Valóban, feltételezve, hogy az  $X_1$  mintaelem az  $i$ -edik legnagyobb,  $n - 1$  db összehasonlítás (az  $n$ -hosszúságú lista első elemének a lista utolsó  $n - 1$  tagjával való összehasonlítása) szükséges az  $(i - 1)$ -hosszúságú  $[y \mid y < q, y < p]$  és az  $(n - i)$ -hosszúságú  $[y \mid y < q, y \geq p]$  listák előállításához, továbbá ezen listák rendezéséhez szükséges műveletek átlagos száma  $M_{i-1}$  és  $M_{n-i}$ .

Vegyük az  $\{nM_n\}_{n=1}^{\infty}$  sorozat elsőrendű differenciáját:

$$\begin{aligned} nM_n - (n-1)M_{n-1} &= n(n-1) - (n-1)(n-2) + 2 \left( \sum_{i=1}^n M_{i-1} - \sum_{i=1}^{n-1} M_{i-1} \right) \\ &= 2(n-1) + 2M_{n-1}, \quad n \geq 1. \end{aligned}$$



Ez alapján kapjuk az

$$\frac{M_n}{n+1} = \frac{M_{n-1}}{n} + \frac{2(n-1)}{n(n+1)}, \quad n \geq 1$$

rekurziót. Valóban,

$$\begin{aligned} \frac{M_n}{n+1} - \frac{M_{n-1}}{n} &= \frac{nM_n - (n+1)M_{n-1}}{n(n+1)} \\ &= \frac{nM_n - (n-1)M_{n-1} - 2M_{n-1}}{n(n+1)} \\ &= \frac{2(n-1) + 2M_{n-1} - 2M_{n-1}}{n(n+1)} \\ &= \frac{2(n-1)}{n(n+1)}, \quad n \geq 1. \end{aligned}$$

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás





Ezért

$$\begin{aligned}
 \frac{M_n}{n+1} &= 2 \sum_{k=1}^n \frac{k-1}{k(k+1)} = 2 \sum_{k=1}^n \left( \frac{2}{k+1} - \frac{1}{k} \right) \\
 &= 4 \left( \frac{1}{2} + \dots + \frac{1}{n+1} \right) - 2 \left( \frac{1}{1} + \dots + \frac{1}{n} \right) \\
 &= 4 \left( \frac{1}{1} + \dots + \frac{1}{n} \right) + \frac{4}{n+1} - 4 - 2 \left( \frac{1}{1} + \dots + \frac{1}{n} \right) \\
 &= 2 \sum_{k=1}^n \frac{1}{k} - \frac{4n}{n+1}.
 \end{aligned}$$

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

Mivel

$$\ln(n+1) < \sum_{k=1}^n \frac{1}{k} < 1 + \ln(n), \quad n > 1,$$

kapjuk, hogy

$$\begin{aligned} 2(n+1)\ln(n+1) - 4n < M_n &= (n+1)2 \sum_{k=1}^n \frac{1}{k} - 4n \\ &< 2(n+1)(1 + \ln(n)) - 4n, \\ &\Downarrow \\ \left(1 + \frac{1}{n}\right) \frac{\ln(n+1)}{\ln(n)} - \frac{2}{\ln(n)} &< \frac{M_n}{2n\ln(n)} \\ &< \left(1 + \frac{1}{n}\right) \left(\frac{1}{\ln(n)} + 1\right) - \frac{2}{\ln(n)}. \end{aligned}$$

Mivel a  $\mathcal{L}'$ Hospital szabály alapján

$$\lim_{n \rightarrow \infty} \frac{\ln(n+1)}{\ln(n)} = \lim_{n \rightarrow \infty} \frac{1/(n+1)}{1/n} = 1,$$



### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statistika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek

### gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



$n \rightarrow \infty$  határátmenettel kapjuk, hogy

$$\lim_{n \rightarrow \infty} \frac{M_n}{2n \ln(n)} = 1.$$

Azaz nagy  $n$ -re

$$M_n = (n+1)2 \sum_{k=1}^n \frac{1}{k} - 4n$$

$$\approx 2n \ln(n) = 2n \frac{\log_2(n)}{\log_2(e)} = 2n \ln(2) \log_2(n)$$

$$\approx 1.386n \log_2(n).$$

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek

## gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Statisztikai elemzés

- statisztikai sokaság
- statisztikai változó
- mérési skálák
- statisztikai módszerek

## Statisztikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

## Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

## Adatelemzés fajtái:

**Feltáró (exploratív):** célja az adatokkal való első ismerkedés, helyes kép kialakítása a mintáról. Paraméteres eloszlás családnál kiinduló becslés adása a paraméterekre.

**Megerősítő (konfirmatív):** van valamilyen előfeltételezésünk az adatokról és ezt akarjuk megerősíteni vagy megcáfolni.

A leíró statisztikákat általában a feltáró adatelemzés során használjuk.

Típusai:

- gyakorisági tábla,
- középértékek vagy helyzet (location) mutatók,
- szóródási vagy skála (scale) mutatók,
- alakmutatók (shape).

Az utóbbi három mutatóval számos paraméteres eloszláscsaládot jellemezhetünk.

Jól használhatóak:

- adattömörítésre (és később grafikus megjelenítésre),
- kilógó (irreguláris, outlier) értékek megállapítására (adatok tisztítása),
- szükséges változó és adat transzformációk meghatározására.

Az alábbiakban **egy változót (egydimenziós eloszlást)** jellemző mutatókkal foglalkozunk.

## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



# Gyakorisági tábla

Egy diszkrét változó értékeiről és eloszlásáról kaphatunk teljes képet általa. Alkalmazható folytonos változóra is diszkretizáció (ún. dobozolás) után.

A gyakorisági tábla az alábbi információkat tartalmazza:

- a változó neve és lehetséges értékei (címkével is megadva),
- a változó értékeinek **gyakorisága**, azaz előfordulásuk száma a mintában,
- a változó értékeinek **százalékos aránya**, azaz előfordulási valószínűsége a mintában,
- a változó értékeinek **felfelé kumulált (összegzett) gyakorisága**,
- a változó értékeinek **felfelé kumulált százalékos aránya**.

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

### Gyakorisági tábla

Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Példa:

Egy társaságban 20 férfi és 30 nő van.

Nem	Gyakoriság	Százalékos gyakoriság	Kumulált gyakoriság	Kumulált százalékos gyakoriság
Férfi	20	40	20	40
Nő	30	60	50	100

### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



# Mutatók jellemzői

Jelöljön  $S$  egy statisztikát, legyen  $\underline{x} := (x_1, \dots, x_n)$  egy tetszőleges minta és  $\underline{1} := (1, \dots, 1)$ .

**Helyzetmutatók:**  $S(\underline{x} + c\underline{1}) = S(\underline{x}) + c, \forall c \in \mathbb{R}$  (eltolást mérnek).

**Szóródási mutatók:**

- $S(\underline{x} + c\underline{1}) = S(\underline{x}), \forall c \in \mathbb{R}$  (eltolás-invariancia),
- $S(d\underline{x}) = dS(\underline{x}), \forall d \in \mathbb{R}_+$  (skálát mérnek).

**Alakmutatók:**  $S(d\underline{x} + c\underline{1}) = S(\underline{x}), \forall d \in \mathbb{R}_+, c \in \mathbb{R}$  (eltolás- és skála-invariancia, csak alakot jellemeznek).

## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás





# Helyzetmutatók (középértékek)

## A. Kvantilisek

### Definíció (Elméleti kvantilis)

Legyen  $\xi$  egy valószínűségi változó,  $\alpha \in (0, 1)$ . Egy  $Q(\alpha)$  valós számot  $\xi$   $\alpha$ -kvantilisének nevezünk, ha

$$P(\xi \leq Q(\alpha)) \geq \alpha \quad \text{és} \quad P(\xi \geq Q(\alpha)) \geq 1 - \alpha.$$

Ha  $F$  jelöli  $\xi$  eloszlásfüggvényét, akkor

$$F(Q(\alpha)) \leq \alpha \quad \text{és} \quad F(Q(\alpha) + 0) \geq \alpha,$$

ahol

$$F(Q(\alpha) + 0) := \lim_{x \downarrow Q(\alpha)} F(x).$$

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék


### Összefoglalás

## 1. eset: Ha az

$$F(x) = \alpha$$

egyenletnek van megoldása, de csak egy, akkor ez az  $F^{-1}(\alpha)$  megoldás az egyetlen  $\alpha$ -kvantilis.

Speciálisan, ha  $\xi$ -nek az  $F$  eloszlásfüggvénye folytonos és szigorúan monoton növekvő (pl. normális eloszlás), akkor a  $\alpha$ -kvantilis a fenti egyenlet egyértelmű megoldása.



### Statisztikai elemzés

- statisztikai sokaság
- statisztikai változó
- mérési skálák
- statisztikai módszerek

### Statisztikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot


### Függelék

### Irodalomjegyzék

### Összefoglalás



**2. eset:** Ha az  $F(x) = \alpha$  egyenletnek nincs megoldása, akkor egyetlen  $\alpha$ -kvantilis van, mégpedig az a szám, ahol az  $F$  függvény átugorja a  $\alpha$  értéket.



## Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

## Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék


## Összefoglalás



**3. eset:** Ha az  $F(x) = \alpha$  egyenletnek több megoldása van, akkor a megoldáshalmaz az  $(a, b]$  vagy az  $[a, b]$  intervallum, és a  $\alpha$ -kvantilisek éppen az  $[a, b]$  intervallum pontjai, ahol

$$a := \inf \left\{ x \in \mathbb{R} : F(x+0) \geq \alpha \right\},$$

$$b := \sup \left\{ x \in \mathbb{R} : F(x) \leq \alpha \right\}.$$



### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



## Megjegyzés

- A kvantilis nem feltétlenül egyértelmű (lásd 3. eset).
- Ha létezik az  $f$  sűrűségfüggvény, akkor

$$\int_{-\infty}^{Q(\alpha)} f(x) dx = \alpha \quad \text{és} \quad \int_{Q(\alpha)}^{\infty} f(x) dx = 1 - \alpha.$$

## Elnevezések:

- $\alpha = 0.5$ : medián,
- $\alpha = 0.25, 0.75$ : alsó ( $Q_1$ ) és felső ( $Q_3$ ) kvartilis,
- $\alpha = 0.1, \dots, 0.9$ : decilisek ( $D_1, \dots, D_9$ ),
- $\alpha = 0.01, \dots, 0.99$ : percentilisek.
- $h = Q_3 - Q_1$ : interkvartilis terjedelem.

### Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

### Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla

### Helyzetmutatók

Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# Tapasztalati kvantilisek

## Definíció (Tapasztalati kvantilis)

Legyen  $x_1, \dots, x_n$   $n$ -elemű minta,  $\alpha \in (0, 1)$ . Az

$$\widehat{Q}(\alpha) := x_{[\alpha(n+1)]}^* + \{\alpha(n+1)\}(x_{[\alpha(n+1)]+1}^* - x_{[\alpha(n+1)]}^*)$$

valós számot tapasztalati  $\alpha$ -kvantilisnek nevezzük, ahol  $[\cdot]$  az egész,  $\{\cdot\}$  a törtrészt jelöli, továbbá  $x_0^* := x_1^*$  és  $x_{n+1}^* := x_n^*$ .

## Megjegyzés

- Ha  $1 \leq [\alpha(n+1)] \leq n$ , akkor nincs szükség az  $x_0^* := x_1^*$  és  $x_{n+1}^* := x_n^*$  definíciókra.
- Vannak más definíciók is a tapasztalati kvantilisre: pl.

$$\widehat{Q}(\alpha) := x_{[\alpha n]}^* + \{\alpha n\}(x_{[\alpha n]+1}^* - x_{[\alpha n]}^*).$$



## Példa (A medián számolása)

$$\widehat{Me} := \widehat{Q}(1/2) = \begin{cases} x_{k+1}^* & \text{ha } n = 2k + 1, \\ (x_k^* + x_{k+1}^*)/2 & \text{ha } n = 2k. \end{cases}$$

Valóban, ha  $n = 2k + 1$ , akkor

$\alpha(n+1) = 0.5(2k+2) = k+1$  és így  $[\alpha(n+1)] = k+1$   
és  $\{\alpha(n+1)\} = 0$ . Ezért  $\widehat{Me} = x_{k+1}^*$ .

Ha  $n = 2k$ , akkor  $\alpha(n+1) = 0.5(2k+1) = k+0.5$  és  
így  $[\alpha(n+1)] = k$  és  $\{\alpha(n+1)\} = 0.5$ . Ezért

$$\widehat{Me} = x_k^* + 0.5(x_{k+1}^* - x_k^*) = \frac{x_k^* + x_{k+1}^*}{2}.$$

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla

### Helyzetmutatók

Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



### Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

### Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla

### Helyzetmutatók

Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás

## B. Közepek

### Definíció (Mintaátlag)

Az  $x_1, \dots, x_n$  minta mintaátlaga (számtani közepe) alatt az

$$\bar{x} := \frac{1}{n} \sum_{i=1}^n x_i = \frac{x_1 + \dots + x_n}{n}$$

valós számot értjük.

A mintaátlag iteratív számolása **Spicer átmeneti átlagok algoritmusával** (1972):

$$\bar{x}_n = \bar{x}_{n-1} + \frac{1}{n}(x_n - \bar{x}_{n-1}) = \frac{1}{n}x_n + \frac{n-1}{n}\bar{x}_{n-1}, \quad n > 1,$$

ahol a kezdőérték  $\bar{x}_1 := x_1$ .

**Előnye:** nincs „túlcsordulás”, abban az értelemben, hogy a számolás során nem lépünk ki az  $[x_1^*, x_n^*]$  intervallumból.





További közepek:

- geometriai:  $(\prod_{i=1}^n x_i)^{1/n}$ ,
- harmonikus:  $n(\sum_{i=1}^n x_i^{-1})^{-1}$ ,
- négyzetes:  $\sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$ .

A közepek kapcsolata:

harmonikus  $\leq$  geometriai  $\leq$  számtani  $\leq$  négyzetes.

Felhívjuk a figyelmet, hogy a geometriai, harmonikus és négyzetes középre nem teljesül az a tulajdonság, hogy  $S(\underline{x} + c\underline{1}) = S(\underline{x}) + c$ ,  $\forall c \in \mathbb{R}$ , azaz nem „méri” az eltolást.

## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla

## Helyzetmutatók

- Szóródási mutatók
- Alakmutatók

## Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

## Definíció

Az  $x_1, \dots, x_n$  minta módusza alatt a leggyakrabban előforduló értéket értjük. Ha több ilyen is van, akkor azok közül a legkisebbet értjük móduszon.

Ha pl. a mintaelemek páronként különbözőek, akkor a módusz a legkisebb mintaelem:  $x_1^*$ .



## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók

## Szóródási mutatók

Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# Szóródási (terjedelem) mutatók

## A. Terjedelmek

Azt mérik, hogy a minta mennyire koncentrálódik egy bizonyos tartományra.

Mintaterjedelem:

$$\widehat{R} := x_n^* - x_1^*.$$

Interkvartilis terjedelem:

$$\widehat{h} := \widehat{Q}_3 - \widehat{Q}_1.$$

## B. Mintaátlagtól való abszolút eltérés

$$\widehat{\delta} := \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}|.$$



## C. Mintaátlagtól való négyzetes eltérés

Tapasztalati szórás:

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

Korrigált tapasztalati szórás:

$$s_n^* := \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}.$$

Kis mintáknál  $s_n^{*2}$  ad jobb becslést a szórásnégyzetre.

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# Steiner–formula

Definiáljuk egy tetszőleges  $a \in \mathbb{R}$  szám körüli általánosított tapasztalati szórásnégyzetet ( $a$ -tól való négyzetes eltérés) az alábbi módon:

$$s_n^2(a) := \frac{1}{n} \sum_{i=1}^n (x_i - a)^2.$$

## Állítás (A mintaátlag jellemzése)

*Minden  $a \in \mathbb{R}$  számra  $s_n^2 = s_n^2(\bar{x}) \leq s_n^2(a)$ , azaz az általánosított tapasztalati szórásnégyzet a mintaátlagban veszi fel a minimumát és ez a minimum a tapasztalati szórásnégyzet.*

## Steiner–formula

Minden  $a \in \mathbb{R}$  számra

$$ns_n^2 = \sum_{i=1}^n (x_i - a)^2 - n(\bar{x} - a)^2.$$



**Bizonyítás.** A tevé-szabály alapján:

$$\begin{aligned} ns_n^2 &= \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n ((x_i - a) + (a - \bar{x}))^2 \\ &= \sum_{i=1}^n (x_i - a)^2 + 2 \sum_{i=1}^n (x_i - a)(a - \bar{x}) + \sum_{i=1}^n (a - \bar{x})^2. \end{aligned}$$

Mivel

$$\begin{aligned} 2 \sum_{i=1}^n (x_i - a)(a - \bar{x}) &= 2(a - \bar{x}) \sum_{i=1}^n (x_i - a) \\ &= 2(a - \bar{x})(n\bar{x} - na) = -2n(a - \bar{x})^2 \end{aligned}$$

kapjuk a formulát. □

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statistika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



Az mintaátlagra vonatkozó állítás a Steiner–formula közvetlen következménye, hiszen minden  $a \in \mathbb{R}$  esetén

$$s_n^2 = s_n^2(a) - (\bar{x} - a)^2.$$

Megj.: A Steiner–formulából  $a = 0$  választással:

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

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## D. Relatív szórás

$$\hat{V} := \frac{S_n}{\bar{X}}.$$

Felhívjuk a figyelmet, hogy a relatív szórásra nem teljesül az eltolás–invariancia és az a tulajdonság sem, hogy  $S(d\underline{x}) = dS(\underline{x})$ ,  $\forall d \in \mathbb{R}_+$ .

## E. Az átlag standard hibája

$$\frac{S_n^*}{\sqrt{n}},$$

mely azt méri, hogy mennyire ingadozhat a várható érték a mintaátlag körül.

Gondoljunk például normális eloszlás várható értékére vonatkozó konfidencia intervallum szerkesztésére ismeretlen szórásnégyzet esetén, lásd később.

### Statisztikai elemzés

- statisztikai sokaság
- statisztikai változó
- mérési skálák
- statisztikai módszerek

### Statisztikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók

### Szóródási mutatók

- Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás





## F. Medián abszolút eltérés

Az

$$|x_1 - \widehat{Me}|, \dots, |x_n - \widehat{Me}|$$

sorozat mediánja, azaz a mediántól való abszolút eltérések mediánja.

## G. Átlagos abszolút eltérés a mediántól

$$\frac{1}{n} \sum_{i=1}^n |x_i - \widehat{Me}|.$$

### Feladat

Adjuk meg a medián mintaátlaghoz hasonló jellemzését az átlagos abszolút eltérés segítségével.

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók

### Szóródási mutatók

Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók

### Szóródási mutatók

Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás

## H. Tapasztalati momentumok

Legyen  $r \in \mathbb{N}$ .

Tapasztalati  $r$ -edik momentum:

$$\widehat{M}_r := \frac{1}{n} \sum_{i=1}^n x_i^r.$$

Tapasztalati  $r$ -edik centrált momentum:

$$\widehat{M}_r^c := \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^r.$$

Felhívjuk a figyelmet, hogy az  $\widehat{M}_r$  és  $\widehat{M}_r^c$  mutatókra csak  $r = 1$  esetén teljesül az  $S(d\underline{x}) = dS(\underline{x})$ ,  $\forall d \in \mathbb{R}_+$  tulajdonság. Általában az igaz, hogy  $S(d\underline{x}) = d^r S(\underline{x})$ ,  $\forall d \in \mathbb{R}_+$ . Az  $(\widehat{M}_r)^{1/r}$  és  $(\widehat{M}_r^c)^{1/r}$  mutatókra viszont már teljesül a  $S(d\underline{x}) = dS(\underline{x})$ ,  $\forall d \in \mathbb{R}_+$  tulajdonság.

Megj.:  $\widehat{M}_2^c = s_n^2$ .



# I. Gini-mutató (átlagos abszolút különbség)

$$\widehat{G} := \frac{1}{n(n-1)} \sum_{i=1}^n \sum_{j=1}^n |x_i - x_j|$$

Megj.: Azért  $n(n-1) = n^2 - n$ -el osztunk és nem  $n^2$ -tel, mert  $i = j$ ,  $i = 1, \dots, n$  esetén az  $x_i - x_j$  különbségek mindegyike 0.

## Feladat

Mutassuk meg, hogy

- 

$$0 \leq \widehat{G} \leq \frac{2}{n-1} \sum_{i=1}^n |x_i|.$$

- ha  $x_i \geq 0$ ,  $i = 1, \dots, n$ , akkor

$$0 \leq \widehat{G} \leq 2\bar{x}.$$

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók

## Szóródási mutatók

Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók

### Szóródási mutatók

Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás

## J. Lorenz-görbe, koncentrációs együttható

Akkor beszélünk koncentrációról, hogy ha a sokasághoz tartozó teljes értékösszeg  $(\sum_{i=1}^n x_i)$  vagy annak jelentős része a sokaság kis részére összpontosul.

Legyen  $x_1, \dots, x_n$  egy olyan minta, melyre  $x_i \geq 0$ ,  $i = 1, \dots, n$  és nem mindegyik mintaelem 0 (mely azzal ekvivalens, hogy  $\bar{x} \neq 0$ ).

Koncentrációs együttható:

$$L := \frac{\hat{G}}{2\bar{x}}.$$

Megj.: A korábbiak alapján  $0 \leq L \leq 1$ .

### Állítás

$$L = \frac{2}{n(n-1)\bar{x}} \sum_{i=1}^n ix_i^* - \frac{n+1}{n-1}.$$



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók

## Szóródási mutatók

Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

Lorenz-görbe: a  $(0,0)$  és a

$$\left( \frac{k}{n}, \frac{\sum_{i=1}^k x_i^*}{\sum_{i=1}^n x_i^*} \right), \quad k = 1, \dots, n,$$

pontokat összekötő töröttvonal.

## Állítás

- a Lorenz-görbe monoton növekvő, konvex függvény.

- 

$$L = \frac{n}{n-1} 2t_c,$$

ahol  $t_c$  az ún. **koncentrációs terület**: a  $(0,0)$  és  $(1,1)$  végpontú szakasz és a Lorenz-görbe által határolt poligon területe.

Minél kisebb a koncentrációs terület, annál kisebb a koncentráció, minél nagyobb a koncentrációs terület, annál nagyobb a koncentráció.



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók

## Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# Alakmutatók

## Azimmetria mutatók

### A. Pearson-féle (1895)

$$\hat{P} := \frac{3(\bar{x} - \widehat{Me})}{s_n}.$$

### B. Ferdeség (Skewness)

Az  $X$  valószínűségi változó (elméleti) ferdesége:

$$S := \frac{E(X - E(X))^3}{D^3(X)}.$$

Az elméleti ferdeségre használatos még az  $\alpha_3$  jelölés is.

Normális eloszlás család, illetve szimmetrikus eloszlások esetén (mikor is  $X$  és  $-X$  eloszlása megegyezik)

$S = 0$ .



Tapasztalati ferdeség:

$$\widehat{S}_1 := \frac{\widehat{M}_3^c}{(\widehat{M}_2^c)^{3/2}} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^{3/2}},$$

$$\widehat{S}_2 := \frac{n}{(n-1)(n-2)} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_n^*} \right)^3.$$

Kis minták esetén  $\widehat{S}_2$  jobban közelíti az elméleti ferdeséget, mint  $\widehat{S}_1$ .

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók

## Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## C. Kvantilis-ferdeségek

Legyen  $\alpha \in (0, 1)$ .

$$\hat{F}_\alpha := \frac{(\hat{Q}(1 - \alpha) - \widehat{Me}) - (\widehat{Me} - \hat{Q}(\alpha))}{(\hat{Q}(1 - \alpha) - \widehat{Me}) + (\widehat{Me} - \hat{Q}(\alpha))},$$

$$\hat{F}_{0.25} := \frac{(\hat{Q}_3 - \widehat{Me}) - (\widehat{Me} - \hat{Q}_1)}{(\hat{Q}_3 - \widehat{Me}) + (\widehat{Me} - \hat{Q}_1)},$$

$$\hat{F}_{0.1} := \frac{(\hat{D}_9 - \widehat{Me}) - (\widehat{Me} - \hat{D}_1)}{(\hat{D}_9 - \widehat{Me}) + (\widehat{Me} - \hat{D}_1)}.$$

Nilván,  $\hat{F}_\alpha \in [-1, 1]$ .

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók

### Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás





## Aszimmetria mutatók értelmezése

**Baloldali aszimmetriát**, mikor is az eloszlás jobboldali farka vastagabb és az eloszlás nagyobb tömege koncentrálódik balra **a mutatók pozitív értékei jelzik**.

Például: az  $X = (1, 2, 3, 4, 5, 1000)$  minta esetén  $\widehat{S}_2 \approx 2.449$ .

**Jobboldali aszimmetriát**, mikor is az eloszlás baloldali farka vastagabb és az eloszlás nagyobb tömege koncentrálódik jobbra **a mutatók negatív értékei jelzik**.

Például: az  $Y = (1, 10000, 10001, 10002, 10003, 10004)$  minta esetén  $\widehat{S}_2 \approx -2.449$ .

### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók

### Alakmutatók


### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



Mean = 1669,17  
 Std. Dev. =  
 4081,258  
 N = 6

Előállította az SPSS rendszer

## Statisztikai elemzés

statisztikai sokaság  
 statisztikai változó  
 mérési skálák  
 statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett  
 minta, a statisztika fogalma  
 tapasztalati  
 eloszlásfüggvény  
 mintavételi módszerek  
 gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
 Helyzetmutatók  
 Szóródási mutatók

## Alakmutatók

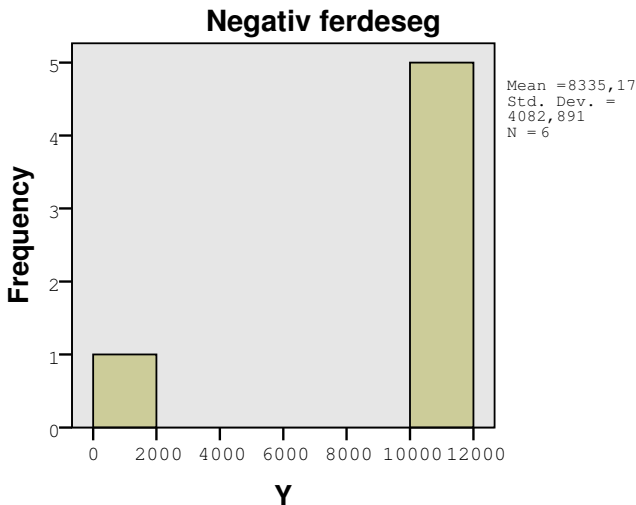
## Grafikus elemzés

Hisztogramok  
 Decimális grafikon  
 Boxdiagram  
 Gauss-papír  
 QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



Előállította az SPSS rendszer

## Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók

## Alakmutatók

## Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# Csúcsossági mutatók

## A. Lapultság (Kurtosis)

Az  $X$  valószínűségi változó (elméleti) lapultsága:

$$K := \frac{E(X - E(X))^4}{D^4(X)} - 3.$$

Az elméleti lapultságra használatos még az  $\alpha_4$  jelölés is.

Belátható, hogy  $K \geq -2$ , továbbá normális eloszlás-család esetén  $K = 0$ .

Tapasztalati lapultság:

$$\widehat{K}_1 := \frac{\widehat{M}_4^c}{(\widehat{M}_2^c)^2} - 3 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^2} - 3,$$

$$\widehat{K}_2 := \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s_n^*}\right)^4 - \frac{3(n-1)^2}{(n-2)(n-3)}.$$

Kis minták esetén  $\widehat{K}_2$  jobban közelíti az elméleti ferdeséget, mint  $\widehat{K}_1$ .



### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statistika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók

### Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



## B. $\widehat{K}_3$ -mutató

$$\widehat{K}_3 := \frac{\widehat{Q}_3 - \widehat{Q}_1}{2(\widehat{D}_9 - \widehat{D}_1)}.$$

Nyilván,  $\widehat{K}_3 \in [0, 1/2]$ .

Ha  $X$  egy normális eloszlású v. v., akkor

$$\begin{aligned} \frac{Q_3 - Q_1}{2(D_9 - D_1)} &= \frac{\Phi^{-1}(3/4) - \Phi^{-1}(1/4)}{2(\Phi^{-1}(9/10) - \Phi^{-1}(1/10))} \\ &\approx \frac{0.675 - (0.675)}{2(1.285 - (-1.285))} \approx 0.263. \end{aligned}$$

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók

### Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



## Csúcsossági mutatók értelmezése

Ha  $\widehat{K}_2 > 0$ , akkor a vizsgált minta sűrűség-hisztogramja  $\bar{x}$  körül csúcsosabb (hegyesebb), mint az  $\mathcal{N}(\bar{x}, (s_n^*)^2)$  sűrűségfüggvénye és vastagabb farkakkal is rendelkezik. (Elnevezés: leptokurtic.)

Ha  $\widehat{K}_2 < 0$ , akkor a vizsgált minta sűrűség-hisztogramja  $\bar{x}$  körül lapultabb, mint az  $\mathcal{N}(\bar{x}, (s_n^*)^2)$  sűrűségfüggvénye és vékonyabb farkakkal is rendelkezik. (Elnevezés: platykurtic.)

Ha  $\widehat{K}_3 > 0.263$ , akkor ugyanaz az értelmezés, mint  $\widehat{K}_2 < 0$  esetén.

Ha  $\widehat{K}_3 < 0.263$ , akkor ugyanaz az értelmezés, mint  $\widehat{K}_2 > 0$  esetén.

A  $\widehat{K}_1$  mutató értelmezése analóg a  $\widehat{K}_2$  mutatóéhoz.

### Statisztikai elemzés

- statisztikai sokaság
- statisztikai változó
- mérési skálák
- statisztikai módszerek

### Statisztikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók

### Alakmutatók

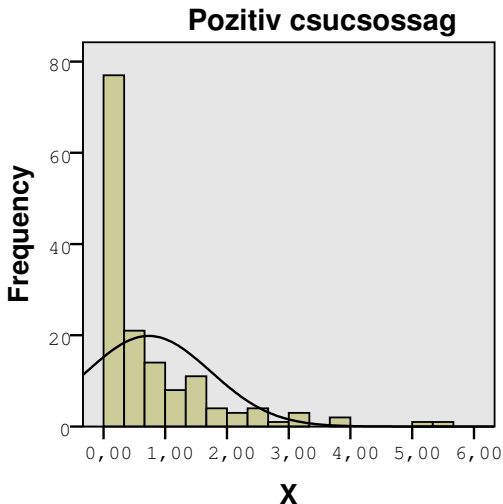
### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



Előállította az SPSS rendszer

## Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók

## Alakmutatók

## Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot


## Függelék

## Irodalomjegyzék

## Összefoglalás



## Negatív csucssosság



Előállította az SPSS rendszer

### Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

### Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók

### Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás





## Megjegyzés

A homogén populációra vett minta eloszlása általában unimodális. Multimodális eloszlás keverékre, inhomogén populációra utal. Ekkor haladottabb statisztikai módszereket kell használni.

### Statisztikai elemzés

- statisztikai sokaság
- statisztikai változó
- mérési skálák
- statisztikai módszerek

### Statisztikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

### Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók

### Alakmutatók

### Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás

# A legismertebb grafikus elemzési módok

- empirikus eloszlásfüggvény,
- gyakorisági- és sűrűséghisztogram,
- kördiagram,
- oszlopdiagram,
- decimális grafikon (stem-and-leaf plot, leveles ág ábra),
- boxdiagram (boxplot),
- Gauss-papír,
- QQ-plot, PP-plot.



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



Tekintsünk egy  $x_1, \dots, x_n$  mintát.

Osszuk fel a számegyenest  $y_1 < \dots < y_r$  osztópontokkal.

Tegyük fel, hogy minden mintaelem az  $(y_1, y_r)$  intervallumba esik.

Jelölje  $\nu_i$  az  $[y_i, y_{i+1})$  intervallumba eső mintaelemek számát,  $i = 1, \dots, r - 1$ .

Rajzoljunk az  $[y_i, y_{i+1})$  intervallum fölé egy  $\nu_i$ -vel arányos területű téglalapot,  $i = 1, \dots, r - 1$ .

Így kapunk egy **hisztogramot**.

## Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

## Grafikus elemzés

### Hisztogramok

- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



**Gyakorisági hisztogram:** a téglalapok összterülete  $n$ .

**Sűrűséghisztogram:** a téglalapok összterülete 1.

## Definíció

Gyakorisági hisztogram:  $f_n : \mathbb{R} \rightarrow [0, \infty)$ ,

$$f_n(x) := \begin{cases} \frac{\nu_i}{(y_{i+1} - y_i)} & \text{ha } x \in [y_i, y_{i+1}), \quad i = 1, \dots, r-1, \\ 0 & \text{ha } x \notin [y_1, y_r). \end{cases}$$

Sűrűséghisztogram:  $f_n : \mathbb{R} \rightarrow [0, \infty)$ ,

$$f_n(x) := \begin{cases} \frac{\nu_i}{n(y_{i+1} - y_i)} & \text{ha } x \in [y_i, y_{i+1}), \quad i = 1, \dots, r-1, \\ 0 & \text{ha } x \notin [y_1, y_r). \end{cases}$$

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

#### Hisztogramok

Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



Az osztópontok sűrítésével, illetve ritkításával érhetjük el, hogy a hisztogram ne legyen se túl durva, se ne ugráljon.

Különböző ajánlások vannak a beosztás sűrűségének megállapítására a mintaelemszám függvényében.

Egyenlő osztályközű beosztást feltételezve:

- Scott-féle módszer:

$$\frac{3.5s_n}{\sqrt[3]{n}},$$

- Freedman–Diaconis módszer:

$$\frac{2\hat{h}}{\sqrt[3]{n}} = \frac{2(\hat{Q}_3 - \hat{Q}_1)}{\sqrt[3]{n}}.$$

## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

### Hisztogramok

Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

### Hisztogramok


Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

## Hisztogram



Előállította az SPSS rendszer



# Decimális grafikon

A **stem=ág** és **leaf=levél** jelentésnek megfelelően úgy bontjuk fel a számértékű adatokat, hogy a fő rész tizedes jegyei adják a „stem”-et (ágot), az utolsó jegy pedig a „leaf”-et (levelet).

Pl. a 34 szám esetén a „stem” 3, a „leaf” 4.

A decimális grafikon segítségével könnyen elkészíthető a rendezett minta.

## Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

## Grafikus elemzés

- Hisztogramok

### Decimális grafikon

- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon

## Boxdiagram


Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# Boxdiagram (nem méretarányos ábra)





# Gauss-papír

Legyen  $x_1, \dots, x_n$  egy minta(realizáció).

Legyen  $X$  egy olyan valószínűségi változó, melynek  $F_X$  eloszlásfüggvénye szigorúan monoton növekvő.

Legyen  $y_1 < y_2 < \dots < y_r$  a számegyenes egy felosztása.

Jelölje  $\mu_i$  az  $y_i$ -nél kisebb mintalemekek számát.

Tekintsük az

$$\left( y_i, F_X^{-1} \left( \frac{\mu_i}{n} \right) \right), \quad i = 1, \dots, r,$$

pontokat összekötő töröttvonalat.

Ha az  $x_1, \dots, x_n$  minta(realizáció) az  $X$  valószínűségi változóra vett minta(realizáció), akkor ez a töröttvonal közelítőleg az  $y = x$  egyenes.

## Statistikai elemzés

- statistikai sokaság
- statistikai változó mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

## Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram

## Gauss-papír

- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



Valóban, nagy  $n$  esetén

$$\frac{\mu_i}{n} \approx P(X < y_i) = F_X(y_i),$$

amiből

$$F_X^{-1} \left( \frac{\mu_i}{n} \right) \approx y_i, \quad i = 1, \dots, n.$$

Az eddigiek tetszőleges (szigorúan monoton növekvő eloszlásfüggvényű) alapeloszlás esetén érvényesek. Azonban elsősorban normalitás vizsgálatára használják.

A Gauss-papír elnevezés onnan adódik, hogy a töröttvonalat eredetileg speciális beosztású, ún. Gauss-papírra rajzolták.

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram

## Gauss-papír

QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



Ha  $X \sim \mathcal{N}(m, \sigma^2)$ , akkor az

$$\left( y_i, \Phi^{-1} \left( \frac{\mu_i}{n} \right) \right) \approx \left( y_i, \frac{y_i - m}{\sigma} \right), \quad i = 1, \dots, r,$$

pontokat összekötő töröttvonal közelítőleg  $1/\sigma$  meredekségű, az  $y$ -tengelyt  $-m/\sigma$ -ban metsző egyenes.

A normalitást akkor kell elvetni, ha a töröttvonal az egyenestől „szisztematikus” eltérést mutat (pl. „S-alakú”).

## Statistikai elemzés

- statistikai sokaság
- statistikai változó
- mérési skálák
- statistikai módszerek

## Statistikai minta

- minta, mintatér, rendezett minta, a statisztika fogalma
- tapasztalati eloszlásfüggvény
- mintavételi módszerek
- gyorsrendezés

## Leíró statisztikák

- Gyakorisági tábla
- Helyzetmutatók
- Szóródási mutatók
- Alakmutatók

## Grafikus elemzés

- Hisztogramok
- Decimális grafikon
- Boxdiagram
- Gauss-papír
- QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## QQ-plot és PP-plot

Legyen  $x_1, \dots, x_n$  egy olyan minta, hogy nincsenek egybeeső mintaelemek, azaz  $x_1^* < x_2^* < \dots < x_n^*$ .

**Normal QQ-plot:** az

$$\left( x_i^*, s_n^* \Phi^{-1} \left( \frac{i - 1/2}{n} \right) + \bar{x} \right), \quad i = 1, \dots, n,$$

pontokat összekötő töröttvonal.

**Megj.:**  $\Phi^{-1}((i - 1/2)/n)$  nemmás, mint a standard normális eloszlás  $(i - 1/2)/n$  kvantilise, korábbi jelöléseinkkel  $Q_{\mathcal{N}(0,1)}((i - 1/2)/n)$ . Továbbá, a fenti képletekben a  $-1$  helyetti  $-1/2$  egyfajta **folytonossági korrekciónak** tekinthető.

Ha a minta(realizáció)  $\mathcal{N}(m, \sigma^2)$  eloszlásból származik, akkor elég nagy  $n$ -re az ábrázolt pontok közelítőleg az  $y = x$  egyenesre illeszkednek.

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír

### QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás

Valóban, a Glivenko–Cantelli-tétel alapján

$$P\left(\limsup_{n \rightarrow \infty} \sup_{x \in \mathbb{R}} |F_n^*(x) - F_{\mathcal{N}(m, \sigma^2)}(x)| = 0\right) = 1.$$

Mivel

$$F_{\mathcal{N}(m, \sigma^2)}(x) = \Phi\left(\frac{x - m}{\sigma}\right), \quad x \in \mathbb{R},$$

elég nagy  $n$ -re

$$\Phi^{-1}(F_n^*(x)) \approx \frac{x - m}{\sigma}, \quad x \in \mathbb{R}.$$

Az  $x = x_i^*$  választással:

$$F_n^*(x_i^*) = \frac{i-1}{n} \implies \Phi^{-1}\left(\frac{i-1}{n}\right) \approx \frac{x_i^* - m}{\sigma},$$

ami alapján

$$\begin{aligned} \left(x_i^*, s_n^* \Phi^{-1}\left(\frac{i-1/2}{n}\right) + \bar{x}\right) &\approx \left(x_i^*, s_n^* \frac{x_i^* - m}{\sigma} + \bar{x}\right) \\ &\approx (x_i^*, x_i^*). \end{aligned}$$



### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett  
minta, a statistika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



**Detrended Normal QQ-plot:** az

$$\left( x_i^*, x_i^* - \left( s_n^* \Phi^{-1} \left( \frac{i - 1/2}{n} \right) + \bar{x} \right) \right), \quad i = 1, \dots, n,$$

pontokat összekötő töröttvonal.

Ha a minta(realizáció)  $\mathcal{N}(m, \sigma^2)$  eloszlásból származik, akkor elég nagy  $n$ -re

$$\left( x_i^*, x_i^* - \left( s_n^* \Phi^{-1} \left( \frac{i - 1/2}{n} \right) + \bar{x} \right) \right) \approx (x_i^*, 0),$$

azaz normalitás esetén az ábrázolt pontok közelítőleg az  $y = 0$  egyenesre illeszkednek.

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



**Normal PP-plot:** az

$$\left( \frac{i-1/2}{n}, \Phi \left( \frac{x_i^* - \bar{x}}{s_n^*} \right) \right), \quad i = 1, \dots, n,$$

pontokat összekötő töröttvonal.

Ez a töröttvonal a  $[0, 1] \times [0, 1]$  egységnégyzeten belül helyezkedik el.

Ha a minta(realizáció)  $\mathcal{N}(m, \sigma^2)$  eloszlásból származik, akkor elég nagy  $n$ -re az ábrázolt pontok közelítőleg az  $y = x$  egyenesre illeszkednek.

Valóban, elég nagy  $n$ -re

$$\Phi \left( \frac{x_i^* - \bar{x}}{s_n^*} \right) \approx \Phi \left( \frac{x_i^* - m}{\sigma} \right) \approx F_n^*(x_i^*) = \frac{i-1}{n}.$$

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



**Detrended Normal PP-plot:** az

$$\left( \frac{i - 1/2}{n}, \frac{i - 1/2}{n} - \Phi \left( \frac{x_i^* - \bar{x}}{s_n^*} \right) \right), \quad i = 1, \dots, n,$$

pontokat összekötő töröttvonal.

Ha a minta(realizáció)  $\mathcal{N}(m, \sigma^2)$  eloszlásból származik, akkor elég nagy  $n$ -re az ábrázolt pontok közelítőleg az  $y = 0$  egyenesre illeszkednek.

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír

QQ-plot és PP-plot

## Függelék

Irodalomjegyzék

Összefoglalás





Jelölje  $F_{Exp(1)}$  az 1-paraméterű exponenciális eloszlás eloszlásfüggvényét.

**Exponential QQ-plot:** az

$$\left( x_i^*, \bar{x} F_{Exp(1)}^{-1} \left( \frac{i - 1/2}{n} \right) \right), \quad i = 1, \dots, n,$$

pontokat összekötő töröttvonal.

Ha a minta(realizáció)  $Exp(\lambda)$  eloszlásból származik, ahol  $\lambda > 0$ , akkor elég nagy  $n$ -re az ábrázolt pontok közelítőleg az  $y = x$  egyenesre illeszkednek.

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



Valóban, a Glivenko–Cantelli–tétel alapján

$$P \left( \limsup_{n \rightarrow \infty} \sup_{x \in \mathbb{R}} |F_n^*(x) - F_{Exp(\lambda)}(x)| = 0 \right) = 1.$$

Mivel

$$F_{Exp(\lambda)}(x) = F_{Exp(1)}(\lambda x), \quad x \in \mathbb{R},$$

elég nagy  $n$ -re

$$F_{Exp(1)}^{-1}(F_n^*(x)) \approx \lambda x, \quad x \in \mathbb{R}.$$

Az  $x = x_i^*$  választással:

$$F_n^*(x_i^*) = \frac{i-1}{n} \implies F_{Exp(1)}^{-1}\left(\frac{i-1}{n}\right) \approx \lambda x_i^*,$$

ami alapján

$$\left( x_i^*, \bar{x} F_{Exp(1)}^{-1}\left(\frac{i-1/2}{n}\right) \right) \approx (x_i^*, \bar{x} \lambda x_i^*) \approx (x_i^*, x_i^*),$$

ahol az utolsó lépésben felhasználtuk, hogy egy  $\lambda$  paraméterű exponenciális eloszlású valószínűségi változó várható értéke  $1/\lambda$ .

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statistika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



**Detrended Exponential QQ-plot:** az

$$\left( x_i^*, x_i^* - \bar{x} F_{Exp(1)}^{-1} \left( \frac{i - 1/2}{n} \right) \right), \quad i = 1, \dots, n,$$

pontokat összekötő töröttvonal.

Ha a minta(realizáció)  $Exp(\lambda)$  eloszlásból származik, ahol  $\lambda > 0$ , akkor elég nagy  $n$ -re az ábrázolt pontok közelítőleg az  $y = 0$  egyenesre illeszkednek.

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír

QQ-plot és PP-plot

## Függelék

Irodalomjegyzék

Összefoglalás



**Exponential PP-plot:** az

$$\left( \frac{i - 1/2}{n}, F_{Exp(1)} \left( \frac{x_i^*}{\bar{x}} \right) \right), \quad i = 1, \dots, n,$$

pontokat összekötő töröttvonal.

Ha a minta(realizáció)  $Exp(\lambda)$  eloszlásból származik, ahol  $\lambda > 0$ , akkor elég nagy  $n$ -re az ábrázolt pontok közelítőleg az  $y = x$  egyenesre illeszkednek.

Valóban, elég nagy  $n$ -re

$$F_{Exp(1)} \left( \frac{x_i^*}{\bar{x}} \right) \approx F_{Exp(1)} (\lambda x_i^*) \approx F_{Exp(\lambda)} (x_i^*) \approx \frac{i - 1}{n}.$$

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statistika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Detrended Exponential PP-plot: az

$$\left( \frac{i-1/2}{n}, \frac{i-1/2}{n} - F_{Exp(1)} \left( \frac{x_i^*}{\bar{x}} \right) \right), \quad i = 1, \dots, n,$$

pontokat összekötő töröttvonal.

Ha a minta(realizáció)  $Exp(\lambda)$  eloszlásból származik, ahol  $\lambda > 0$ , akkor elég nagy  $n$ -re az ábrázolt pontok közelítőleg az  $y = 0$  egyenesre illeszkednek.

### Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

### Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír

QQ-plot és PP-plot

### Függelék

Irodalomjegyzék

Összefoglalás



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

# Függelék

## Állítás

Legyen  $X_1, \dots, X_n$  minta  $\mathcal{N}(m, \sigma^2)$  eloszlásra. Ekkor

$$\mathbb{E}(\widehat{S}_2) = \mathbb{E} \left( \frac{n}{(n-1)(n-2)} \sum_{i=1}^n \left( \frac{X_i - \bar{X}}{S_n^*} \right)^3 \right) = 0,$$

és

$$\mathbb{E}(\widehat{K}_2) = \mathbb{E} \left( \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{i=1}^n \left( \frac{X_i - \bar{X}}{S_n^*} \right)^4 - \frac{3(n-1)^2}{(n-2)(n-3)} \right) = 0.$$

Azaz normális eloszlásból származó minta esetén a tapasztalati ferdeség és lapultság várható értéke 0, így megegyezik az elméleti ferdeséggel, illetve lapultsággal.



**Bizonyítás.** Minden  $r \in \mathbb{N}$  esetén legyen

$$M_r^c := \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^r.$$

Ekkor tetszőleges eloszlásból származó minta esetén

$$\mathbb{E}M_1^c = 0, \quad \mathbb{E}M_2^c = \frac{n-1}{n} \mathbb{E}X_1^2,$$

$$\mathbb{E}M_3^c = \frac{(n-1)(n-2)}{n^2} \mathbb{E}X_1^3,$$

$$\mathbb{E}M_4^c = \frac{(n-1)(n^2 - 3n + 3)}{n^3} \mathbb{E}X_1^4 + \frac{3(n-1)(2n-3)}{n^3} (\mathbb{E}X_1^2)^2.$$

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



Továbbá, **normális eloszlásból származó minta** esetén  
(Fisher, 1930):

$$\mathbb{E} \left( \frac{M_3^c}{(M_2^c)^{3/2}} \right) = 0, \quad \mathbb{E} \left( \frac{M_4^c}{(M_2^c)^2} \right) = \frac{3(n-1)}{n+1}. \quad (1)$$

Így

$$\begin{aligned} \mathbb{E}(\widehat{S}_2) &= \frac{n}{(n-1)(n-2)} \mathbb{E} \left( \frac{n \cdot M_3^c}{\frac{n^{3/2}}{(n-1)^{3/2}} (M_2^c)^{3/2}} \right) \\ &= \frac{n^{1/2}(n-1)}{n-2} \mathbb{E} \left( \frac{M_3^c}{(M_2^c)^{3/2}} \right) = 0, \end{aligned}$$

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás





és

$$\begin{aligned} \mathbb{E}(\widehat{K}_2) &= \frac{n(n+1)}{(n-1)(n-2)(n-3)} \mathbb{E} \left( \frac{n \cdot M_4^c}{\frac{n^2}{(n-1)^2} (M_2^c)^2} \right) \\ &\quad - \frac{3(n-1)^2}{(n-2)(n-3)} \\ &= \frac{(n-1)(n+1)}{(n-2)(n-3)} \cdot \frac{3(n-1)}{n+1} - \frac{3(n-1)^2}{(n-2)(n-3)} = 0. \end{aligned}$$

A következőkben megadjuk Fisher (1) eredményének egy bizonyításvázlatát.

## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Fisher (1) eredményének bizonyítás vázlat:

Legyen  $X_1, \dots, X_n$  minta  $\mathcal{N}(m, \sigma^2)$ -re.

- $(\bar{X}, s_n^2)$  teljes és elégséges statisztika, illetve

$$\left( \sum_{i=1}^n \left( \frac{X_i - \bar{X}}{s_n^*} \right)^3, \sum_{i=1}^n \left( \frac{X_i - \bar{X}}{s_n^*} \right)^4 \right) \quad (2)$$

kiegészítő statisztika (azaz eloszlása nem függ  $(m, \sigma^2)$ -től).

- Így feltehetjük, hogy  $m = 0$  és  $\sigma^2 = 1$ .
- Basu 2. tétele szerint  $(\bar{X}, s_n^2)$  és (2) függetlenek. Így speciálisan  $M_3^C / (M_2^C)^{3/2}$  és  $(M_2^C)^{3/2}$  függetlenek.

### Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

### Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

### Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

### Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

### Függelék

### Irodalomjegyzék

### Összefoglalás



- Ezért

$$\begin{aligned}\mathbb{E}M_3^c &= \mathbb{E}\left(\frac{M_3^c}{(M_2^c)^{3/2}} \cdot (M_2^c)^{3/2}\right) \\ &= \mathbb{E}\left(\frac{M_3^c}{(M_2^c)^{3/2}}\right) \mathbb{E}((M_2^c)^{3/2}),\end{aligned}$$

amiből

$$\mathbb{E}\left(\frac{M_3^c}{(M_2^c)^{3/2}}\right) = \frac{\mathbb{E}M_3^c}{\mathbb{E}(M_2^c)^{3/2}}.$$

- Hasonlóan,

$$\mathbb{E}\left(\frac{M_4^c}{(M_2^c)^2}\right) = \frac{\mathbb{E}M_4^c}{\mathbb{E}(M_2^c)^2}.$$

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

$$\mathbb{E}M_3^c = \frac{(n-1)(n-2)}{n^2} \mathbb{E}X_1^3 = 0.$$

$$\begin{aligned} \mathbb{E}M_4^c &= \frac{(n-1)(n^2-3n+3)}{n^3} \mathbb{E}X_1^4 \\ &\quad + \frac{3(n-1)(2n-3)}{n^3} (\mathbb{E}X_1^2)^2 \\ &= \frac{3(n-1)(n^2-3n+3)}{n^3} + \frac{3(n-1)(2n-3)}{n^3}. \end{aligned}$$



- Fazekas [50. old., 8. Feladat megoldása] alapján

$$\begin{aligned}
 \mathbb{E}(M_2^c)^2 &= \frac{(n-1)^2}{n^2} \mathbb{E}(s_n^*)^4 \\
 &= \frac{(n-1)^2}{n^2} \left( \frac{1}{n} \mathbb{E}X_1^4 + \frac{n^2 - 2n + 3}{n(n-1)} (\mathbb{E}X_1^2)^2 \right) \\
 &= \frac{(n-1)^2}{n^2} \left( \frac{3}{n} + \frac{n^2 - 2n + 3}{n(n-1)} \right).
 \end{aligned}$$

- Így

$$\mathbb{E} \left( \frac{M_4^c}{(M_2^c)^2} \right) = \frac{3(n^2 - 3n + 3) + 3(2n - 3)}{3(n-1) + (n^2 - 2n + 3)} = \frac{3(n-1)}{n+1}.$$

□

## Statistikai elemzés

statistikai sokaság  
statistikai változó  
mérési skálák  
statistikai módszerek

## Statistikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás

- 1 T. H. Cormen, C. E. Leiserson, R. L. Rivest: Algoritmusok. Műszaki Könyvkiadó, Budapest, 2003.
- 2 Fazekas I.: (szerk.), Bevezetés a matematikai statisztikába. Kossuth Egyetemi Kiadó. Debrecen, 2003.
- 3 Füstös L., Kovács E., Meszéna Gy., Simonné Mosolygó N.: Alakfelismerés (Sokváltozós statisztikai módszerek). Új Mandátum Könyvkiadó, Budapest, 2004.
- 4 Hunyadi L., Vita L.: Statisztika közgazdászoknak. KSH, Budapest, 2002.
- 5 Lange, K.: Numerical Analysis for Statisticians. Springer. New York, 1998.

## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett  
minta, a statisztika fogalma  
tapasztalati  
eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás



1. Az elemzés kiinduló pontjai: a vizsgálandó statisztikai sokaság és az őt jellemző változók.
2. Az elemzés módjai, a változók típusai.
3. A megfigyelt ( $n$ -elemű) minta a sokaságra tett konkrét megfigyelések eredménye:  $n$  darab valós szám (vagy vektor). Mintatér: a lehetséges minták összessége.
4. A rendezett minta: gyorsrendezés.
5. A tapasztalati eloszlásfüggvény.
6. A minta tömörítése, jellemzése statisztikák útján történik.
7. A leíró statisztikák szerepe.
8. A grafikus elemzés elemei.

## Statisztikai elemzés

statisztikai sokaság  
statisztikai változó  
mérési skálák  
statisztikai módszerek

## Statisztikai minta

minta, mintatér, rendezett minta, a statisztika fogalma  
tapasztalati eloszlásfüggvény  
mintavételi módszerek  
gyorsrendezés

## Leíró statisztikák

Gyakorisági tábla  
Helyzetmutatók  
Szóródási mutatók  
Alakmutatók

## Grafikus elemzés

Hisztogramok  
Decimális grafikon  
Boxdiagram  
Gauss-papír  
QQ-plot és PP-plot

## Függelék

## Irodalomjegyzék

## Összefoglalás