


# Normális eloszlás



**Normal Distribution**



**Paranormal Distribution**

# Normális eloszlás

A statisztikai tesztek előfeltétele többnyire unimodális eloszlás (csak egy módusz).

Parametrikus tesztek előfeltétele gyakran normális eloszlás.

- ▶ Módusz nagyjából az eloszlás közepén található, megegyezik a mediánnal és az átlaggal,
- ▶ onnan mindkét irányban szimmetrikus csökkenés,
- ▶ megközelítőleg harang formájú (Gauß-görbe).
- ▶ aszimptotikus (0-hoz tart, de soha nem éri el),
- ▶ feltétel általában: folytonos változók, tehát nem csak egész, hanem valós számok,

# Hol fordul elő a normális eloszlás?

A legtöbb, természete szerint parametrikus adat normális eloszlású, ha a minta elég nagy.




- ▶ Egy adott tóból kifogott halak tömege és hossza.
- ▶ Egy városban naponta megtett utak hossza méterben.
- ▶ Klíma, pl. minimum és maximum hőmérsékletek adott időn át.
- ▶ A rövid /i/ magánhangzó tartama 100 magyar beszélő spontán beszédében.
- ▶ Az IQ is ilyen, szándékosan normális eloszlásra van kalibrálva. Az átlag önkényesen rögzített érték: mentális életkor/valós életkor\*100.

# Hol nem találunk normális eloszlást?

- ▶ Pénzügyi mutatók és gazdasági adatok, pl. magyar keresőképes lakosság bevétele.
- ▶ Árváltozások, hozamok, tőzsdei értékek, részvények, árfolyamok.
- ▶ Emberek életkora (korfa).
- ▶ Műszaki és elektronikus termékek élettartama: hosszú élettartam gyakoribb.
- ▶ Reakcióidő: rövid idő gyakoribb.

# Normális eloszlás (N)

Függ  $n$ -től – az elemszámtól, és  $k$ -tól – az osztályok/kategóriák számától. Itt:  $n = 100, 1000, 10000$ .



`a = rnorm(100,0,1)`: 100 random szám húzása normális eloszlásból,  $\bar{x} = 0$  átlaggal,  $s = 1$  szórással.

`hist(a)`: hisztogramm. `plot(density(a))`: sűrűségfüggvény.

Újabb ábra egy már meglévő ábrára: a két függvény között `par(new=T)` futtatása.

## N paramétere

$\mu$ : a teljes populáció feltételezett átlaga.

$\sigma$ : a teljes populáció feltételezett szórása.

$\bar{x}$ : a rendelkezésre álló minta átlaga.

$s$ : a rendelkezésre álló minta szórása.

**minta átlaga:**

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n}$$

## N paraméterei

$\mu$ : a teljes populáció feltételezett átlaga.

$\sigma$ : a teljes populáció feltételezett szórása.

$\bar{x}$ : a rendelkezésre álló minta átlaga.

$s$ : a rendelkezésre álló minta szórása.

**minta átlaga:**

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n}$$

**minta varianciája:**

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



## N paraméterei

$\mu$ : a teljes populáció feltételezett átlaga.

$\sigma$ : a teljes populáció feltételezett szórása.

$\bar{x}$ : a rendelkezésre álló minta átlaga.

$s$ : a rendelkezésre álló minta szórása.

**minta átlaga:**

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n}$$

**minta varianciája:**

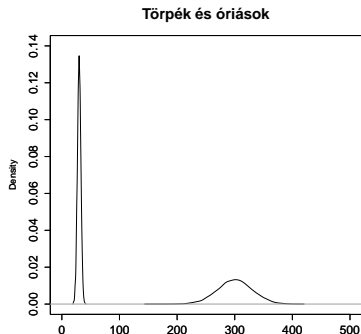
$$v = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}$$

**minta szórása:**

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

# Probléma

A törpék átlagos testmagassága 30 cm, a szórás ennek  $1/10$ -e, azaz 3 cm. Az óriások átlagosan 300 cm magasak, a testmagasság szórása 30 cm.



DE: a szórás függ az elemszámtól és az átlagtól  $\Rightarrow$  eltérő átlagok eloszlása nem összehasonlítható.


## z-transzformáció

Megoldás: standardizálás z-értékre. Minden egyes elemre:

$$z_i = \frac{x_i - \mu}{\sigma}$$

azaz minden egyes elem értékét kivonjuk a populáció (itt: minta) átlagából, és elosztjuk a populáció feltételezett szórásával (tehát a nevezőben itt  $n$  van, és nem  $n - 1$ ).

Ez az általánosító eljárás a z-transzformáció. A normál eloszlású adatokat így standard normális eloszlásúvá alakítjuk. A függvénye `scale()`.



# Standard normális eloszlás

Populáció normális eloszlásának jellemzői:  $N(\mu, \sigma)$ .

átlag:  $\mu = \bar{x}$

z-transzformáció:

$$z_i = \frac{\mu - \mu}{\sigma} = 0$$

szórás:  $\sigma = \mu + \sigma$

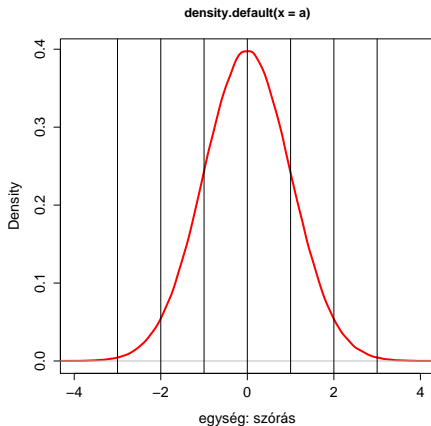
$$z_i = \frac{(\mu + \sigma) - \mu}{\sigma} = 1$$

standard normális eloszlás jellemzése:  $N(0, 1)$







# Standard normális eloszlás

Sűrűségfüggvény:

$x$ -tengely: egységnyi szórás, tartomány:  $\sigma = -\infty \cdots + \infty$ .



Hozzunk létre normális eloszlású vektorokat eltérő átlagokkal és szórásokkal, majd standardizáljuk őket z-transzformációval.  
Szükséges parancssor: 5\_statiztika\_R.txt




## A standardizálással kapott függvények közös jellemzői

- ▶ az  $x$ -tengely és a sűrűségfüggvény által bezárt terület összege = 1.
- ▶ Az esetek 50%-a az átlagtól balra helyezkedik el.
- ▶  $\sigma = -1 \cdots + 1$  közötti tartomány az esetek 68,27%-át tartalmazza.
- ▶  $\sigma = -2 \cdots + 2$  közötti tartomány az esetek 95,45%-át tartalmazza.
- ▶  $\sigma = -3 \cdots + 3$  közötti tartomány az esetek 99,73%-át tartalmazza.




# Standard normális eloszlás



## Ferdeség

Ha az eloszlás szimmetrikus, a **ferdesége** (skewness) 0. Pozitív ferdeség esetén a jobb oldal laposabb, az átlag mediántól jobbra esik, azaz magasabb, mint a medián → jobbra ferde eloszlás.



Negatív ferdeség esetén a bal oldal laposabb, az átlag a mediánnál alacsonyabb → balra ferde eloszlás.

# Transzformációk

Unimodális, de nem szimmetrikus, azaz jobbra vagy balra ferde eloszlások gyakran átalakíthatóak normális eloszlásúvá.

Szokásos eljárások:

- ▶  $x = \log(x)$
- ▶  $x = 1/x$
- ▶  $x = \sqrt{x}$
- ▶ ...