

## Segédanyag a Valószínűségszámítás és statisztika tantárgyhoz

2015. szeptember 11.

**Definíció. Véges valószínűségi mező:**  $(\Omega, \mathcal{A}, P)$  hármas, ahol:

- $\{\omega_1, \dots, \omega_n\} = \Omega$ : eseménytér; elemei: elemi események
- $\{A, B, \dots\} = \mathcal{A} \subset 2^\Omega$ , ahol  $A, B, \dots$ : események
- $P$ : valószínűségi mérték
  - $P(\Omega) = 1$
  - $P(A) \geq 0$  minden  $A$  eseményre
  - $P(A \cup B) = P(A) + P(B)$  minden  $A$  és  $B$  egymást kizáró eseményre ( $A \cap B = \emptyset$ ).

**Definíció. Kolmogorov-féle vsz.-i mező:**  $(\Omega, \mathcal{A}, P)$  hármas, ahol:

- $\Omega$ : nemüres halmaz
- $\mathcal{A} \subset 2^\Omega$   $\sigma$ -algebra
- $P: \mathcal{A} \rightarrow [0; 1]$  halmazfüggvény, amelyre
  - $P(\Omega) = 1$
  - $P(A) \geq 0 \quad \forall A \in \mathcal{A}$ -ra
  - páronként kizáró  $A_1, A_2, \dots \in \mathcal{A}$  eseményekre

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i).$$

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

$$P(\bar{A}) = 1 - P(A)$$

**Permutáció:**  $n$  elem összes lehetséges sorrendje:  $n!$

**Ismétléses permutáció:**  $n$  elem összes lehetséges sorrendje, ha ezek közül  $k_1, \dots, k_m$  darab megegyezik:  $\frac{n!}{k_1! \dots k_m!}$

Adott  $n$  elem, ebből  $k$  darabot kivesszünk

	<b>Kombináció:</b> a kihúzás sorrendje NEM számít (nem számozottak az elemek)	<b>Variáció:</b> a kihúzás sorrendje számít (számozottak az elemek)
Visszatevés nélkül (ismétlés nélkül)	$\binom{n}{k} = \frac{n!}{k!(n-k)!}$	$\frac{n!}{(n-k)!}$
Visszatevéssel (ismétléssel)	$\binom{n+k-1}{k}$	$n^k$

**Mintavétel:** Adott  $N$  termék, ezek közül  $M$  selejtes. Az összes termékből kivesszünk  $n$  darabot. Mi a valószínűsége, hogy ezek között  $k$  selejtes lesz? ( $k = 0, 1, \dots, n$ )

- Visszatevés nélkül:  $\frac{\binom{M}{k} \binom{N-M}{n-k}}{\binom{N}{n}}$
- Visszatevéssel:  $\binom{n}{k} p^k (1-p)^{n-k}$  ahol  $p = \frac{M}{N}$  a selejtarány

**Feltételes valószínűség:** Ha  $B$  bekövetkezett, mi a valószínűsége, hogy  $A$  bekövetkezik?

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \quad (P(B) \neq 0)$$

**Definíció. Teljes eseményrendszer (TER)**  $B_1, B_2, \dots$  események teljes eseményrendszert alkotnak, ha

- $B_i \cap B_j = \emptyset$  minden  $i \neq j$ -re
- $\bigcup_{i=1}^{\infty} B_i = \Omega$

**Tétel. Teljes valószínűség tétele:** Legyen  $B_1, B_2, \dots$  teljes eseményrendszer,  $A$  tetszőleges esemény,  $P(B_j) > 0$  minden  $j$ -re

$$\text{Ekkor } P(A) = \sum_{j=1}^{\infty} P(A|B_j)P(B_j).$$

**Tétel. Bayes-tétel:** Legyen  $B_1, \dots, B_n$  teljes eseményrendszer,  $A$  tetszőleges esemény,  $P(B_j) > 0$  minden  $j$ -re

$$\text{Ekkor } P(B_k|A) = \frac{P(A|B_k)P(B_k)}{\sum_{j=1}^{\infty} P(A|B_j)P(B_j)}.$$

**Definíció. Események függetlensége:**  $A$  és  $B$  események függetlenek, ha  $P(A \cap B) = P(A) \cdot P(B)$  ( $A$  esemény bekövetkezése nem befolyásolja  $B$  esemény bekövetkezését, és fordítva).

**Definíció. Valószínűségi változó:**  $X: \Omega \rightarrow \mathbb{R}$  mérhető függvény, azaz amire  $\{\omega : X(\omega) \in B\} \in \mathcal{A}$  minden  $B \subseteq \mathbb{R}$  nyílt halmazra.

**Definíció. Valószínűségi változó eloszlása:**  $Q_X(B) = P(X \in B) = P(\omega : X(\omega) \in B)$

**Definíció. Diszkrét valószínűségi változó:** értékészlete legfeljebb meg-

számlálhatóan végtelen, azaz  $\{x_1, \dots, x_n, \dots\}$  elemekből áll.

Ekkor eloszlása:  $p_i := P(X = x_i) = P(\omega : X(\omega) = x_i)$

**Tétel. Binomiális tétel:**  $(a + b)^n = \sum_{k=0}^n \binom{n}{k} a^k b^{n-k}$ .

Geometriai sor összege:  $\sum_{n=0}^{\infty} q^n = \frac{1}{1-q}$ , ha  $|q| < 1$ .

Konvergenciatartományon belül "be lehet deriválni" egy végtelen sort, így  $\sum_{n=1}^{\infty} nq^{n-1} = \frac{1}{(1-q)^2}$ , ha  $|q| < 1$ .

Legyen  $(\Omega, \mathcal{A}, P)$  valószínűségi mező,  $X: \Omega \rightarrow \mathbb{R}$  valószínűségi változó.

**Definíció. Várható érték**  $X$  várható értéke:  $EX = \int_{\Omega} X dP$ , ha ez létezik.

**Definíció. 1. momentum** :  $EX^l = \int_{\Omega} X^l dP$ , ha ez létezik.

**Definíció. X szórásnégyzete** :  $D^2X = E[(X-EX)^2] = EX^2 - E^2X$ .

**Definíció. X szórása** :  $DX = \sqrt{D^2X}$ .

Legyen  $X$  diszkrét valószínűségi változó, ami az  $x_1, x_2, \dots$  értékeket veszi fel,  $p_1, p_2, \dots$  valószínűségekkel. Ekkor  $EX = \sum_{i=1}^{\infty} x_k p_k$ , ha a végtelen összeg

abszolút konvergens. Ugyanígy  $EX^l = \sum_{i=1}^{\infty} (x_k)^l p_k$ , ha a végtelen összeg

abszolút konvergens.

Nevezetes diszkrét eloszlások:

Eloszlás neve	Jelölése	Eloszlása	EX	$D^2X$
Karakterisztikus (indikátórvált.)	Ind(p)	$P(X = 1) = p$ $P(X = 0) = 1 - p$	$p$	$p(1 - p)$
Geometriai (Pascal)	Geo(p)	$P(X = k) = p(1 - p)^{k-1}$ $k=1, 2, \dots$	$\frac{1}{p}$	$\frac{1-p}{p^2}$
Hipergeometriai	Hipgeo(N, M, n)	$P(X = k) = \frac{\binom{M}{k} \binom{N-M}{n-k}}{\binom{N}{n}}$ $k=0, 1, \dots, n$	$n \frac{M}{N}$	$n \frac{M}{N} \left(1 - \frac{M}{N}\right) \left(1 - \frac{n-1}{N-1}\right)$
Binomiális	Bin(n, p)	$P(X = k) = \binom{n}{k} p^k (1 - p)^{n-k}$ $k=0, 1, \dots, n$	$np$	$np(1 - p)$
Negatív binomiális	NegBin(n, p)	$P(X = k) = \binom{k-1}{n-1} p^n (1 - p)^{k-n}$ $k=n, n+1, \dots$	$\frac{n}{p}$	$\frac{n(1-p)}{p^2}$
Poisson	Poi( $\lambda$ )	$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}$ $k=0, 1, \dots$	$\lambda$	$\lambda$

Előfordulásuk:

- Indikátor változó: egy  $p$  valószínűségű esemény bekövetkezik-e vagy sem
- Geometriai: hányadikra következik be először egy  $p$  valószínűségű esemény
- Hipergeometriai: visszatevés nélküli mintavétel
- Binomiális: visszatevéses mintavétel
- Negatív binomiális: hányadikra következik be  $n$ . alkalommal egy  $p$  valószínűségű esemény
- Poisson: ritka események bekövetkezését írja le

**Állítás.** Legyenek  $X, Y, X_1, \dots, X_n$  valószínűségi változók;  $c, c_i, a, b \in \mathbb{R}$ . Ekkor

- $E(X + Y) = EX + EY$ ;
- $E(cX) = cEX$ ;
- $E \sum_{i=1}^n c_i X_i = \sum_{i=1}^n c_i EX_i$ ;
- $D^2(aX + b) = a^2 D^2X$ .

**Definíció. X val.változó eloszlásfüggvénye:**  $F_X(x) = P(X < x)$ .

Amennyiben egyértelmű, melyik val.változó eloszlásfüggvényéről van szó,  $F(x)$ -et írunk.

**Állítás.** Az eloszlásfüggvény tulajdonságai:

- $0 \leq F_X(x) \leq 1$ ;
- monoton növény;
- balról folytonos;
- $\lim_{x \rightarrow -\infty} F(x) = 0, \lim_{x \rightarrow \infty} F(x) = 1$ .

**Állítás.** Tetszőleges  $X$  val.változó esetén

- $P(a \leq X < b) = F(b) - F(a)$ ;
- $P(a < X \leq b) = F(b+) - F(a+)$ .

**Definíció. X val.változó abszolút folytonos**, ha létezik olyan  $f(x)$  függvény, amelyre  $F(x) = \int_{-\infty}^x f(t) dt$ . Ilyenkor  $f(x)$ -et **sűrűségfüggvénynek** hívjuk.

**Állítás.** Legyen  $X$  abszolút folytonos eloszlású. Ekkor

- $f(x) = F'(x)$ ;
- $f(x) \geq 0$ ;
- $\int_{-\infty}^{\infty} f(x) dx = 1$ ;
- $P(X = x) = 0 \quad \forall x\text{-re}$ ;
- $P(a < X \leq b) = P(a \leq X < b) = F(b) - F(a)$ .

Abszolút folytonos val.változó várható értéke:  $EX = \int_{-\infty}^{\infty} xf(x) dx$ .

Abszolút folytonos val.változó  $l$ . momentuma:  $EX^l = \int_{-\infty}^{\infty} x^l f(x) dx$ .

Nevezetes abszolút folytonos eloszlások:

Eloszlás neve	Jelölése	Eloszlásfüggvény	Sűrűségfüggvény	EX	D <sup>2</sup> X
Egyenletes	$E(a, b)$	$\begin{cases} 0 & \text{ha } x \leq a \\ \frac{x-a}{b-a} & \text{ha } a < x \leq b \\ 1 & \text{ha } b < x \end{cases}$	$\begin{cases} \frac{1}{b-a} & \text{ha } a < x \leq b \\ 0 & \text{különben} \end{cases}$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$
Exponenciális	$\text{Exp}(\lambda)$	$\begin{cases} 1 - e^{-\lambda x} & \text{ha } x \geq 0 \\ 0 & \text{különben} \end{cases}$	$\begin{cases} \lambda e^{-\lambda x} & \text{ha } x \geq 0 \\ 0 & \text{különben} \end{cases}$	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$
Standard normális	$N(0, 1^2)$	$\Phi(x) = \dots$	$\frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \quad x \in \mathbb{R}$	0	1
Normális	$N(m, \sigma^2)$	...	$\frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x-m)^2}{2\sigma^2}} \quad x \in \mathbb{R}$	m	$\sigma^2$

### Állítás. Val.változó függvényének várható értéke

Legyen X val. változó;  $g: \mathbb{R} \rightarrow \mathbb{R}$  függvény.

Ekkor

- $E(g(X)) = \sum_k g(x_k)p_k$ , ha X diszkrét
- $E(g(X)) = \int_{-\infty}^{\infty} g(x)f(x) dx$ , ha X abszolút folytonos

Mindkét esetben a várható érték létezéséhez a szumma/integrál abszolút konvergenciájára van szükség.

### Állítás. Abszolút folytonos val.változó szigorúan monoton függvényének eloszlás- és sűrűségfüggvénye

Legyen X abszolút folytonos val. változó;  $g: \mathbb{R} \rightarrow \mathbb{R}$  szigorúan monoton, folytonosan differenciálható függvény. Ekkor

a.)  $Y = g(X)$  eloszlásfüggvénye:

$$F_Y(y) = F_{g(X)}(y) = \begin{cases} F_X(g^{-1}(y)) & \text{ha } g \text{ szig. mon. növe} \\ 1 - F_X(g^{-1}(y)) & \text{ha } g \text{ szig. mon. csökken} \end{cases}$$

b.)  $Y = g(X)$  sűrűségfüggvénye:

$$f_Y(y) = f_{g(X)}(y) = f_X(g^{-1}(y)) \cdot |[g^{-1}(y)]'| = \frac{f_X(g^{-1}(y))}{|g'(g^{-1}(y))|}$$

### Állítás. Normálás

Legyen  $X \sim N(m, \sigma^2)$ . Ekkor  $\frac{X-m}{\sigma} \sim N(0, 1)$ .

Állítás.  $\Phi(-x) = 1 - \Phi(x)$

Állítás.  $\Phi^{-1}(q) = -\Phi^{-1}(1 - q) \quad 0 < q < 1$

**Definíció. Val.változók konvolúciója:** Legyenek X és Y független val.változók. X és Y konvolúciójának (jel.  $X * Y$ ) az  $X + Y$  val.változót nevezzük.

### Állítás. A konvolúció eloszlásának meghatározása

- Diszkrét eset:  $P(X + Y = k) = \sum_{l=0}^{\infty} P(X = l) \cdot P(Y = k - l)$
- Folytonos eset:  $f_{X+Y}(z) = \int_{-\infty}^{\infty} f_X(u)f_Y(z - u)du$

Állítás. Legyenek  $X_1, \dots, X_n, X$  és  $Y$  független val. változók

- $X_1 \sim \text{Ind}(p), \dots, X_n \sim \text{Ind}(p) \Rightarrow X_1 + \dots + X_n \sim \text{Bin}(n, p)$
- $X \sim \text{Bin}(n, p), Y \sim \text{Bin}(m, p) \Rightarrow X + Y \sim \text{Bin}(n + m, p)$
- $X_1 \sim \text{Geo}(p), \dots, X_n \sim \text{Geo}(p) \Rightarrow X_1 + \dots + X_n \sim \text{NegBin}(n, p)$
- $X \sim \text{Poi}(\lambda_1), Y \sim \text{Poi}(\lambda_2) \Rightarrow X + Y \sim \text{Poi}(\lambda_1 + \lambda_2)$
- $X \sim N(m_1, \sigma_1^2), Y \sim N(m_2, \sigma_2^2) \Rightarrow X + Y \sim N(m_1 + m_2, \sigma_1^2 + \sigma_2^2)$

**Definíció. Valószínűségi vektorváltozó:**  $\mathbf{X}: \Omega \rightarrow \mathbb{R}^d$  mérhető függvény, azaz amire  $\{\omega : \mathbf{X}(\omega) \in B\} \in \mathcal{A}$  minden  $B \subseteq \mathbb{R}^d$  nyílt halmazra.

### Definíció. Valószínűségi vektorváltozó eloszlása:

$$Q_{\mathbf{X}}(B) = P(\mathbf{X} \in B) = P(\omega : \mathbf{X}(\omega) \in B)$$

### Definíció. X valószínűségi vektorváltozó eloszlásfüggvénye:

$$F_{\mathbf{X}}(\mathbf{x}) = P(\mathbf{X} < \mathbf{x}) = P(X_1 < x_1, \dots, X_d < x_d).$$

Állítás. Az eloszlásfüggvény tulajdonságai:

- $0 \leq F_{\mathbf{X}}(\mathbf{x}) \leq 1$ ;
- minden koordinátájában monoton növény;
- minden koordinátájában balról folytonos;
- $\lim_{x_1, \dots, x_d \rightarrow \infty} F_{\mathbf{X}}(x_1, \dots, x_d) = 1$ ;
- $\lim_{x_i \rightarrow -\infty} F_{\mathbf{X}}(x_1, \dots, x_d) = 0$  minden  $i$ -re.

**Definíció.**  $\mathbf{X}$  valószínűségi vektorváltozó abszolút folytonos, ha létezik olyan  $f_{\mathbf{X}}(x_1, \dots, x_d)$  függvény, amelyre

$$F_{\mathbf{X}}(x_1, \dots, x_d) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_d} f_{\mathbf{X}}(t_1, \dots, t_d) dt_1 \dots dt_d.$$

Ilyenkor  $f_{\mathbf{X}}(\mathbf{x})$ -et **sűrűségfüggvénynek** hívjuk.

Mostantól  $d = 2$  lesz, és a következő jelöléseket és elnevezéseket használjuk:

- $F_{X,Y}(x, y) = P(X < x, Y < y) \rightsquigarrow$  együttes eloszlásfüggvény
- $F_X(x) = P(X < x)$
- $F_Y(y) = P(Y < y)$   $\rightsquigarrow$  peremeloszlásfüggvények
- $f_{X,Y}(x, y) \rightsquigarrow$  együttes sűrűségfüggvény
- $f_X(x), f_Y(y) \rightsquigarrow$  peremsűrűségfüggvények

**Állítás.**

- $F_X(x) = \lim_{y \rightarrow \infty} F_{X,Y}(x, y)$  és  $F_Y(y) = \lim_{x \rightarrow \infty} F_{X,Y}(x, y)$
- $F_{X,Y}(x, y) = \int_{-\infty}^y \int_{-\infty}^x f_{X,Y}(u, v) dudv$
- $f_{X,Y}(x, y) = \partial_y \partial_x F_{X,Y}(x, y) = \partial_x \partial_y F_{X,Y}(x, y)$
- $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{X,Y}(x, y) dx dy = 1$
- $f_X(x) = \int_{-\infty}^{\infty} f_{X,Y}(x, y) dy$  és  $f_Y(y) = \int_{-\infty}^{\infty} f_{X,Y}(x, y) dx$

**Állítás.**

- $X, Y$  függetlenek  $\Leftrightarrow F_{X,Y}(x, y) = F_X(x) \cdot F_Y(y)$
- $X, Y$  függetlenek  $\Leftrightarrow f_{X,Y}(x, y) = f_X(x) \cdot f_Y(y)$
- $X, Y$  függetlenek  $\Leftrightarrow P(X = x, Y = y) = P(X = x) \cdot P(Y = y)$
- $X, Y$  függetlenek  $\Rightarrow E(XY) = EX \cdot EY$

**Definíció.**  $X$  és  $Y$  kovarianciája:  $\text{Cov}(X, Y) = E[(X - EX)(Y - EY)]$ .

Köv.:  $\text{Cov}(X, Y) = E(XY) - EXEY$ .

Elnevezés: ha  $\text{Cov}(X, Y) = 0$ , akkor azt mondjuk, hogy  $X$  és  $Y$  **korrelálatlanok**.

**Állítás.**

- Ha  $X$  és  $Y$  függetlenek egymástól, akkor korrelálatlanok is.
- Ha  $X$  és  $Y$  korrelálatlanok, akkor ebből **nem** következik, hogy függetlenek is!!!!

**Állítás. A kovariancia tulajdonságai:**

Legyenek  $X, Y, X_1, \dots, X_n$  valószínűségi változók,  $a, b \in \mathbb{R}$ . Ekkor

- $\text{Cov}(X, X) = D^2 X$
- $\text{Cov}(X, Y) = \text{Cov}(Y, X)$
- $\text{Cov}(X, a) = 0$
- $\text{Cov}(aX, bY) = ab \text{Cov}(X, Y)$
- $D^2(X + Y) = D^2 X + D^2 Y + 2 \text{Cov}(X, Y)$
- $D^2(\sum_{i=1}^n X_i) = \sum_{i=1}^n D^2 X_i + 2 \sum_{1 \leq i < j \leq n} \text{Cov}(X_i, X_j)$
- $X, Y$  függetlenek  $\Rightarrow \text{Cov}(X, Y) = 0$

**Definíció.**  $X$  és  $Y$  korrelációja:  $R(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{D^2 X D^2 Y}}$ .

A korreláció két valószínűségi változó lineáris kapcsolatát méri:

- $R > 0 \Rightarrow$  pozitív a kapcsolat
- $R < 0 \Rightarrow$  negatív a kapcsolat
- $R^2 \sim 1 \Rightarrow$  erős a kapcsolat
- $R^2 \sim 0.5 \Rightarrow$  közepes a kapcsolat
- $R^2 \sim 0 \Rightarrow$  gyenge a kapcsolat

**Tétel. Markov-egyenlőtlenség:** Legyen  $g : \mathbb{R} \rightarrow \mathbb{R}$  monoton növény függvény,  $X \geq 0$  val.változó,  $\varepsilon > 0$  tetsz.

Ekkor  $P(X \geq \varepsilon) \leq \frac{E[g(X)]}{g(\varepsilon)}$ .

Spec., ha  $g(x) = x \Rightarrow P(X \geq \varepsilon) \leq \frac{E(X)}{\varepsilon}$

**Tétel. Csebisev-egyenlőtlenség:**  $P(|X - EX| \geq \varepsilon) \leq \frac{D^2(X)}{\varepsilon^2}$ .

Legyen  $X_1, X_2, \dots$  valószínűségi változók sorozata.

**Definíció. 1 valószínűségű konvergencia:**

$X_n \xrightarrow{n \rightarrow \infty} X$  1 valószínűséggel, ha  $P(\{\omega : X_n(\omega) \xrightarrow{n \rightarrow \infty} X(\omega)\}) = 1$ .

**Definíció. Gyenge konvergencia:**  $X_n \xrightarrow{n \rightarrow \infty} X$  gyengén, ha az eloszlásfüggvényeikre  $F_n(x) \xrightarrow{n \rightarrow \infty} F(x)$   $F$  minden folytonossági pontjában.

**Tétel. Nagy számok törvénye (NSZT):**

Legyenek  $X_1, X_2, \dots$  i.i.d. val. változók,  $EX_1 = m < \infty$ .

Ekkor  $\frac{X_1 + \dots + X_n}{n} \xrightarrow{n \rightarrow \infty} m$  1 valószínűséggel.

**Tétel. Centrális határeloszlás tétel (CHT):**

Legyenek  $X_1, X_2, \dots$  i.i.d. val. változók,  $EX_1 = m, D^2(X_1) = \sigma^2 < \infty$ .

Ekkor  $\frac{X_1 + \dots + X_n - nm}{\sqrt{n}\sigma} \xrightarrow{n \rightarrow \infty} N(0,1)$  gyengén, azaz  $P\left(\frac{X_1 + \dots + X_n - nm}{\sqrt{n}\sigma} < x\right) \xrightarrow{n \rightarrow \infty} \Phi(x)$ .

**Minta:**  $X_1, \dots, X_n$  valószínűségi változó sorozat. Jel.  $\mathbf{X} = (X_1, \dots, X_n)$

A továbbiakban feltesszük, hogy függetlenek és azonos eloszlásúak. Magyarosan rövidítve FAE minta, de gyakrabban használják az angol *i.i.d. minta* rövidítést (independent, identically distributed).

Az elméleti értékeket nagy, a konkrét, realizált mintából számolt értékeket mindig kis betű fogja jelölni, azaz minta esetén  $x_1, \dots, x_n$ .

**Statisztika:** a minta valamely függvénye:  $T : \mathbf{X} \rightarrow \dots$

**Becslés:** a minta eloszlásának ismeretlen paraméterét közelíti a minta segítségével

Megj.: Minden becslés statisztika.

Néhány lényeges statisztika:

- **Rendezett minta:**  $X_1^* \leq \dots \leq X_n^*$  nem csökkenő sorrendbe tesszük a mintaelemeket

- **Mintaátlag:**  $\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$

- **Tapasztalati szórás:**  $S_n = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}}$

Értelmezése: az átlagtól való átlagos eltérés abszolút mértékegységben

- **Korrigált tapasztalati szórás:**  $S_n^* = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}}$

- **Szórási együttható:**  $V = \frac{S_n}{\bar{X}}$

Értelmezése: az átlagtól való átlagos eltérés százalékban

Megj.: relatív szórásnak is hívják

- **Tapasztalati eloszlásfüggvény:**  $F_n(x) = \frac{\sum_{i=1}^n I(X_i < x)}{n}$

ahol  $I(X_i < x) = \begin{cases} 1 & \text{ha } X_i < x \\ 0 & \text{ha } X_i \geq x \end{cases} \rightsquigarrow$  karakterisztikus függvény

- **z-quantilis:**  $q_z = \inf\{x : F(x) \geq z\}$ , és amennyiben F invertálható, akkor  $q_z = F^{-1}(z)$ -re egyszerűsödik

Értelmezése: a mintaelemek z-ed része  $q_z$ -nél kisebb,  $(1 - z)$ -ed része  $q_z$ -nél nagyobb

Realizált mintából sokféleképpen számolható, interpolációs módszer:

1.) Sorszám megállapítása:  $(n + 1)z = e + t$  (e:egészrész, t:tötrész)

2.)  $q_z = X_e^* + t(X_{e+1}^* - X_e^*)$

- **kvartilisek:** speciális kvartilisek
  - $Q_1 := q_{\frac{1}{4}} \rightsquigarrow$  alsó kvartilis
  - $Q_2 = Me := q_{\frac{1}{2}} \rightsquigarrow$  medián (középső mintaelem)
  - $Q_3 := q_{\frac{3}{4}} \rightsquigarrow$  felső kvartilis

**Állítás.** Az  $F_n(x) = \sum_{i=1}^n \frac{I(X_i < x)}{n}$  tapasztalati eloszlásfüggvény 1 valószínűséggel tart a (valódi)  $F(x)$  eloszlásfüggvényhez.

**Definíció. Torzítatlan becslés:**

$T(\mathbf{X})$  statisztika torzítatlan becslése  $\theta$ -nak, ha  $E_\theta T(\mathbf{X}) = \theta \quad \forall \theta$ -ra.

**Definíció. Likelihood függvény:** Legyen  $\mathbf{X} = (X_1, \dots, X_n)$  i.i.d. minta

- $L(\theta, \mathbf{x}) = f_\theta(\mathbf{x}) = \prod_{i=1}^n f_\theta(x_i)$ , ha az eloszlás folytonos

- $L(\theta, \mathbf{x}) = P_\theta(\mathbf{X} = \mathbf{x}) = \prod_{i=1}^n P_\theta(X_i = x_i)$ , ha az eloszlás diszkrét.

**Definíció. Log-likelihood függvény:**  $l(\theta, \mathbf{x}) = \log(L(\theta, \mathbf{x}))$ .

**Paraméterbecslési módszerek**

- **Maximum likelihood módszer (ML-módszer):** Azt a paraméterértéket keressük, ahol a likelihood függvény a legnagyobb értéket veszi fel:  $\max_{\theta} L(\theta, \mathbf{x})$

Amennyiben a függvény deriválható  $\theta$  szerint, akkor a maximumot kereshetjük a szokásos módon, az első és második deriváltak segítségével, azonban a feladatunkat jelentősen megnehezíti, hogy olyan n-szeres szorzatot kellene deriválni, amelyiknek minden tagjában ott van az

a változó, ami szerint deriválnunk kellene. Ezért likelihood függvény helyett a log-likelihood függvény maximumhelyét keressük.

Ha  $\theta$  1 dimenziós, akkor az

- elsőrendű feltétel:  $\partial_{\theta} l(\theta, \mathbf{x}) = 0 \rightsquigarrow \hat{\theta}$
- másodrendű feltétel:  $\partial_{\theta}^2 l(\theta, \mathbf{x}) < 0$

Ha  $\theta$   $p$  dimenziós, akkor  $\theta = (\theta_1, \dots, \theta_p)$ , az

- elsőrendű feltétel:  $\partial_{\theta_i} l(\theta, \mathbf{x}) = 0 \rightsquigarrow \hat{\theta}_i \ (i = 1, \dots, p) \rightsquigarrow \hat{\theta} = (\hat{\theta}_1, \dots, \hat{\theta}_p)$
- másodrendű feltétel:  $H(\theta_1, \dots, \theta_p) = (\partial_{\theta_i} \partial_{\theta_j} l(\theta, \mathbf{x}))_{i,j=1,\dots,p}$  Hesse-mátrix negatív definit a  $\theta = \hat{\theta}$  helyen

- **Momentum módszer:** A mintából számítható tapasztalati momentumokat ( $m_i := \frac{\sum_j x_j^i}{n}$ ) egyenlővé tesszük az elméleti momentumokkal ( $M_i := E_{\theta} X^i$ ), az elsőtől kezdve, mégpedig annyit, amennyi paraméter van. Tehát  $p$  darab ismeretlen paraméter esetén a következő  $p$  ismeretlenes egyenletrendszer oldjuk meg:

$$\begin{aligned} M_1 &= m_1 \\ &\vdots \\ M_p &= m_p \end{aligned}$$

Megjegyzés:  $m_1 = \bar{x}$

**Fisher-tétel:** Ha  $\theta$  ML-beclése  $\hat{\theta}$ , akkor tetszőleges  $g$  függvény esetén  $g(\theta)$  ML-beclése  $g(\hat{\theta})$ .

**Definíció.  $\chi^2$ -eloszlás:** Az  $X$  valószínűségi változó  $n$  szabadságfokú  $\chi^2$ -eloszlást követ (jel.:  $X \sim \chi_n^2$ ), ha  $X = U_1^2 + \dots + U_n^2$ , ahol  $U_i \sim N(0, 1)$  minden  $i$ -re és függetlenek egymástól.

**Definíció. t-eloszlás:** Az  $X$  valószínűségi változó  $n$  szabadságfokú Student-féle t-eloszlást követ (jel.:  $X \sim t_n$ ), ha  $X = \frac{Z}{\sqrt{\frac{Y_n}{n}}}$ , ahol  $Z \sim N(0, 1)$  és

$Y_n \sim \chi_n^2$  függetlenek egymástól.

Mostantól  $\alpha$  egy 0-hoz közeli pozitív szám lesz (például  $0.05 = 5\%$ ), és vezessük be a következő jelöléseket:

- $u_{\alpha}$ :  $N(0, 1)$  eloszlás  $(1 - \alpha)$ -kvantilise, azaz  $u_{\alpha} = \Phi^{-1}(1 - \alpha)$
- $z_{\alpha} := u_{1-\alpha}$  (sok könyvben ezt használják)
- $t_{n,\alpha}$ :  $n$  szabadságfokú t-eloszlás  $(1 - \alpha)$ -kvantilise
- $\chi_{n,\alpha}^2$ :  $n$  szabadságfokú  $\chi^2$ -eloszlás  $\alpha$ -kvantilise

**Definíció. Konfidencia intervallum:** Adott  $\alpha$ -hoz legalább  $(1 - \alpha)$  valószínűséggel tartalmazza az adott paramétert (vagy annak egy függvényét):  $P_{\theta} (T_1(\mathbf{X}) < \hat{\theta} < T_2(\mathbf{X})) \geq 1 - \alpha$ .

Gyakran keresünk szimmetrikus konfidencia intervallumot, ilyenkor  $T_1 = T_2 =: \Delta$ , és az intervallum  $\hat{\theta} \pm \Delta$  alakba írható.

Legyen  $X_1, \dots, X_n \sim N(m, \sigma)$  i.i.d. minta

- $m$ -re konfidencia intervallum
  - ha  $\sigma$  ismert, akkor  $\bar{x} \pm u_{\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}$
  - ha  $\sigma$  ismeretlen, akkor  $\bar{x} \pm t_{n-1, \frac{\alpha}{2}} \frac{s_n^*}{\sqrt{n}}$
- $\sigma^2$ -re konfidencia intervallum:  $\left[ \frac{(n-1) \cdot (s_n^*)^2}{\chi_{n-1, 1-\frac{\alpha}{2}}^2}, \frac{(n-1) \cdot (s_n^*)^2}{\chi_{n-1, \frac{\alpha}{2}}^2} \right]$

Konfidencia intervallum a valószínűsége ( $p$ ) nagy minta esetén, ha normális eloszlással közelítünk:  $\hat{p} \pm u_{\frac{\alpha}{2}} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$ .

Hipotézis  $\sim$  valami állítás, aminek igazságát vizsgálni szeretnénk

Paramétertér:  $\Theta = \Theta_0 \cup^* \Theta_1 \rightarrow$  "valóság"

Mintatér:  $\mathcal{X} = \mathcal{X}_e \cup^* \mathcal{X}_k \rightarrow$  "látszat" - MINTÁBÓL

$\mathcal{X}_k$ : kritikus tartomány - azon  $\mathbf{X}$  megfigyelések halmaza, amikre *elutasítjuk* a nullhipotézist

$\mathcal{X}_e$ : elfogadási tartomány - azon  $\mathbf{X}$  megfigyelések halmaza, amikre *elfogadjuk* a nullhipotézist

**Hipotézisvizsgálati feladat:**

$H_0 : \theta \in \Theta_0 \rightsquigarrow$  nullhipotézis

$H_1 : \theta \in \Theta_1 \rightsquigarrow$  ellenhipotézis

Tehát ha  $\mathbf{X} \in \mathcal{X}_e$ , akkor elfogadjuk  $H_0$ -t; ha  $\mathbf{X} \in \mathcal{X}_k$ , akkor pedig elutasítjuk  $H_0$ -t.

Amennyiben a  $\Theta_0$  halmaz egyelemű, akkor azt mondjuk, hogy  $H_0$  egyszerű.  $H_1$ -re ugyanígy.

Az  $\mathcal{X}$  mintatér felosztását általában egy statisztika (neve: próbastatisztika) segítségével végezzük el:

$$\text{legyen } T: \mathcal{X} \rightarrow \mathbb{R}, \quad \mathcal{X}_k = \{\underline{x} \in \mathcal{X} : T(\underline{x}) > c\} \quad c \text{ neve: kritikus érték}$$

$$\mathcal{X}_e = \{\underline{x} \in \mathcal{X} : T(\underline{x}) \leq c\}$$

"valóság"	döntés	$H_0$ -t	
		elfogadjuk ( $\mathcal{X}_e$ )	elutasítjuk ( $\mathcal{X}_k$ )
$H_0$ teljesül ( $\Theta_0$ )	helyes döntés	elsőfajú hiba	
$H_0$ nem teljesül ( $\Theta_1$ )	másodfajú hiba	helyes döntés	

$P(\text{elsőfajú hiba}) = \alpha(\theta) = P_\theta(\mathcal{X}_k)$ , ahol  $\theta \in \Theta_0$

$P(\text{másodfajú hiba}) = \beta(\theta) = P_\theta(\mathcal{X}_e)$ , ahol  $\theta \in \Theta_1$

**Erőfüggvény:**  $\psi: \Theta_1 \rightarrow \mathbb{R}, \psi(\theta) = P_\theta(\mathcal{X}_k)$

**Terjedelem:**  $\alpha = \sup \{ \alpha(\theta) : \theta \in \Theta_0 \}$

**p-érték:** az az  $\alpha$  terjedelem, ami esetén a próbastatisztika értéke egyenlő a kritikus értékkel:  $T(\mathbf{x}) = c_\alpha$ .

A p-érték a legkisebb terjedelem, amire még elutasítjuk a  $H_0$ -t. Ha egy próbát számítógép segítségével végzünk el, rendszerint a p-érték révén tudunk dönteni: ha  $(p\text{-érték}) < \alpha$ , akkor elvetjük  $H_0$ -t.

Néhány konkrét próba – az  $\alpha$  végig a próba terjedelmét jelöli, ami előre adott

### 1.) Egymintás próbák

#### a.) Egymintás u-próba

$X_1, \dots, X_n \sim N(m, \sigma^2)$ , ahol  $\sigma$  ismert,  $m$  paraméter

- a.)  $H_0 : m = m_0$       b.)  $H_0 : m = m_0$       c.)  $H_0 : m = m_0$   
 $H_1 : m \neq m_0$        $H_1 : m > m_0$        $H_1 : m < m_0$

A próbastatisztika:  $T(\mathbf{X}) = u = \sqrt{n} \frac{\bar{X} - m_0}{\sigma} \stackrel{H_0 \text{ esetén}}{\sim} N(0, 1)$

A kritikus tartományok:

- a.)  $\mathcal{X}_k = \{ \mathbf{x} : |u| > u_{\alpha/2} \}$   
b.)  $\mathcal{X}_k = \{ \mathbf{x} : u > u_\alpha \}$   
c.)  $\mathcal{X}_k = \{ \mathbf{x} : u < -u_\alpha \}$

#### b.) Egymintás t-próba

$X_1, \dots, X_n \sim N(m, \sigma^2)$ , ahol  $\sigma, m$  paraméter

- a.)  $H_0 : m = m_0$       b.)  $H_0 : m = m_0$       c.)  $H_0 : m = m_0$   
 $H_1 : m \neq m_0$        $H_1 : m > m_0$        $H_1 : m < m_0$

A próbastatisztika:  $T(\mathbf{X}) = t = \sqrt{n} \frac{\bar{X} - m_0}{s_n^*} \stackrel{H_0 \text{ esetén}}{\sim} t_{n-1}$

A kritikus tartományok:

- a.)  $\mathcal{X}_k = \{ \mathbf{x} : |t| > t_{n-1, \alpha/2} \}$   
b.)  $\mathcal{X}_k = \{ \mathbf{x} : t > t_{n-1, \alpha} \}$   
c.)  $\mathcal{X}_k = \{ \mathbf{x} : t < -t_{n-1, \alpha} \}$

### 3.) $\chi^2$ -próbák

#### a.) Diszkrét illeszkedésvizsgálat

Feladat: adott egy  $\mathbf{X} = (X_1, \dots, X_n)$   $n$  elemű minta, és azt akarjuk eldönteni, hogy a minta egy általunk "remélt" eloszlásból származik-e. *Diszkrét illeszkedésvizsgálat*nál feltesszük, hogy a mintaelemek  $r$  különböző értéket vehetnek fel:  $P(X_i = x_j) = p_j \quad j = 1, \dots, r$ . Jelöljük  $N_j$ -vel a gyakoriságot, azaz azt, hogy az  $n$  elemű mintában hány darab  $x_j$  szerepel.

Osztályok	1	2	...	r	Összesen
Valószínűségek	$p_1$	$p_2$	...	$p_r$	1
Gyakoriságok	$N_1$	$N_2$	...	$N_r$	n

$H_0$ : a valószínűségek:  $\mathbf{p} = (p_1, \dots, p_r)$

$H_1$ : nem ezek a valószínűségek

A próbastatisztika:  $T_n = \sum_{i=1}^r \frac{(N_i - np_i)^2}{np_i} \stackrel{H_0 \text{ esetén}}{\rightarrow} \chi_{r-1}^2$  eloszlásban, ha  $n \rightarrow \infty$

A kritikus tartomány:  $\mathcal{X}_k = \{ \mathbf{x} : T_n(\mathbf{x}) > \chi_{r-1, 1-\alpha}^2 \}$

*Becsléses illeszkedésvizsgálat:* csak annyit "sejtünk", hogy a minta valamilyen eloszlású, viszont a paramétereiről nincs sejtésünk. Ilyenkor amennyiben ML-módszerrel becsüljük meg az  $s$  darab ismeretlen paramétert, akkor a próbastatisztika:  $T_n \stackrel{H_0 \text{ esetén}}{\rightarrow} \chi_{r-1-s}^2$  eloszlásban, ha  $n \rightarrow \infty$ .

#### b.) Függetlenségvizsgálat

Feladat: van egy minta, két szempont szerint csoportosítva. Azt kell eldönteni, hogy a két szempont független-e egymástól.

$p_{i,j} = P(\text{egy megfigyelés az (i,j) osztályba kerül})$

$N_{i,j}$  = ennyi megfigyelés kerül az (i,j) osztályba

A mintavétel eredménye:

		2. szempont					
		1	...	j	...	s	Összesen
1. szempont	1	$N_{11}$	...	$N_{1j}$	...	$N_{1s}$	$N_{1\bullet}$
	⋮	⋮		⋮		⋮	⋮
	i	$N_{i1}$	...	$N_{ij}$	...	$N_{is}$	$N_{i\bullet}$
	⋮	⋮		⋮		⋮	⋮
	r	$N_{r1}$	...	$N_{rj}$	...	$N_{rs}$	$N_{r\bullet}$
	Összesen	$N_{\bullet 1}$	...	$N_{\bullet j}$	...	$N_{\bullet s}$	$n$

$$N_{i\bullet} = \sum_{j=1}^s N_{i,j}$$

$$N_{\bullet j} = \sum_{i=1}^r N_{i,j}$$

$H_0$ : a szempontok függetlenek, azaz  $p_{i,j} = p_{i\bullet} \cdot p_{\bullet j} \quad \forall i, j$ -re

$H_1$ : nem azok

A próbastatisztika:  $T_n = n \left( \sum_{i=1}^r \sum_{j=1}^s \frac{N_{i,j}^2}{N_{i\bullet} N_{\bullet j}} - 1 \right) \xrightarrow{H_0 \text{ esetén}} \chi_{(r-1)(s-1)}^2$  eloszlásban, ha  $n \rightarrow \infty$

A kritikus tartomány:  $\mathcal{X}_k = \{ \mathbf{x} : T_n(\underline{x}) > \chi_{(r-1)(s-1), 1-\alpha}^2 \}$

Feladat:  $Y$  val. változót szeretnénk közelíteni  $X$  val. változó lineáris függvénye segítségével:

$$E[Y - (aX + b)]^2 \rightarrow \min_{a,b} \rightsquigarrow \text{Megoldása: } \begin{aligned} a_{opt} &= \frac{Cov(X,Y)}{D^2(X)} \\ b_{opt} &= EY - a_{opt}EX \end{aligned}$$

Feladat (lineáris modell): Adottak  $(x_1, y_1), \dots, (x_n, y_n)$  pontok, ezekre szeretnénk egyenest illeszteni (neve: *regressziós egyenes*) legkisebb négyzetek módszerével.

A modell:  $Y_i = aX_i + b + \varepsilon_i$ , ahol  $E\varepsilon_i = 0$  és  $D^2\varepsilon_i = \sigma^2 < \infty \quad (i = 1, \dots, n)$

Megoldás:  $\hat{a} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sum(x_i - \bar{x})^2}$ ,  $\hat{b} = \bar{y} - \hat{a}\bar{x}$

Reziduumok:  $\hat{\varepsilon}_i = y_i - \hat{a}x_i - \hat{b} \quad (i=1, \dots, n)$

Reziduális négyzetösszeg:  $RN\ddot{O} = \sum \hat{\varepsilon}_i^2 = \sum (y_i - \bar{y})^2 - \frac{\sum(x_i - \bar{x})(y_i - \bar{y})^2}{\sum(x_i - \bar{x})^2}$

$$\hat{\sigma}^2 = \frac{RN\ddot{O}}{n-2}$$