

A sztochasztika alapjai

MBNXK262

10. előadás: Nagy számok törvényei, CHT; statisztika

Kevei Péter

2022/23 tavasz

Nagy számok törvénye

Tétel (Csebisev-féle nagy számok gyenge törvénye)

Legyenek ξ_1, ξ_2, \dots páronként független, véges szórású véletlen változók, melyek közös várható értéke μ és szórásnégyzete σ^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 (Csebisev-egyenlőtlenség)

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

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

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 ξ, ξ_1, ξ_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

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, akármi is $p \in (0, 1)$?

Statisztikai alapfogalmak

Független, azonos eloszlású véletlen változók egy ξ, ξ_1, ξ_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 ξ_1, \dots, ξ_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 ξ_1, \dots, ξ_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 ξ_1, ξ_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:

