

## Sűrűségfüggvény: definíció (11. előadás)

Az  $X : \Omega \rightarrow \mathbb{R}$  valószínűségi változó **sűrűségfüggvénye** az  $f : \mathbb{R} \rightarrow \mathbb{R}$  függvény, ha

$$\mathbb{P}(X \leq t) = \int_{-\infty}^t f(x) dx$$

teljesül minden  $t \in \mathbb{R}$  számra.

**Nem minden** valószínűségi változónak van sűrűségfüggvénye, például a diszkrétnek nincs. Ha  $X$ -nek **van sűrűségfüggvénye**, akkor **abszolút folytonos** valószínűségi változónak nevezzük.

Ha az  $X$  valószínűségi változó sűrűségfüggvénye  $f$ , akkor tetszőleges  $a < b$  számokra

$$\mathbb{P}(a < X < b) = \mathbb{P}(a \leq X \leq b) = \int_a^b f(x) dx.$$

## A sűrűségfüggvény tulajdonságai

Legyen  $X$  abszolút folytonos valószínűségi változó, melynek  $F$  az eloszlásfüggvénye. (a) Ha  $f$  az  $X$  sűrűségfüggvénye, akkor minden  $t \in \mathbb{R}$  számra

$$F(t) = \mathbb{P}(X \leq t) = \int_{-\infty}^t f(x) dx.$$


(b) Az  $f(t) = F'(t)$  függvény (azokra a  $t$ -kre, ahol  $F$  differenciálható) az  $X$  sűrűségfüggvénye.

Ha az  $f : \mathbb{R} \rightarrow \mathbb{R}$  függvény sűrűségfüggvény, akkor

- ❶  $f(x) \geq 0$  teljesül „majdnem minden”  $x \in \mathbb{R}$ -re (például véges vagy megszámlálható sok kivétel lehetséges).
- ❷  $\int_{-\infty}^{\infty} f(x) dx = 1$ .

*Fordítva:* ha  $f$  teljesíti ezt a két tulajdonságot, akkor van olyan valószínűségi változó, aminek  $f$  a sűrűségfüggvénye.

# Exponenciális eloszlás



$\lambda = 1$  paraméterű exponenciális eloszlás sűrűségfüggvénye és 500 darab független, 1 paraméterű exponenciális eloszlású valószínűségi változóból álló minta hisztogramja

## Exponenciális eloszlás: definíció és tulajdonságok

Legyen  $\lambda > 0$  valós szám. Az  $X$  valószínűségi változó **exponenciális eloszlású**  $\lambda$  paraméterrel, ha sűrűségfüggvénye

$$f(x) = \begin{cases} \lambda e^{-\lambda x}, & \text{ha } x > 0; \\ 0, & \text{különben.} \end{cases}$$

Ekkor

❶  $X$  eloszlásfüggvénye:

$$F(t) = \mathbb{P}(X \leq t) = \int_{-\infty}^t f(x) dx = \begin{cases} 1 - e^{-\lambda t}, & \text{ha } t > 0; \\ 0 & \text{különben.} \end{cases}$$

❷  $X$  várható értéke:  $\mathbb{E}(X) = \frac{1}{\lambda}$ , szórása:  $D(X) = \frac{1}{\lambda}$ .

❸ **Örökifjú tulajdonság.** Legyenek  $s, t$  pozitív számok. Ekkor

$$\mathbb{P}(X \geq s + t | X \geq s) = \mathbb{P}(X \geq t).$$

## Exponenciális eloszlás: példa

Tegyük fel, hogy egy boltban egy vevő kiszolgálásának ideje (percben számolva) **3 várható értékű exponenciális eloszlású** valószínűségi változó.

Mennyi a valószínűsége, hogy a vevőt **legalább 5 percig** tart kiszolgálni?

Mennyi a valószínűsége, hogy a vevő kiszolgálása **legalább 2, de legfeljebb 4 percig** tart?

## Exponenciális eloszlás: példa

Tegyük fel, hogy egy boltban egy vevő kiszolgálásának ideje (percben számolva) **3 várható értékű exponenciális eloszlású** valószínűségi változó.

Mennyi a valószínűsége, hogy a vevőt **legalább 5 percig** tart kiszolgálni?

Mennyi a valószínűsége, hogy a vevő kiszolgálása **legalább 2, de legfeljebb 4 percig** tart? Legyen  $X$  a kiszolgálás ideje. Exponenciális eloszlás esetén

$$\mathbb{E}(X) = 1/\lambda, \text{ és most } \mathbb{E}(X) = 3 \Rightarrow \lambda = 1/3.$$


Ezért az eloszlásfüggvény alapján

$$\begin{aligned}\mathbb{P}(X \geq 5) &= 1 - \mathbb{P}(X < 5) = 1 - F(5) = 1 - (1 - e^{-\lambda \cdot 5}) = e^{-\lambda \cdot 5} = \\ &= e^{-5/3} = 18,9\%.\end{aligned}$$

Hasonlóképpen

$$\begin{aligned}\mathbb{P}(2 \leq X \leq 4) &= \mathbb{P}(X \leq 4) - \mathbb{P}(X \leq 2) = F(4) - F(2) = \\ &= (1 - e^{-4/3}) - (1 - e^{-2/3}) = e^{-2/3} - e^{-4/3} = 25\%.\end{aligned}$$

# Exponenciális eloszlás: példa



Annak valószínűsége, hogy a kiszolgálás legalább 5 percig tart, illetve hogy legalább 2, de legalább 4 percig, ha a kiszolgálási idő 3 várható értékű exponenciális eloszlású valószínűségi változó

## Normális eloszlás: definíció

Legyen  $m$  valós,  $\sigma$  pedig pozitív szám. Azt mondjuk, hogy az  $Y$  valószínűségi változó **normális eloszlású**  $m$  várható értékkel és  $\sigma^2$  szórásnégyzettel, ha **sűrűségfüggvénye**

$$f(x) = \frac{1}{\sqrt{2\pi} \cdot \sigma} \exp\left(-\frac{(x-m)^2}{2\sigma^2}\right) \quad (x \in \mathbb{R}).$$


Jelölése:  $Y \sim N(m, \sigma^2)$ .

Ha  $Y \sim N(m, \sigma^2)$ , akkor  $\mathbb{E}(Y) = m$ ,  $D(Y) = \sigma$ .

**Standard normális eloszlás:** az  $m = 0$  várható értékű és  $\sigma = 1$  szórásu normális eloszlás. **Eloszlásfüggvénye:**  $\Phi$ , sűrűségfüggvénye  $\varphi$ , ahol


$$\Phi(t) = \int_{-\infty}^t \varphi(x) dx; \quad \varphi(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right).$$

# Normális eloszlás



Normális eloszlás ( $m = 1, \sigma = 1$ ) sűrűségfüggvénye és 500 darab független,  $N(1, 1)$  eloszlású valószínűségi változóból álló minta hisztogramja

# Normális eloszlás



Különböző várható értékű ( $m$ ) és szórású ( $\sigma$ ) normális eloszlások sűrűségfüggvényei

## További nevezetes eloszlások

Az alábbi eloszlások többek között **statisztikai alkalmazásokban** fordulnak elő:

- Pareto-eloszlás: végtelen momentumokkal rendelkező eloszlások modellezésére (például jövedelmek, kárnagyságok)
- $t$ -eloszlás: például két eloszlás **várható értékének** összehasonlítására
- $F$ -eloszlás: például két eloszlás **szórásának** összehasonlítására
- $\chi^2$ -eloszlás: például annak eldöntésére, hogy két tulajdonság között van-e **összefüggés**
- gamma-eloszlás: nemnegatív valószínűségi változók modellezésére
- beta-eloszlás:  $[0, 1]$ -értékű valószínűségi változók modellezésére

## Pareto-eloszlás

Az  $X$  valószínűségi változó Pareto-eloszlású, ha sűrűségfüggvénye

$$f(x) = \begin{cases} \frac{\beta}{\alpha^{\beta+1}} \cdot x^{-\beta}; & \text{ha } x \leq \alpha \\ 0, & \text{ha } x > \alpha. \end{cases}$$

Itt  $\alpha > 0, \beta > 1$  rögzített számok. Ekkor  $X$  eloszlásfüggvénye:

$$F(t) = \mathbb{P}(X \leq t) = \begin{cases} 1 - \left(\frac{t}{\alpha}\right)^{-\beta+1}; & \text{ha } t \leq \alpha \\ 0, & \text{ha } t > \alpha. \end{cases}$$

## Pareto-eloszlás

Az  $X$  valószínűségi változó Pareto-eloszlású, ha sűrűségfüggvénye

$$f(x) = \begin{cases} \frac{\beta}{\alpha^{\beta+1}} \cdot x^{-\beta}; & \text{ha } x \leq \alpha \\ 0, & \text{ha } x < \alpha. \end{cases}$$

Itt  $\alpha > 0, \beta > 1$  rögzített számok. Ekkor  $X$  eloszlásfüggvénye:

$$F(t) = \mathbb{P}(X \leq t) = \begin{cases} 1 - \left(\frac{t}{\alpha}\right)^{-\beta+1}; & \text{ha } t \leq \alpha \\ 0, & \text{ha } t < \alpha. \end{cases}$$


Az  $X$  valószínűségi változó  $k$ . momentuma:

$$\mathbb{E}(X^k) = \int_{-\infty}^{\infty} x^k \cdot f(x) dx = \frac{\beta}{\alpha^{\beta+1}} \int_{-\infty}^{\infty} x^{k-\beta} dx < \infty \Leftrightarrow k - \beta < -1.$$

Tehát a Pareto-eloszlásnak csak  $\beta - 1$ -nél kisebb  $k$ -ra véges a  $k$ . momentuma.

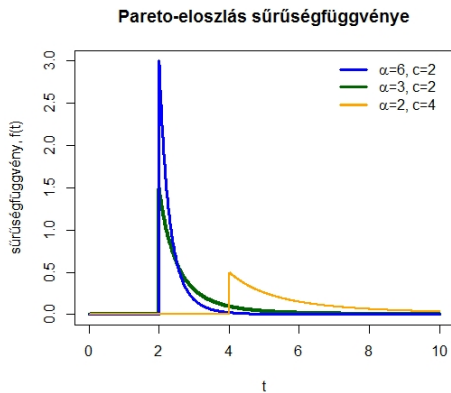
Például ha  $\beta = 2, 5$ , akkor a várható érték létezik és véges, de szórása nem létezik.

# Pareto-eloszlás



Különböző paraméterű Pareto-eloszlások eloszlásfüggvénye

# Pareto-eloszlás



Különböző paraméterű Pareto-eloszlások sűrűségfüggvénye

## $t$ -eloszlás

Legyenek  $X_1, X_2, \dots, X_f$  és  $Y$  független standard normális eloszlású valószínűségi változók. Ekkor a

$$Z = \frac{Y}{\sqrt{(X_1^2 + X_2^2 + \dots + X_f^2)/f}}$$


valószínűségi változó eloszlását  $f$  szabadsági fokú  **$t$ -eloszlásnak** (vagy Student-eloszlásnak) nevezzük.

Az  $f = 1$  szabadsági fokú  $t$ -eloszlás, vagyis  $Y/X$  eloszlása a **Cauchy-eloszlás**. Ennek sűrűségfüggvénye:

$$f(x) = \frac{1}{\pi} \cdot \frac{1}{1 + x^2}.$$

A Cauchy-eloszlásnak sem várható értéke, sem szórása nem létezik:  $\int_{-\infty}^{\infty} x \cdot f(x) dx$  nem értelmezhető, mert  $\int_0^{\infty} \frac{1}{x} dx$  integrál nem véges.

# A $t$ -eloszlás sűrűségfüggvénye



Különböző szabadsági fokú  $t$ -eloszlások sűrűségfüggvényei. A pöttyözött vonal a standard normális eloszlás sűrűségfüggvényét jelöli, ez közel van a  $t$ -eloszlás sűrűségfüggvényéhez, ha  $f$  nagy.

## F-eloszlás


Legyenek  $m, n$  pozitív egészek,  $X_1, \dots, X_m, Y_1, Y_2, \dots, Y_n$  pedig független standard normális eloszlású valószínűségi változók. Ekkor az

$$F = \frac{n(X_1^2 + X_2^2 + \dots + X_m^2)}{m(Y_1^2 + Y_2^2 + \dots + Y_n^2)}$$

valószínűségi változó eloszlását  $m, n$  szabadsági fokú **F-eloszlásnak** nevezük.

# Az $F$ -eloszlás sűrűségfüggvénye

F-eloszlások sűrűségfüggvényei



Különböző szabadsági fokú  $F$ -eloszlások sűrűségfüggvényei

## $\chi^2$ -eloszlás

Legyenek  $X_1, X_2, \dots, X_q$  független standard normális eloszlású valószínűségi változók. Az

$$Y = X_1^2 + X_2^2 + \dots + X_q^2$$

valószínűségi változó eloszlását  $q$  szabadsági fokú  $\chi^2$ -eloszlásnak nevezzük. Ennek sűrűségfüggvénye:

$$f(t) = \begin{cases} \frac{t^{q/2-1}}{2^{q/2}\Gamma(q/2)} e^{-t/2}, & t \geq 0; \\ 0, & t < 0. \end{cases}$$


**Gamma-függvény.** Ha  $a > 0$  pozitív szám, legyen

$$\Gamma(a) = \int_0^{\infty} t^{a-1} e^{-t} dt.$$

Parciális integrálással belátható, hogy  $\Gamma(a) = (a-1)\Gamma(a-1)$  minden  $a > 1$ -re, és így  $\Gamma(n) = (n-1)!$ , ha  $n$  pozitív egész.

# A $\chi^2$ -eloszlás sűrűségfüggvénye

$\chi^2$ -eloszlások sűrűségfüggvényei



Különböző szabadsági fokú  $\chi^2$ -eloszlások sűrűségfüggvényei

# Gamma-eloszlás

**Gamma-függvény.** Ha  $a > 0$  pozitív szám, legyen


$$\Gamma(a) = \int_0^{\infty} t^{a-1} e^{-t} dt.$$

Parciális integrálással belátható, hogy  $\Gamma(a) = (a-1)\Gamma(a-1)$  minden  $a > 1$ -re, és így  $\Gamma(n) = (n-1)!$ , ha  $n$  pozitív egész.

Legyenek  $a$  és  $\lambda$  pozitív számok. Az  $X$  valószínűségi változó **gamma-eloszlású**  $a$  renddel és  $\lambda$  paraméterrel, ha sűrűségfüggvénye

$$f(x) = \begin{cases} \frac{\lambda^a x^{a-1}}{\Gamma(a)} e^{-\lambda x}, & x \geq 0; \\ 0, & x < 0. \end{cases}$$

# A gamma-eloszlás sűrűségfüggvénye



Különböző szabadsági fokú gamma-eloszlások sűrűségfüggvényei

## A gamma-eloszlás tulajdonságai

Az  $X$  valószínűségi változó **gamma-eloszlású**  $a$  renddel és  $\lambda$  paraméterrel, ha sűrűségfüggvénye

$$f(x) = \begin{cases} \frac{\lambda^a x^{a-1}}{\Gamma(a)} e^{-\lambda x}, & x \geq 0; \\ 0, & x < 0. \end{cases}$$

- **Kapcsolat az exponenciális eloszlással:** ha  $a = 1$ , akkor a sűrűségfüggvény  $\lambda e^{-\lambda x}$ , ha  $x \geq 0$ , és az exponenciális eloszlást kapjuk vissza.
- **Exponenciális eloszlások összege:** ha  $X_1, X_2, \dots, X_n$  független  $\lambda$  paraméterű exponenciális eloszlású valószínűségi változók, akkor  $X_1 + X_2 + \dots + X_n$  gamma-eloszlású  $a = n$  renddel és  $\lambda$  paraméterrel.
- **Kapcsolat a  $\chi^2$ -eloszlással:** ha  $a = q/2$  és  $\lambda = 1/2$ , akkor a  $q$  szabadsági fokú  $\chi^2$ -eloszlást kapjuk vissza.
- **Várható érték** és **szórás:**

$$\mathbb{E}(X) = \frac{a}{\lambda}; \quad D(X) = \frac{\sqrt{a}}{\lambda}.$$

## Beta-eloszlás


Legyenek  $a, b > 1$  számok. Az  $X$  valószínűségi változó **beta-eloszlású**  $a$  és  $b$  paraméterekkel, ha sűrűségfüggvénye

$$f(x) = \begin{cases} \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} x^{a-1} (1-x)^{b-1}, & t \in [0, 1]; \\ 0, & x < 0 \text{ vagy } x > 1. \end{cases}$$

Ha  $X_1, X_2, \dots, X_n$  független, a  $[0, 1]$  intervallumon egyenletes eloszlású valószínűségi változók, és  $X_k^*$  jelöli ebben a mintában a  $k$ . legnagyobb számot, akkor  $X_k^*$  eloszlása beta-eloszlás  $a = k$  és  $b = n - k + 1$  paraméterekkel.


Az  $a = 1$  és  $b = 1$  választással az **egyenletes eloszlást** kapjuk vissza.

# A beta-eloszlás sűrűségfüggvénye




Különböző szabadsági fokú beta-eloszlások sűrűségfüggvényei

# Normális eloszlás



Száz független normális eloszlású valószínűségi változó hisztogramja és a sűrűségfüggvény ( $m = 10, \sigma = 3, \bar{x} = 9,88, s_n^* = 2,58$ )

# Normális eloszlások átlaga



Százelemű minta az alábbi eloszlásból:  $n = 1000$  független normális eloszlású ( $m = 10, \sigma = 3$ ) valószínűségi változó átlaga és az  $N(10, 9/1000)$  normális eloszlás sűrűségfüggvénye ( $\bar{x} = 9,99, s_n^* = 0,084, \sigma/\sqrt{n} = 0,095$ )

## Normális eloszlások átlaga

Legyenek  $X, Y$  függetlenek, normális eloszlásúak:  $X \sim N(m_1, \sigma_1^2)$ ,  $Y \sim N(m_2, \sigma_2^2)$ . Ekkor a következők igazak:

- $X + b$  eloszlása normális,  $m_1 + b$  várható értékkel és  $\sigma$  szórással;
- $aX$  eloszlása normális  $am_1$  várható értékkel és  $|a|\sigma$  szórással;
- $X + Y$  eloszlása normális,  $m_1 + m_2$  várható értékkel és  $\sqrt{\sigma_1^2 + \sigma_2^2}$  szórással.

Emlékeztető:  $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y)$ , és ha  $X$  és  $Y$  függetlenek, akkor  $D^2(X + Y) = D^2(X) + D^2(Y)$ .

## Normális eloszlások átlaga

Legyenek  $X, Y$  függetlenek, normális eloszlásúak:  $X \sim N(m_1, \sigma_1^2)$ ,  $Y \sim N(m_2, \sigma_2^2)$ . Ekkor a következők igazak:


- $X + b$  eloszlása normális,  $m_1 + b$  várható értékkel és  $\sigma$  szórással;
- $aX$  eloszlása normális  $am_1$  várható értékkel és  $|a|\sigma$  szórással;
- $X + Y$  eloszlása normális,  $m_1 + m_2$  várható értékkel és  $\sqrt{\sigma_1^2 + \sigma_2^2}$  szórással.

Emlékeztető:  $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y)$ , és ha  $X$  és  $Y$  függetlenek, akkor  $D^2(X + Y) = D^2(X) + D^2(Y)$ .

Ebből következik: ha  $X_1, \dots, X_n$  független normális eloszlásúak  $m$  várható értékkel és  $\sigma$  szórással, akkor


$$\frac{X_1 + \dots + X_n}{n} \sim N\left(m, \frac{\sigma^2}{n}\right)$$

# Exponenciális eloszlás




Száz független  $\lambda = 1/3$  paraméterű exponenciális eloszlású valószínűségi változó hisztogramja és a sűrűségfüggvény, azaz  $e^{-1/3}/3$  ( $\mathbb{E}(X) = D(X) = 3, \bar{x} = 3,03, s_n^* = 2,89$ )

# Exponenciális eloszlások átlaga




Százelemű minta az alábbi eloszlásból:  $n = 1000$  független exponenciális eloszlású ( $\lambda = 1/3$ ) valószínűségi változó átlaga, és az  $N(3, 9/1000)$  normális eloszlás sűrűségfüggvénye ( $\bar{x} = 2,98, s_n^* = 0,098, \sigma/\sqrt{n} = 0,095$ )

# Két kockadobás összege



Két szabályos kockadobás összegének eloszlása


# Kockadobások átlaga



Százelemű minta az alábbi eloszlásból:  $n = 1000$  független szabályos kockadobás átlaga, és az  $N(3,5, D^2(X_1)/1000)$  normális eloszlás sűrűségfüggvénye ( $\bar{x} = 3,501, s_n^* = 0,098, \sigma/\sqrt{n} = 0,051$ )

# Exponenciális eloszlás a kitevőben


Exponenciális eloszlás a kitevőben



$e^{X_1}, e^{X_2}, \dots, e^{X_{1000}}$  hisztogramja, ahol  $X_j$ -k függetlenek, 2 paraméterű exponenciális eloszlásúak ( $\mathbb{E}(e^{X_1}) = 2, D(e^{X_1}) = \infty, \bar{x} = 1,99, s_n^* = 2,33$ )


# Exponenciális eloszlás a kitevőben

Ezer exponenciális eloszlás átlaga



Százelemű minta az alábbi eloszlásból:  $e^{X_1}, e^{X_2}, \dots, e^{X_{1000}}$  átlaga, ahol  $X_i$ -k függetlenek, 2 paraméterű exponenciális eloszlásúak. Itt  $e^{X_i}$  várható értéke véges, de szórása végtelen.

# Az átlag konvergenciája



A  $[0, 1]$  intervallumon egyenletes eloszlásból vett minta átlaga  $n = 500$ -ig

## A nagy számok törvényei

### Tétel (A nagy számok gyenge törvénye)

*Legyenek  $X_1, X_2, \dots$  olyan valószínűségi változók, melyek függetlenek és azonos eloszlásúak. Tegyük fel, hogy  $D(X_1) < \infty$ . Ekkor minden  $\varepsilon > 0$  esetén*

$$\mathbb{P}(|\bar{X}_n - \mathbb{E}(X_1)| > \varepsilon) \rightarrow 0 \quad (n \rightarrow \infty),$$

*azaz  $\bar{X}_n \rightarrow \mathbb{E}(X_1)$  sztochasztikusan.*

## A nagy számok törvényei

### Tétel (A nagy számok gyenge törvénye)

Legyenek  $X_1, X_2, \dots$  olyan valószínűségi változók, melyek függetlenek és azonos eloszlásúak. Tegyük fel, hogy  $D(X_1) < \infty$ . Ekkor minden  $\varepsilon > 0$  esetén

$$\mathbb{P}(|\bar{X}_n - \mathbb{E}(X_1)| > \varepsilon) \rightarrow 0 \quad (n \rightarrow \infty),$$

azaz  $\bar{X}_n \rightarrow \mathbb{E}(X_1)$  sztochasztikusan.

### Tétel (A nagy számok erős törvénye)

Legyenek  $X_1, X_2, \dots$  valószínűségi változók, melyek függetlenek és azonos eloszlásúak. Tegyük fel még, hogy  $m = \mathbb{E}(X_1) < \infty$ . Ekkor

$$\bar{X}_n = \frac{X_1 + X_2 + \dots + X_n}{n} \rightarrow \mathbb{E}(X_1) = m$$

teljesül 1 valószínűséggel  $n \rightarrow \infty$  esetén.

A második esetben gyengébb feltevésből erősebb állítás következik.

# Centrális határeloszlástétel

## Tétel (Centrális határeloszlástétel)

Legyenek  $X_1, X_2, \dots$  **független azonos eloszlású** valószínűségi változók, melyekre  $\mathbb{E}(X_1) = m$  és  $D(X_1) = \sigma < \infty$ , azaz **szórásuk véges**. Ekkor tetszőleges  $t$  valós számra

$$\mathbb{P}\left(\frac{X_1 + X_2 + \dots + X_n - n \cdot m}{\sigma\sqrt{n}} \leq t\right) \rightarrow \mathbb{P}(Z \leq t) \quad (n \rightarrow \infty),$$

ahol  $Z$  standard normális eloszlású, azaz

$$\mathbb{P}(Z \leq t) = \Phi(t) = \int_{-\infty}^t \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right) dx.$$

Ezt úgy is fogalmazhatjuk, hogy

$$\frac{X_1 + X_2 + \dots + X_n - n \cdot m}{\sigma\sqrt{n}} \rightarrow N(0, 1)$$

teljesül  $n \rightarrow \infty$  esetén eloszlásban. Azonos eloszlású:  $\mathbb{P}(X_i \leq t) = P(X_j \leq t)$  minden  $i, j$  párra és  $t$  valós számra

## Centrális határeloszlástétel

Legyenek  $X_1, X_2, \dots$  független azonos eloszlású valószínűségi változók, melyekre  $\mathbb{E}(X_1) = m$  és  $D(X_1) = \sigma < \infty$ . Ekkor

$$\lim_{n \rightarrow \infty} \mathbb{P} \left( a \leq \frac{X_1 + X_2 + \dots + X_n - n \cdot m}{\sigma \sqrt{n}} < b \right) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-x^2/2} dx.$$

A határértéket  $\Phi(b) - \Phi(a) = \mathbb{P}(a \leq Y \leq b)$  alakban is írhatjuk, ahol  $Y \sim N(0, 1)$ .

## Centrális határelosztástétel

Legyenek  $X_1, X_2, \dots$  független azonos eloszlású valószínűségi változók, melyekre  $\mathbb{E}(X_1) = m$  és  $D(X_1) = \sigma < \infty$ . Ekkor

$$\lim_{n \rightarrow \infty} \mathbb{P} \left( a \leq \frac{X_1 + X_2 + \dots + X_n - n \cdot m}{\sigma \sqrt{n}} < b \right) = \frac{1}{\sqrt{2\pi}} \int_a^b e^{-x^2/2} dx.$$

A határértéket  $\Phi(b) - \Phi(a) = \mathbb{P}(a \leq Y \leq b)$  alakban is írhatjuk, ahol  $Y \sim N(0, 1)$ .

Így is átfogalmazható a tétel állítása:

$$\mathbb{P}(nm + a\sigma\sqrt{n} \leq X_1 + X_2 + \dots + X_n < nm + b\sigma\sqrt{n}) \rightarrow \Phi(b) - \Phi(a).$$

Ez azt jelenti, hogy az  $\bar{X}_n$  átlag eloszlása közel van egy  $m$  várható értékű,  $\sigma/\sqrt{n}$  szórású normális eloszláshoz.

## Centrális határeloszlástétel

Legyenek  $X_1, X_2, \dots$  **független** azonos eloszlású valószínűségi változók, melyekre  $\mathbb{E}(X_1) = m$  és  $D(X_1) = \sigma < \infty$ , azaz **szórásuk véges**. Ekkor

$$\begin{aligned} \lim_{n \rightarrow \infty} \mathbb{P} \left( a \leq \frac{X_1 + X_2 + \dots + X_n - n \cdot m}{\sigma \sqrt{n}} < b \right) &= \frac{1}{\sqrt{2\pi}} \int_a^b e^{-x^2/2} dx = \\ &= \Phi(b) - \Phi(a) = \mathbb{P}(a \leq Z \leq b), \end{aligned}$$

ahol  $Z \sim N(0, 1)$  **standard normális eloszlású**. Tovább alakítva:

## Centrális határeloszlástétel

Legyenek  $X_1, X_2, \dots$  **független** azonos eloszlású valószínűségi változók, melyekre  $\mathbb{E}(X_1) = m$  és  $D(X_1) = \sigma < \infty$ , azaz **szórásuk véges**. Ekkor

$$\begin{aligned} \lim_{n \rightarrow \infty} \mathbb{P} \left( a \leq \frac{X_1 + X_2 + \dots + X_n - n \cdot m}{\sigma \sqrt{n}} < b \right) &= \frac{1}{\sqrt{2\pi}} \int_a^b e^{-x^2/2} dx = \\ &= \Phi(b) - \Phi(a) = \mathbb{P}(a \leq Z \leq b), \end{aligned}$$

ahol  $Z \sim N(0, 1)$  **standard normális eloszlású**. Tovább alakítva:

$$\mathbb{P}(nm + a\sigma\sqrt{n} \leq X_1 + X_2 + \dots + X_n < nm + b\sigma\sqrt{n}) \rightarrow \mathbb{P}(a \leq Z \leq b).$$

Ha  $n$ -nel osztunk, hogy az átlag jelenjen meg:

$$\mathbb{P} \left( m + a \frac{\sigma}{\sqrt{n}} \leq \frac{X_1 + X_2 + \dots + X_n}{n} < m + b \frac{\sigma}{\sqrt{n}} \right) \rightarrow \mathbb{P}(a \leq Z \leq b).$$

Vagyis az **átlag eloszlása** „közel van” egy  $m$  várható értékű,  $\frac{\sigma}{\sqrt{n}}$  szórású **normális eloszláshoz**.

## Centrális határeloszlástétel: példa

Legyenek  $X_1, X_2, \dots$  független, 2 várható értékű, exponenciális eloszlású valószínűségi változók. Mi a limesze a  $\mathbb{P}(X_1 + \dots + X_n - 2n < 2\sqrt{n})$  mennyiségnek  $n \rightarrow \infty$  esetén?

## Centrális határeloszlástétel: példa

Legyenek  $X_1, X_2, \dots$  független, 2 várható értékű, exponenciális eloszlású valószínűségi változók. Mi a limesze a  $\mathbb{P}(X_1 + \dots + X_n - 2n < 2\sqrt{n})$  mennyiségnek  $n \rightarrow \infty$  esetén?

Mivel a valószínűségi változók **függetlenek**, **azonos eloszlásúak és véges szórásúak**, teljesülnek a centrális határeloszlástétel feltételei. Ezért

$$\mathbb{P}(X_1 + \dots + X_n - 2n < 2\sqrt{n}) = \mathbb{P}\left(\frac{X_1 + \dots + X_n - 2n}{2\sqrt{n}} < 1\right) \rightarrow \Phi(1),$$

ha  $n \rightarrow \infty$ , hiszen  $m = 2$  a várható érték, és mivel az eloszlás exponenciális, a várható érték egyenlő a szórással, így  $\sigma = 2$  a szórás.

# Konvergenciafajták

## Definíció

A  $Z_1, Z_2, \dots$ , valószínűségi változókból álló sorozat **eloszlásban konvergál** az  $Z$  valószínűségi változóhoz, ha minden olyan  $t$  számra, melyre  $Z$  eloszlásfüggvénye folytonos  $t$ -ben, teljesül, hogy

$$\mathbb{P}(Z_n \leq t) \rightarrow \mathbb{P}(Z \leq t) \quad (n \rightarrow \infty).$$

# Konvergenciafajták

## Definíció

A  $Z_1, Z_2, \dots$ , valószínűségi változókból álló sorozat **eloszlásban konvergál** az  $Z$  valószínűségi változóhoz, ha minden olyan  $t$  számra, melyre  $Z$  eloszlásfüggvénye folytonos  $t$ -ben, teljesül, hogy

$$\mathbb{P}(Z_n \leq t) \rightarrow \mathbb{P}(Z \leq t) \quad (n \rightarrow \infty).$$

Ha  $Z_n \rightarrow Z$  teljesül 1 valószínűséggel, akkor  $Z_n \rightarrow Z$  sztochasztikusan és eloszlásban is.

Lehetséges, hogy  $Z_n \rightarrow Z$  eloszlásban, de  $Z_n$  nem tart  $Z$ -hez sztochasztikusan (és ezért 1 valószínűséggel sem).

## A centrális határeloszlástétel alkalmazása

Tegyük fel, hogy egy véletlenszerűen választott ember  $p$  valószínűséggel szavaz egy adott pártra. Legalább hány embert kell megkérdeznünk (feltételezve, hogy mindenki a többiektől függetlenül válaszol és igazat mond), hogy annak valószínűsége, hogy a pártra szavazók aránya legfeljebb  $0,01$ -gyel tér el  $p$ -tól, tetszőleges  $p$  esetén legalább  $95\%$  legyen?

## A centrális határeloszlástétel alkalmazása

Tegyük fel, hogy egy véletlenszerűen választott ember  $p$  valószínűséggel szavaz egy adott pártra. Legalább hány embert kell megkérdeznünk (feltételezve, hogy mindenki a többiektől függetlenül válaszol és igazat mond), hogy annak valószínűsége, hogy a pártra szavazók aránya legfeljebb 0,01-gyel tér el  $p$ -től, tetszőleges  $p$  esetén legalább 95% legyen?

$n$  megkérdezett, mindenki  $p$  valószínűséggel támogatja a pártot

$X$ : a pártot támogatók száma a megkérdezettek között

Kell:

$$\mathbb{P}\left(\left|\frac{X}{n} - p\right| \leq 0,01\right) \geq 0,95$$

teljesüljön minden  $0 \leq p \leq 1$ -re.

## A centrális határeloszlástétel alkalmazása

$n$  megkérdezett, mindenki  $p$  valószínűséggel támogatja a pártot

$X$ : a pártot támogatók száma a megkérdezettek között,

Kell:

$$\mathbb{P}\left(\left|\frac{X}{n} - p\right| \leq 0,01\right) \geq 0,95$$

teljesüljön minden  $0 \leq p \leq 1$ -re, ahol  $X = \sum_{j=1}^n X_j$ , az  $X_j$ -k függetlenek, és

$$\mathbb{P}(X_j = 1) = 1 - \mathbb{P}(X_j = 0) = p; \quad \mathbb{E}(X_j) = p; \quad D(X_j) = \sqrt{p(1-p)}.$$

$$\begin{aligned} \mathbb{P}\left(\left|\frac{X}{n} - p\right| \leq 0,01\right) &= \mathbb{P}\left(\left|\frac{\sum_{j=1}^n X_j - np}{\sqrt{np(1-p)}}\right| \leq \frac{0,01\sqrt{n}}{\sqrt{p(1-p)}}\right) \\ &\approx 2\Phi\left(\frac{0,01\sqrt{n}}{\sqrt{p(1-p)}}\right) - 1. \end{aligned}$$

## A centrális határeloszlástétel alkalmazása

$n$  megkérdezett, mindenki  $p$  valószínűséggel támogatja a pártot

Kell:

$$\mathbb{P}\left(\left|\frac{X}{n} - p\right| \leq 0,01\right) \approx 2\Phi\left(\frac{0,01\sqrt{n}}{\sqrt{p(1-p)}}\right) - 1 \geq 0,95$$

teljesüljön minden  $0 \leq p \leq 1$ -re. Vagyis mivel  $p(1-p) \leq 1/4$ :


$$\Phi\left(\frac{0,01\sqrt{n}}{\sqrt{p(1-p)}}\right) \geq 0,975;$$

$$\frac{0,01\sqrt{n}}{\sqrt{p(1-p)}} \geq \Phi^{-1}(0,975) = \text{qnorm}(0,975) = 1,96;$$

$$n \geq p(1-p) \cdot 1,96^2 \cdot \frac{1}{0,01^2};$$

$$n \geq \frac{1}{4} \cdot 1,96^2 \cdot \frac{1}{0,01^2} = 9607.$$

# A hiba valószínűsége



A hiba valószínűsége a  $p$  függvényében

## A centrális határeloszlástétel alkalmazása

Tegyük fel, hogy egy véletlenszerűen választott ember  $p$  valószínűséggel szavaz egy adott pártra. Legalább hány embert kell megkérdeznünk (feltételezve, hogy mindenki a többiektől függetlenül válaszol és igazat mond), hogy annak valószínűsége, hogy a pártra szavazók aránya legfeljebb  $0,01$ -gyel tér el  $p$ -től, tetszőleges  $p$  esetén legalább  $95\%$  legyen?


- Csebisev-egyenlőtlenséggel:  $n \geq 50000$  biztosan elég
- centrális határeloszlástétellel közelítve:  $n \geq 9607$  elég

## A centrális határeloszlástétel alkalmazása

Tegyük fel, hogy egy véletlenszerűen választott ember  $p$  valószínűséggel szavaz egy adott pártra. Legalább hány embert kell megkérdeznünk (feltételezve, hogy mindenki a többiektől függetlenül válaszol és igazat mond), hogy annak valószínűsége, hogy a pártra szavazók aránya legfeljebb 0,01-gyel tér el  $p$ -től, tetszőleges  $p$  esetén legalább 95% legyen?

- Csebisev-egyenlőtlenséggel:  $n \geq 50000$  biztosan elég
- centrális határeloszlástétellel közelítve:  $n \geq 9607$  elég
- valójában:  $n = 9607, p = 1/2$  esetén 0,94987 adódik a 0,95 helyett
- valójában  $n \geq 9650$  kell (pontos számolással)

# Szükséges mintaelemszám



A szükséges mintaelemszám a megengedett hibák függvényében

## Házi feladat december 11., hétfő, 10:15-ig

Egy koncertre 16000 ember vett jegyet. Mindenki a többiektől függetlenül  $1/4$  valószínűséggel vesz egyet a fellépő zenekar pólójából.

A centrális határeloszlástétel alapján közelítve hány pólót kell vinni a koncertre, hogy 95% valószínűséggel jusson mindenkinek, aki szeretne vásárolni?

Számítsuk ki a pontos értéket is az R segítségével.