

# A sztochasztika alapjai

## MBNXK262

9. előadás: Nagy számok törvényei, centrális határeloszlás-tétel; Statisztika

Kevei Péter

2023/24 tavasz

# Egyenlőtlenségek

## Tétel (Markov-egyenlőtlenség)

*Legyen  $\xi$  egy véletlen változó  $(\Omega, \mathcal{A}, \mathbf{P})$  valószínűségi mezőn, melynek véges a várható értéke. Ekkor tetszőleges pozitív  $c$  konstansra*

$$\mathbf{P}(|\xi| \geq c) \leq \frac{\mathbf{E}(|\xi|)}{c}.$$

# Egyenlőtlenségek

## Tétel (Csebisev-egyenlőtlenség)

Legyen  $\xi$  egy véletlen változó  $(\Omega, \mathcal{A}, \mathbf{P})$  valószínűségi mezőn, melynek véges a szórása. Ekkor tetszőleges pozitív  $c$  konstansra

$$\mathbf{P}(|\xi - \mathbf{E}(\xi)| \geq c) \leq \frac{\mathbf{D}^2(\xi)}{c^2}.$$

# Nagy számok törvénye

## Tétel (Csebisev-féle nagy számok gyenge törvénye)

*Legyenek  $\xi_1, \xi_2, \dots$  páronként független, véges szórású véletlen változók, melyek közös várható értéke  $\mu$  és szórnégyszete  $\sigma^2$ . Ekkor tetszőleges  $\varepsilon > 0$  esetén*

$$\lim_{n \rightarrow \infty} \mathbf{P} \left( \left| \frac{\xi_1 + \dots + \xi_n}{n} - \mu \right| > \varepsilon \right) = 0.$$



## Tétel (Bernoulli-féle nagy számok gyenge törvénye (1713))

*Jelölje  $S_n$  egy  $p$  valószínűségű  $A$  esemény bekövetkezéseinek a számát egy kísérlet  $n$  független ismétlése során. Ekkor tetszőleges  $\varepsilon > 0$  esetén*

$$\lim_{n \rightarrow \infty} \mathbf{P} \left( \left| \frac{S_n}{n} - p \right| > \varepsilon \right) = 0.$$

## Tétel (Centrális határeloszlás-tétel)

Legyenek  $\xi, \xi_1, \xi_2, \dots$  független, azonos eloszlású véletlen változók közös  $\mathbf{E}(\xi) = \mu$  várható értékkel, és véges  $\mathbf{D}(\xi) = \sigma$  szórással. Ekkor tetszőleges  $x \in \mathbb{R}$  esetén

$$\lim_{n \rightarrow \infty} \mathbf{P} \left( \frac{\sum_{i=1}^n (\xi_i - \mu)}{\sqrt{n}\sigma} < x \right) = \Phi(x),$$

ahol

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{y^2}{2}} dy$$

a standard normális eloszlás eloszlásfüggvénye.





## Tétel (de Moivre–Laplace tétel)

*Jelölje  $S_n$  egy  $p$  valószínűségű  $A$  esemény bekövetkezéseinek a számát egy kísérlet  $n$  független ismétlése során. Ekkor tetszőleges  $x \in \mathbb{R}$  esetén*

$$\lim_{n \rightarrow \infty} \mathbf{P} \left( \frac{S_n - np}{\sqrt{np(1-p)}} < x \right) = \Phi(x).$$

## Példa

A kakucsretyegek polgármesterválasztáson két jelölt van: A és B. Kakucsretyege 40000 szavazója egymástól függetlenül,  $1/2 - 1/2$  valószínűséggel szavaz a két jelölt egyikére. A feszült politikai helyzet miatt a szavazatok újraszámolását rendelik el, ha a két jelöltre leadott szavazatok száma között legfeljebb 100 a különbség. Mi a valószínűsége, hogy újraszámolásra kerül sor?



## Példa

A sztochasztika alapjai kurzus 700 hallgatójának mindegyike bemegy az első előadásra. Ezt követően minden hallgató minden további előadás előtt feldob egy szabályos pénzérmét. Ha fejet kap, akkor bemegy a következő előadásra, ha írást akkor nem, és utána már egyetlen előadásra sem megy be. Véletlen Vince a 700 hallgató egyike. Mennyi a valószínűsége, hogy Vince az összes előadásra bemegy? Várhatóan hány előadáson vesz részt? Mennyi a valószínűsége, hogy a 13. (utolsó) előadáson lesz hallgató? Várhatóan hány hallgató lesz a 2., 3., utolsó előadáson? Mennyi a valószínűsége, hogy a negyedik előadáson 100-nál több hallgató vesz részt. És annak, hogy a tizenegyediken pontosan 2 hallgató vesz részt?



## Példa

Budapesten meg akarják állapítani a dohányosok  $p$  arányát. Ehhez kiválasztanak  $n$  egyént úgy, hogy minden választásnál mindenki ugyanakkora valószínűséggel kerül kiválasztásra, és csak ezek közt nézik meg a dohányosok  $k$  számát. Legalább mekkora legyen az  $n$ , hogy a kapott  $p' = k/n$  arány legalább 0,95 valószínűséggel legfeljebb 0,005 hibával közelítse a valódi  $p$  arányt, akármilyen  $p \in (0, 1)$ ?





# Statisztikai alapfogalmak

Független, azonos eloszlású véletlen változók egy  $\xi, \xi_1, \xi_2, \dots$  sorozatát *statisztikai mintának* nevezzük. Közös (ismeretlen) eloszlást *háttéreloszlás*. A minta egy adott realizációját  $x_1, \dots, x_n$  jelöli. A minta egy  $T$  függvényét *statisztikának* nevezzük.

# Alapstatisztikák

$\xi_1, \xi_2, \dots, \xi_n$  egy  $n$ -elemű minta.

## Definíció

Az

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

a *mintaátlag*.

## Torzítatlanság, konzisztencia

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

$$\mathbf{E}(\bar{\xi}_n) =$$

# Torzítatlanság, konzisztencia

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

$$\mathbf{E}(\bar{\xi}_n) =$$

$$\mathbf{P}(|\bar{\xi}_n - \mu| > \varepsilon) \rightarrow 0$$

## Definíció

*Az empirikus szórásnégyzet*

$$V_n(\xi) = V_n = \frac{1}{n} \sum_{i=1}^n (\xi_i - \bar{\xi}_n)^2.$$

## Definíció

Az empirikus szórásnégyzet

$$V_n(\xi) = V_n = \frac{1}{n} \sum_{i=1}^n (\xi_i - \bar{\xi}_n)^2.$$

## Tétel (Steiner-tétel)

Tetszőleges  $x_1, \dots, x_n$  értékekre és  $c$  valós számra

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

A  $c = 0$  választással

$$V_n = \frac{1}{n} \sum_{i=1}^n \xi_i^2 - (\bar{\xi}_n)^2.$$

A  $c = 0$  választással

$$V_n = \frac{1}{n} \sum_{i=1}^n \xi_i^2 - (\bar{\xi}_n)^2.$$

$$\mathbf{E}(V_n) =$$



A  $c = 0$  választással

$$V_n = \frac{1}{n} \sum_{i=1}^n \xi_i^2 - (\bar{\xi}_n)^2.$$

$$\mathbf{E}(V_n) =$$

Korrigált empirikus szórásnégyzet

$$V_n^*(\xi) = \frac{1}{n-1} \sum_{i=1}^n (\xi_i - \bar{\xi}_n)^2 = \frac{n}{n-1} V_n(\xi)$$

torzítatlan becslése a szórásnégyzetnek.

## Tétel

*Ha  $\mathbf{E}(\xi^4) < \infty$ , akkor mind az empirikus szórásnégyzet, mind a korigált empirikus szórásnégyzet gyengén konzisztens becslése a szórásnégyzetnek.*

Az  $(\xi_1, \eta_1), \dots, (\xi_n, \eta_n)$  minta *empirikus kovarianciája*

$$C_n(\xi, \eta) = \frac{1}{n} \sum_{i=1}^n (\xi_i - \bar{\xi}_n)(\eta_i - \bar{\eta}_n) = \frac{1}{n} \sum_{i=1}^n \xi_i \eta_i - \bar{\xi}_n \bar{\eta}_n.$$

Az  $(\xi_1, \eta_1), \dots, (\xi_n, \eta_n)$  minta *empirikus kovarianciája*

$$C_n(\xi, \eta) = \frac{1}{n} \sum_{i=1}^n (\xi_i - \bar{\xi}_n)(\eta_i - \bar{\eta}_n) = \frac{1}{n} \sum_{i=1}^n \xi_i \eta_i - \bar{\xi}_n \bar{\eta}_n.$$

$$\mathbf{E}(C_n(\xi, \eta)) =$$

## Tétel

Legyen  $(\xi, \eta), (\xi_1, \eta_1), (\xi_2, \eta_2), \dots$  olyan statisztikai minta, melyre  $\mathbf{E}_\theta(\xi^4) < \infty, \mathbf{E}_\theta(\eta^4) < \infty$ , minden  $\theta \in \Theta$  esetén. Ekkor a

$$C_n = \frac{1}{n} \sum_{i=1}^n (\xi_i - \bar{\xi}_n)(\eta_i - \bar{\eta}_n)$$

*empirikus kovariancia gyengén konzisztens becslése a kovarianciának.*

# Jelölés

A konkrét realizációból számolt értékeket a megfelelő kisbetűvel jelöljük, így konkrét  $x_1, \dots, x_n$  realizációhoz tartozó mintaátlag és empirikus szórásnégyzet

$$\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i, \quad v_n = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_i)^2.$$

## Definíció

Az  $\xi_1, \dots, \xi_n$  minta *empirikus eloszlásfüggvénye*

$$F_n(x) = \frac{1}{n} |\{i : \xi_i < x\}|.$$

Indikátorváltozókkal:

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{I}(\xi_i < x).$$

## Definíció

Az  $\xi_1, \dots, \xi_n$  minta *empirikus eloszlásfüggvénye*

$$F_n(x) = \frac{1}{n} |\{i : \xi_i < x\}|.$$

Indikátorváltozókkal:

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{I}(\xi_i < x).$$

A függetlenség miatt  $\mathbb{I}(\xi_1 < x), \dots, \mathbb{I}(\xi_n < x)$  független Bernoulli-eloszlású véletlen változók  $p = F(x)$  paraméterrel.

## Állítás

Legyen  $\xi_1, \xi_2, \dots$  az  $F$  háttéreloszlásból származó minta, és tekintsük ennek az  $F_n$  empirikus eloszlásfüggvényét. Ekkor

$$\mathbf{E}(F_n(x)) = F(x), \quad \mathbf{D}^2(F_n(x)) = \frac{F(x)(1 - F(x))}{n}.$$

Továbbá, tetszőleges  $x \in \mathbb{R}$  esetén, tetszőleges  $\varepsilon > 0$  számra

$$\lim_{n \rightarrow \infty} \mathbf{P}(|F_n(x) - F(x)| > \varepsilon) = 0.$$



## Példa

Az  $x_1 = 40$ ,  $x_2 = 45$ ,  $x_3 = 40$ ,  $x_4 = 42$ ,  $x_5 = 36$  minta empirikus eloszlásfüggvénye:

