

Def. Statistikai művő: (Ω, A, P) , ahol (Ω, A) néhány tér, P valószínű előfordulásai epp szabályja, gyakran $P = \{P_\theta : \theta \in \Theta\}$, ahol Θ a paramétertér, és $\theta_1 \neq \theta_2 \Rightarrow P_{\theta_1} \neq P_{\theta_2}$ (identifikálhatóság).

Cél: meghatározni az "igazi" előfordulást, ill. a hozzá tartozó paramétert, ezteg valamelyen fünyét.

Def. Statistikai minta: $X: (\Omega, A) \rightarrow (\mathbb{X}, \mathcal{B})$ val. változó

→ spec. eset: $X = (X_1, \dots, X_n)$, ahol X_i fülelőn általános el. v.v.

Ezben X n elemű (független) minta.

Ez tipikus: elvégzett egy részletek n-szer (mintavétel),
és ebből szereznék következtetést.

De nem csak ilyen létezik, pl. szöv. poligonizáció.

Legyen $Q_\theta = P_\theta \circ X^{-1}$ az X előfordulása $(\mathbb{X}, \mathcal{B})$ -n, ha a paraméter epp θ . Ezzel $(\mathbb{X}, \mathcal{B}, Q = \{Q_\theta : \theta \in \Theta\})$ is stat. művő.

$(\mathbb{X}, \mathcal{B})$ neve a mintatér. → Ennek alapján osz a Q_θ előfordulásra lehet kör.

A hosszúban leírt stat. művő dolgának.

Def. Statistikai: $T: (\mathbb{X}, \mathcal{B}) \rightarrow (\mathbb{Y}, \mathcal{C})$, a minta epp függvénye

Gyakran a $T(X) = T \circ X: (\Omega \rightarrow \mathbb{Y})$ fr.-t nevezik statistikaiak.

A rötfelé értelmezés nem orosz felirattal.

$Q(B) = P(X \in B)$. A mintavételt n-szer megismétlik:

n elemű fülelő mintát kapunk: X_1, \dots, X_n

A relatív gyakoriság közelítést ad:

$$Q_n^*(B) = \frac{1}{n} \sum_{i=1}^n I(X_i \in B)$$

NSEZET: $Q_n^*(B) \rightarrow Q(B)$ 1 val.

CHT: $\sqrt{n}(Q_n^*(B) - Q(B)) \xrightarrow{d} N(0, P(B) \cdot (1 - P(B)))$,

ahol \xrightarrow{d} az előfordulási konvergencia, N pedig szórásnagybetűvel

(és nem minden) paraméteresett, azaz a konvergencia végtelenre.

$B \ni x \mapsto Q_n^*(B)$ valóban val. mérte, neve tapasztalati eloszlás.

A tap. es. eloszlási: $\frac{1}{n}$ szuperát tesz az eggyel x_1, \dots, x_n megfigyelésére.

Formálisan: $Q_n^* = \frac{1}{n} \sum_{i=1}^n \delta_{x_i}$, ahol δ_x a c-re koncentrált eloszlást elnevez (Dirac-mérte)

Legyen φ az eloszlásokon értelmezett függetlenségi függvény.

Beműködik meretnövek a $\varphi(Q)$, értékét.

Ha φ értelmezhető a Q_n^* tapasztalati eloszláson, akkor

$\varphi(Q)$ tapasztalati becslése $\hat{\varphi}(x) = \varphi(Q_n^*)$

Példa: Egy - vagy többdimenziós eloszlásor (Boreleken)
 φ : vállalat értéke

Tap. becslés: $\varphi(Q_n^*) = \frac{x_1 + \dots + x_n}{n} = \bar{x}$ mintatátlag.

Példa: 1-dim., φ : störzsöképpet.

Tap. becslés: $s_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 =$

tap.
störzsöképpet $= \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2$

Ez minden es. -ra igaz öf., esetleg tap. es. -re is, ezért nem kell rölkön bizonyítan.

Megj. Konvákt tap. störzsöképpet: $s_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{n}{n-1} s_n^2$,
ez ugyanis konzisztens, mégis s_n^2 nem. (majd)

Példa: Többszörmében a Kovarianciamátrix:

$S_n = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^T$, tap. Kovarianciamátrix.

ahol x_1, \dots, x_n k-dim. vektörök, S_n 2×2 -as

Példa: Legyen $\underline{x} = (x_1, \dots, x_n)$ n elemű állapot valós értékközönsége.

$\underline{x} \rightarrow \underline{x}^* = (x_1^*, \dots, x_n^*)$ rendszerei között: $x_1^* \leq \dots \leq x_n^*$.

Ez is egy statisztikát ad.

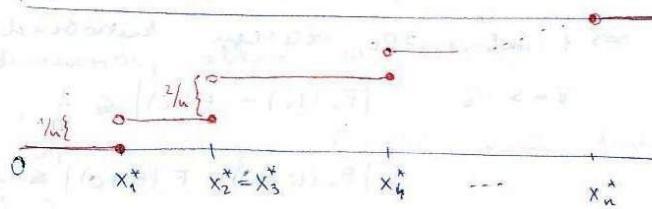
A tap. es. tulajdonság \underline{x}^* fréncse: $Q_n^*(B) = \frac{1}{n} \sum_{i=1}^n I(x_i \in B) = \frac{1}{n} \sum_{i=1}^n I(x_i^* \in B)$

Jog vicces az euclidiátorozás miatt nem az es. frencse!

Példa: φ az esetf. : $Q(Q) = F(\cdot)$, $F(t) = P(X_i < t) = Q((-\infty, t))$

$$\text{Tap. esetf. : } F_n(t) = Q_n^*((-\infty, t)) = \frac{1}{n} \sum_{i=1}^n I(X_i^* < t)$$

Ez lépésű:



$$F_n(t) = \begin{cases} 0 & t \leq x_1^* \\ \frac{i}{n} & x_i^* \leq t \leq x_{i+1}^*, \quad i = 1, 2, \dots, n-1 \\ 1 & x_n^* < t \end{cases}$$

(Ez sűrűségfömpje nem megys: a tap. eo. dissz. nélk., és ezért mincs szüksége.)

Vt: $F_n(t) \rightarrow F(t)$ 1 val. (az a 0-mértekkal megegyező t-függő).

Szóval, az erősebb is nem nyilvánvaló, hogy

F_n mindenkorant tart 1 val.: 1 val. $\forall t \quad F_n(t) \rightarrow F(t)$.

Giliviro-Cantelli-tétel (A statisztika alapfeléle)

$$\Delta_n := \sup_t |F_n(t) - F(t)|.$$

Erre a $\Delta_n \rightarrow 0$ 1 val. azaz a tap. esetf. 1 val. tart az igazit.

Megy: Ez azt tükrízi, hogy a vélyeg meghismerhető: elég több meghívással a jelenség leírható; ténylegesen közel lehet benne a meghismerésből.

Megy: Δ_n val. változó: a belfolytatosság miatt $\Delta_n = \sup_{t \in Q} |F_n(t) - F(t)|$.

B: Legyen $\varepsilon > 0$.

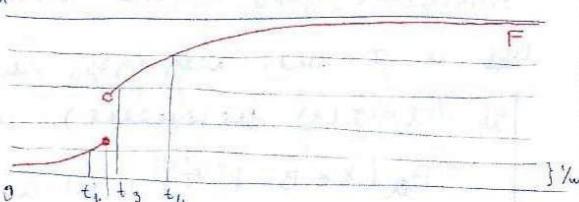
Legyen $m > \frac{\varepsilon}{2}$, és osszuk

$[0, 1]$ -et m részre.

$$t_1 \leq \dots \leq t_{m-1}: F(t_i) \leq \frac{i}{m} \leq F(t_{i+1})$$

Ilyenek léteznek, pl.

$$t_i := \sup \left\{ t : F(t) \leq \frac{i}{m} \right\} = \max \left\{ t : F(t) \leq \frac{i}{m} \right\}$$



NSZET: $F_n(t_i) \rightarrow F(t_i)$ 1 val. $\forall i = 1, \dots, m-1$

$$F_n(t_i) = Q_n^*((-\infty, t_i]) \rightarrow Q((-\infty, t_i]) = F(t_i + 0)$$

Ez véges szövés \Rightarrow 1 val. ilyenkor teljesül.

\Rightarrow 1 val. $\exists n_0$ véletlen rövidítések, ilyen

$$\forall n > n_0 : |F_n(t_i) - F(t_i)| \leq \frac{1}{m},$$

$$|F_n(t_i + 0) - F(t_i + 0)| \leq \frac{1}{m} \quad \forall i = 1, \dots, m-1$$

Ezen az m eseményen, ha $n > n_0$:

$$\bullet \text{ legyen } t_i < t \leq t_{i+1} \Rightarrow F_n(t) - F(t) \leq F_n(t_{i+1}) - F(t_i) \leq$$

$$\leq F(t_{i+1}) + \frac{1}{m} - F(t_i + 0) \leq \frac{i+1}{m} + \frac{1}{m} - \frac{i}{m} = \frac{2}{m} < \epsilon$$

$$\text{Analóg módon: } F(t) - F_n(t) \leq F(t_{i+1}) - F_n(t_i + 0) \leq$$

$$\leq F(t_{i+1}) - F(t_i + 0) + \frac{1}{m} \leq \frac{i+1}{m} - \frac{i}{m} + \frac{1}{m} = \frac{2}{m} < \epsilon$$

$$\bullet \text{ ha } t \leq t_1: F_n(t) - F(t) \leq F_n(t_1) \leq F(t_1) + \frac{1}{m} \leq \frac{2}{m} < \epsilon$$

$$F(t) - F_n(t) \leq F(t_1) \leq \frac{1}{m} < \frac{2}{m} < \epsilon$$

$$\bullet \text{ ha } t > t_{m-1}: F_n(t) - F(t) \leq 1 - F(t_{m-1} + 0) \leq 1 - \frac{m-1}{m} = \frac{1}{m} < \epsilon$$
$$F(t) - F_n(t) \leq 1 - F_n(t_{m-1} + 0) \leq 1 - F(t_{m-1} + 0) + \frac{1}{m} \leq$$
$$\leq \frac{2}{m} < \epsilon.$$

$$\Rightarrow \Delta_n \leq \frac{2}{m} < \epsilon.$$

A tételes igaz magasabb dimenzióban is, a bizonyítás megy át.

$$\sup_B |Q_n^*(B) - Q(B)| \text{ -vel eléri a minimumot?}$$

Legyen minden B -re nézve; minden részben meg a 0-nál kisebb.

Elegségesség.

Amikor nem, legy a stat. minden értékét tartalmazzon.

Def. A T stat. elegséges, ha az X minden felt. eloszlája

($T = T(X)$ feltételek) minden függő θ -ról.

$P_{\theta}(X \in B \mid T)$ felülről: az átlagos jelzi, hogy általában van θ -függés, de itt nincs.

Ebben a definícióban a reguláris feltételek elosztást értjük, ez $Q(B, w)$ független, ha: $B \mapsto Q(B, w)$ val elosztás és $\forall B: Q(B, \cdot)$ feltételek valóságai $\{x \in B\}$ -nél.

Def: ha X véges dimenziós, akkor ez leterzi.

A def ugy értendő, hogy \exists ilyen, θ -re nem függő vértető, és nem egyszerű.

$$\text{Reguláritás} \Rightarrow E_{\theta}(s(x)) = \int_{\mathbb{R}} s(x) Q_{\theta}(dx, \cdot)$$

Hl. T elégsges (X, B, P) -n és $P' \subset P \Rightarrow T$ elégsges (X, B, P') -n is.

Hl: Legyen $X = \mathbb{R}^n$, $B = \text{Borel}$, $P = \{P \times \dots \times P, P \text{ n-dim. val. es.}\}$ (n elemű minden összes lehetséges elosztása).

Ellor az $X^* = (x_1^*, \dots, x_n^*)$ rendesített minden elégsges.

B: Legyen $\pi \in S_n$ permutáció, és jelölje $\pi: \mathbb{R}^n \rightarrow \mathbb{R}^n$ $x = (x_1, \dots, x_n) \mapsto \pi x = (x_{\pi(1)}, \dots, x_{\pi(n)})$ transzformációt.

Ez a transzformációt alkotja, $z \in \mathbb{R}^n$ orbitja $\langle z \rangle = \{\pi z \mid \pi \in S_n\}$

A $\sigma z: \sigma \in S_n$ feszültsében $\langle z \rangle$ minden eleme ugyanannyira rendel (ez a más attól függ, hogy z -nél mely minden koordinátája van). Ha ha $z_1, z_2 \in \langle z \rangle$, akkor $\exists \tau \in S_n$, hogy $z_2 = \tau z_1$, mert az orbitok particionálhatóak. Ezért $\sigma z = z_1 \Leftrightarrow \tau \sigma z = z_2$, tehát a z -t z_1 -be ill. z_2 -be ugyanaz a feszültsében $\sigma \leftrightarrow \tau \sigma$ megfeleltetés.

Számítsuk ki $E(f(x) \mid X^* = z)$ -t! Rendeljünk minden esetben P -funkciót.

$$\begin{aligned} \int_{\{X^* \in B\}} f(x) dP &= \int_{\substack{\{(\sigma x)^* \in B\} \\ X^* \stackrel{\text{def}}{=} \sigma X \\ (\text{arányos es.})}} f(\sigma x) dP = \int_{\{X^* \in B\}} f(\sigma x) dP \quad \forall \sigma \\ &\quad \text{(mindegy, hogy permutációjának minden lehetséges rendezése)} \\ &\stackrel{\text{összegzés}}{=} \int_{\{X^* \in B\}} \frac{1}{n!} \sum_{\sigma} f(\sigma x) dP = \int_{\{X^* \in B\}} \frac{1}{n!} \sum_{\sigma} f(\sigma x^*) dP \end{aligned}$$

$$\Rightarrow E(f(x) \mid X^* = z) = \frac{1}{n!} \sum_{\sigma} f(\sigma z) = \frac{1}{|\langle z \rangle|} \sum_{x \in \langle z \rangle} f(x) \quad \text{new függ}$$

az x_i megfigyelés elosztásától $\rightarrow X^*$ elégsges stat., behelyettesítve $f = \text{indikátor}$.

□

Megj. X feltétes eloszlára X^* -re néve: $\langle X^* \rangle$ -on capcolatos, avagy minden soronként egyformán valószínű.

Dominált mérő és osztályozás

P, Q, \dots val. mérők

P, Q, \dots eloszlásokkal (mérőosztályozás)

Def. P dominált, ha $\exists \lambda$ 0-véges, hogy $P \ll \lambda \forall P \in \mathcal{P}$

Ekkor P megadható a $dP/d\lambda$ szükségfüggvényrel is.

Spec. esetek: • $\lambda = \text{Lebesgue-mérő}$ \mathbb{R}^n -ben $\Rightarrow f_\lambda = \frac{dP_\lambda}{d\lambda}$ a hosszmérő

• λ megnövelhető, $\lambda = \text{szimultánmérő}$

$$\Rightarrow f_\lambda(x) = P_\lambda(\{x\}) \text{ a valószínűség}$$

Def.

$B \in \mathcal{B}$ P -0-halmaz, ha $P(B) = 0$.

Def. $B \in \mathcal{B}$ P -0-halmaz, ha $P(B) = 0 \quad \forall P \in \mathcal{P}$.

Def. $P \sim Q \Leftrightarrow P \ll Q, Q \ll P \Leftrightarrow (B \text{ } P\text{-0-h.} \Leftrightarrow Q\text{-0-h.})$ (Equiválencia)

Def. $P \sim Q$ (Equiválencia): a P -0-halmazok megegyeznek a Q -0-halmazokkal.

Tétel: (Halmos → Savage) Ekvivalens:

(1) P dominált

(2) $\exists P_0 \subset P$, P_0 megnövelhető, $P \sim P_0$

(3) $\exists P_1, P_2, \dots \in \mathcal{P}, \exists c_1, c_2, \dots \in \mathbb{R}, \sum c_i = 1, \forall c_i > 0,$

$$\text{és } P_0 = \sum_{i=1}^{\infty} c_i P_i \sim P \quad (\text{kilevert})$$

Megj. P_0 maga is val. mérő, kisbőf az ekvivalens val. mérőknek hivatalosnak.

Tétel: (Neyman faktorizációs tétel)

Dominált statisztikai mérő ekvivalens:

(1) T elégsges statisztika

(2) az ekvivalens valószínű mérőre vonatkozó szükséghigiéniától

$$f_\lambda(x) = g_\lambda(T(x)) \quad (g_\lambda \geq 0, \text{ mérhető})$$

(3) tömöleges dominált mérő melleth

$$f_\lambda(x) = h(x) \cdot g(T(x)) \quad (h \geq 0)$$

B : (1) \Rightarrow (2) $B \in \mathcal{B}$

$$\exists P_\lambda(B|T) \text{ községi vértő$$

$$P_0 = \sum_{n=1}^{\infty} c_n P_n. \quad A \text{ körös } \text{verős } jö \text{ eint } P_0(B|T) \text{-vel } \text{is.}$$

$$\text{Tudjuk, hogy } A \in \sigma(T) \Rightarrow \int_A P_{\mathcal{F}}(B|T) dP_{\mathcal{F}} = P_{\mathcal{F}}(A \cap B) \text{ és} \\ \Rightarrow \int_A P_{\mathcal{F}}(B|T) dP_0 = P_0(A \cap B)$$

$$\frac{dP_{\mathcal{F}}|_{\sigma(T)}}{dP_0|_{\sigma(T)}} = \text{a RND, } \sigma(T) - \text{mérhető } \omega = g_{\mathcal{F}}(T),$$

$$P_{\mathcal{F}} \ll P_0 \Rightarrow P_{\mathcal{F}}|_{\sigma(T)} \ll P_0|_{\sigma(T)}$$

legyunkatjuk, hogy $\frac{dP_{\mathcal{F}}}{dP_0} = g_{\mathcal{F}}(T)$ is finom.

Lépjünk u. $A \in \mathcal{B}$.

$$\begin{aligned} \int_A g_{\mathcal{F}}(T) dP_{\mathcal{F}} &= \int_{\mathbb{X}} I_A \cdot g_{\mathcal{F}}(T) dP_{\mathcal{F}} = \int_{\mathbb{X}} E(I_A \cdot g_{\mathcal{F}}(T) | T) dP_{\mathcal{F}} = \\ &= \int_{\mathbb{X}} E_{\mathcal{F}}(I_A \cdot g_{\mathcal{F}}(T) | T) dP_{\mathcal{F}}|_{\sigma(T)} = \\ &= \int_{\mathbb{X}} E_{\mathcal{F}}(I_A | T) \cdot \underbrace{g_{\mathcal{F}}(T) dP_0|_{\sigma(T)}}_{dP_{\mathcal{F}}|_{\sigma(T)}} = \text{"még egy lépés a} \\ &\quad \text{rajzbaigás sorozatban"} \\ &= \int_{\mathbb{X}} E_{\mathcal{F}}(I_A | T) dP_0 = \int_{\mathbb{X}} I_A dP_0 = P_{\mathcal{F}}(A) \end{aligned}$$

(2) \Rightarrow (1), $P_0(B|T)$ jo' eint szörök verőnek: elhet az ell., hogy $\forall A \in \sigma(T) \forall \vartheta \in \Theta : \int_A P_0(B|T) dP_{\mathcal{F}} = P_{\mathcal{F}}(A \cap B)$.

$$\begin{aligned} \int_A P_0(B|T) dP_{\mathcal{F}} &= \int_A E_0(I_B | T) \underbrace{g_{\mathcal{F}}(T) dP_0}_{\text{mérth.}} = \\ &= \int_A E_0(I_B g_{\mathcal{F}}(T) | T) dP_0 = \\ &= \int_A g_{\mathcal{F}}(T) I_B dP_0 = \int_{A \cap B} g_{\mathcal{F}}(T) dP_0 = P_{\mathcal{F}}(A \cap B) \end{aligned}$$

(2) \Rightarrow (3) Láncsoraboly: $\lambda \ll \mu \ll \nu \Rightarrow \frac{d\lambda}{d\nu} = \frac{d\lambda}{d\mu} \cdot \frac{d\mu}{d\nu}$

$$\text{Említj } P \ll \lambda \Rightarrow P_0 \ll \lambda \Rightarrow P_{\mathcal{F}} = \frac{dP_{\mathcal{F}}}{d\lambda} = \frac{dP_{\mathcal{F}}}{dP_0} \cdot \frac{dP_0}{d\lambda} = g_{\mathcal{F}}(T) \cdot h$$

$$(3) \Rightarrow (2) : P_0 = \sum c_n P_n \Rightarrow \frac{dP_{\mathcal{F}}}{dP_0(x)} = \frac{dP_{\mathcal{F}}/d\lambda(x)}{dP_0/d\lambda(x)} = \frac{f_{\mathcal{F}}(x)}{\sum c_n f_n(x)} \stackrel{(3)}{=} \frac{g_{\mathcal{F}}(\tau(x)) \cdot h(x)}{\sum c_n g_n(\tau(x)) \cdot h(x)} = \\ = \tilde{g}_{\mathcal{F}}(\tau(x)).$$

Elutol u. O, at P_0 -ki P -nullmeitől.

□

Nem tipikus, hogy elégéges stat. rész díszteoriás, bár a nevezetesebbet is igaz, de azaz mint minden egy spec. esetben tökéletesen teljesít.

Példák: Elbőlsparaméteres Cauchy: $\frac{1}{\pi((x-\theta)^2+1)}$, est. nehez feldolgozni.

Def. T minimalis elégéges stat., ha elégéges és $\forall S$ elégéges stat. Igy: $T = g(S)$, ahol T tömörítése S-vel. (P-m.m.)

All. (BN) $\mathbb{X} = \mathbb{R}^n$

- (1) $(\exists\text{-m.m. } x, y : T(x) = T(y) \Rightarrow \frac{f_\theta(x)}{f_\theta(y)} \text{ nem függ } \theta\text{-tól}) \Leftrightarrow T \text{ egs.}$
- (2) $(\exists\text{-m.m. } x, y : T(x) = T(y) \Leftrightarrow \frac{f_\theta(x)}{f_\theta(y)} \text{ nem függ } \theta\text{-tól.}) \Rightarrow T \text{ egs.}$

Fischer-féle információs mátrix (Fischer-információ)

1925

Def. Likelihood-függvény $\theta \mapsto f_\theta(\mathbf{x})$ valóban f.

Def. Log-likelihood-fu. $\log f_\theta(\mathbf{x}) = l(\theta)$

Ha a minta n elemű független, akkor az egyszeres előtolás log-likelihoodja $L(\theta)$, és X_i log-likelihoodja $l_i(\theta)$

Ha X_i szintén λ -ra f $\rightarrow \underline{\mathbf{x}} = (x_1, \dots, x_n)$ $\lambda^n = \lambda \times \dots \times \lambda$ -ra vett szintén $\prod_{i=1}^n f(x_i)$,

$$\Rightarrow L(\theta) = \sum_{i=1}^n l_i(\theta), \quad \text{az } l_i(\theta) \text{ val. változók független arányos előtolásúak.}$$

ment független
szintén
ment az x_i -re
arányos előtolásúak

Felölv. $\theta = \theta_0$ a θ minden parciális deriváltak.

Tfn. $\exists \partial l(\theta)$, ahol $\Theta \subset \mathbb{R}^p$ konvex műfkt.

Error $\partial l(\theta)$ p-dim. sorvektor.

Def. Fischer-inf.: $I(\theta) = E_\theta (\partial l(\theta)^\top \cdot \partial l(\theta))$, ha értelmes.

Tulajdonságok.

$I(\theta)$ simmetrikus, pozitív menedzsmit (mert $a \in \mathbb{R}^p$ -re

$$a^\top I(\theta) \cdot a = E_\theta (a^\top \partial l(\theta)^\top \partial l(\theta) \cdot a) = E_\theta ((\partial l(\theta) \cdot a)^2) \geq 0$$

$$I(\theta) = \int \frac{(\partial f_\theta)^\top \cdot \partial f_\theta}{f_\theta^2} \cdot f_\theta \cdot d\lambda = 4 \int (\partial \sqrt{f_\theta})^\top \cdot \partial \sqrt{f_\theta} \cdot d\lambda$$

$$(\sqrt{f})' = \frac{f'}{2\sqrt{f}}$$

Gyenge regularitási feltételek (R)

① $f \mapsto \sqrt{f(x)}$ folyt diff. \exists -nál. $x \rightarrow e$

② $I(f)$ lítériz, továbbáos ϑ -ban és invertálható

Tétel: Tpl. a gy. r. felt. teljesülve, azaz (R). Legyen $T: \mathbb{X} \rightarrow \mathbb{R}^k$ lokálisan körönként második momentummal, azaz a $f \mapsto E_f \|T\|^2$ fu. legyen körönként bármely ϑ eng rögzítében.

Előre $E_f(T)$ folyt. diffelő és minden esetben deriválható a ϑ -val, azaz $E_f(T) = \int_{\mathbb{X}} T(x) f(x) dx$

$$\begin{aligned}\partial E_f(T) &= \int_{\mathbb{X}} T(x) \partial f(x) dx = \int_{\mathbb{X}} T(x) \underbrace{\frac{\partial f(x)}{f(x)}}_{\vartheta(x)} f(x) dx = \\ &= E_{\vartheta}(T \vartheta(x)) \quad k \times p - \text{es mátrix.}\end{aligned}$$

Megj.: Speciálisan $T \equiv 1-e$ $0 = E_f(\vartheta(x))$, ezért (R) \Rightarrow

$$\Rightarrow I(f) = \sum_{\vartheta} (\vartheta \cdot T), \quad \partial E_f(T) = \text{cov}_f(T, \vartheta \cdot \vartheta^T)$$

Megj.: (R)-ból minélgy az a bemenetelkészítés hármasjár, cser azzal lehet ellenőrizni.

Megj.: A Fischer-információ nem függ a bemenetlő néhánytól.

Ha u. μ az eredmény val. mérése, λ pedig kett. bemenetlő mérése, jel. $f_\theta = \frac{dP_\theta}{d\lambda}$, $g_\theta = \frac{dP_\theta}{d\mu}$, error per me $\mu \ll \lambda$, ilyenkor elhacsabálly minden $f_\theta = g_\theta \cdot \frac{d\mu}{d\lambda} = g_\theta \cdot h$ $\xrightarrow{\theta \text{-fkt.}}$

$$\Rightarrow \log f_\theta = \log h + \log g_\theta \Rightarrow \lambda \log f_\theta = \lambda \log g_\theta \checkmark$$

$$\Rightarrow (R) \text{ nem függ } \theta \text{-től}$$

Tétel: (1) Függetlenek infomációja összeholdol:

$$\left. \begin{array}{l} X \text{ minta eloszlásaira teljesül (R)} \\ Y \text{ --- --- --- --- (R)} \end{array} \right\} \forall \vartheta \rightarrow \text{független}$$

\Rightarrow az egymáshoz közeládják is teljesül (R) és

$$I(X,Y)(\vartheta) = I_X(\vartheta) + I_Y(\vartheta) \quad \forall \vartheta$$

Köv.: n elemű fiktív mintára: ha egy mintában eloszlásai teljesül (R) \Rightarrow a teljes mintára is, és $I_n(\vartheta) = n \cdot I_1(\vartheta)$, ahol $I_1(\vartheta)$ az n elemű minta infomációja.

2017. 03. 01.

(2) Statisztika információja nem nagyobb, mint a mintáé:

ha X előreláncra tekerül (R), és $T = T(X)$ előreláncra is tekerül (R), akkor $\forall S: I_T(S) \leq I_X(S)$ (azaz $I_X - I_T$ poz. nemidef.)

(3) Elégéges statisztika megőrzi az információt:

ha X előreláncra (R), és T elégéges $\Rightarrow T$ előreláncra (R),
és $I_T(S) = I_X(S) \quad \forall S$.

(4) Teljes előrelánc nincs eredménye.

Ezért (3) megfordítható: ha X és T előreláncra (R) és
 $I_T(S) = I_X(S) \quad \forall S \Rightarrow T$ elégéges.

B: (1) X minta értékeit az $(\mathbb{X}, \mathcal{B}_X)$ mért. területhez venni, előreláncai
 $P_\theta, \theta \in \Theta$; ugyanilyen Y az $(\mathbb{Y}, \mathcal{B}_Y)$ -ból, eo. $Q_\theta, \theta \in \Theta$

$\Rightarrow (X, Y)$ az $(\mathbb{X} \times \mathbb{Y}, \mathcal{B}_X \times \mathcal{B}_Y)$ -ból, eo. $P_\theta \times Q_\theta, \theta \in \Theta$

Ha $P_\theta \ll \lambda, Q_\theta \ll \mu \Rightarrow P_\theta \times Q_\theta \ll \lambda \times \mu$.

Tel. $f_\theta = \frac{dP_\theta}{d\lambda}, g_\theta = \frac{dQ_\theta}{d\mu} \Rightarrow \frac{d(P_\theta \times Q_\theta)}{d(\lambda \times \mu)}(x, y) = f_\theta(x) \cdot g_\theta(y) = h_\theta(x, y)$

(az elegendő mérhetőlégi összefüggés.)

$$\partial \log h_\theta(x, y) = \partial \log f_\theta(x) + \partial \log g_\theta(y) \quad (\text{itt nagyobb zártban!})$$

várható értéke (R) miatt 0

$$\Rightarrow E_\theta(\partial \log h_\theta(x, y)) = 0 \rightarrow I_{(X,Y)}(S) = \sum_{(x,y)} (\partial \log h_\theta(x, y))^T =$$

$$= \sum_x (\partial \log f_\theta(x)) + \sum_y (\partial \log g_\theta(y)) \quad \text{a függetlenség miatt.}$$

$$= I_X(S) + I_Y(S)$$

Az együttes eo. regularitása:

$$\textcircled{1} \sqrt{h_\theta(x, y)} = \sqrt{f_\theta(x)} \cdot \sqrt{g_\theta(y)} \quad \lambda \times \mu - \text{m.m. } (x, y) \rightarrow \text{folyt. diff.}$$

\textcircled{2} $I_{(X,Y)}(S)$ folytonos S -ben és poz. def., nem illeszthető osszegre.

(2) Lemmas. Tel. P_θ X előreláncát, $f_\theta = \frac{dP_\theta}{d\lambda}$. Ezért $T(X)$ előrelánc

$$Q_\theta = P_\theta \circ T^{-1} \ll \mu = \lambda \circ T^{-1}, \quad \text{és} \quad \frac{dQ_\theta}{d\mu} = g_\theta.$$

$$\Rightarrow E_\theta[\partial \log f_\theta(X)|T] = \partial \log g_\theta(T)$$

B_L : legyen B mérhető halmaz.

$$P_\theta(T \in B) = P_\theta(T^{-1}(B)) = E_\theta(I_{T^{-1}(B)}) \quad \xrightarrow{\text{indikátor}} \text{folyt. diff. } (R) \text{ miatt}$$

$$\Rightarrow \partial P_{\theta}(T^{-1}(B)) = \int_{\mathbb{R}} I_{T^{-1}(B)} \partial f_{\theta} d\lambda = E_{\theta}(I_{T^{-1}(B)} \partial \log f_{\theta}(X)) =$$

nicht korribbar

$$= \int_{T^{-1}(B)} \partial \log f_{\theta} d\lambda$$

bedeutet, integriert.

$$P_{\theta}(T^{-1}(B)) = Q_{\theta}(B) \quad \text{folgt diff} \quad \Rightarrow \partial Q_{\theta}(B) = \int_B \partial \log g_{\theta} d(\underbrace{\lambda \circ T^{-1}}_{\mu}) =$$

$$= \int_{T^{-1}(B)} (\partial \log (g_{\theta} \circ T)) d\lambda$$

Lemma: (A kejes mérásnéppet tétel)

A feltételek kovarianciamatrix (mérásnéppet): $\mathbb{E}(X|\mathcal{F}) = E([X - E(X|\mathcal{F})] \cdot [X - E(X|\mathcal{F})]^T | \mathcal{F})$

$$= E(XX^T | \mathcal{F}) - E(X|\mathcal{F}) \cdot E(X|\mathcal{F})^T$$

$$\text{erre} \quad \mathbb{E}(X) = E(\mathbb{E}(X|\mathcal{F})) + \mathbb{E}(E(X|\mathcal{F}))$$

B.: Defiböl jól látható: $\mathbb{E}(X|\mathcal{F}) = X - E(X|\mathcal{F})$, mert X \mathcal{F} -melek.

$$\rightarrow \mathbb{E}(X|\mathcal{F}) = \mathbb{E}(X - E(X|\mathcal{F})) = E([X - EX] \cdot [X - EX]^T | \mathcal{F}) - [E(X|\mathcal{F}) - EX] \cdot [E(X|\mathcal{F}) - EX]^T$$

$$\rightarrow E \mathbb{E}(X|\mathcal{F}) = \mathbb{E}(X) - \mathbb{E}(E(X|\mathcal{F}))$$

$$\Rightarrow I_X(\delta) = \mathbb{E}_{\theta}(\partial \log f_{\theta}(X)^T) \geq \mathbb{E}_{\theta}(\partial \log g_{\theta}(T)) = I_T(\delta)$$

$\partial \log f_{\theta}(X)^T$, $T = \sigma(T)$ - e lemmával

$$(3) T elágúzás: $f_{\theta}(X) = h(X) \cdot g_{\theta}(T(X)) \Rightarrow \partial \log f_{\theta}(X) = \partial \log g_{\theta}(T(X))$$$

$$\Rightarrow I_X(\delta) = E_{\theta}([\partial \log f_{\theta}]^T [\partial \log f_{\theta}(X)]) = E_{\theta}([\partial \log g_{\theta}(T(X))]^T \cdot [\partial \log g_{\theta}(T(X))]) = I_T(\delta)$$

A regularitás dominálónévre - független \Rightarrow f.tu. \mathbb{E}_{θ} eredmény megtételi.

$$\text{erre} \quad f_{\theta}(x) = g_{\theta}(t(x)).$$

N.m.m. $x \mapsto \delta \mapsto \sqrt{f_{\theta}(x)}$ folgt diff. $\rightarrow \lambda \circ T^{-1}$ -m.m. $t \mapsto \delta \mapsto \sqrt{g_{\theta}(t)}$ folgt diff.

és az információ is megőrzi.

$\Rightarrow T(X)$ -re is (R).

$$(4) I_X(\delta) = I_T(\delta) - \text{mér. az sell. mely } E_{\theta}(\mathbb{E}_{\theta}(\partial \log f_{\theta}(X)^T | T)) = O_{p \times p}$$

$$\Rightarrow \mathbb{E}_{\theta}(\partial \log f_{\theta}(X)^T | T) = O_{p \times p}, \quad \text{mert pos. szav. diff. is v. este. } O.$$

P -m.m., mert λ mér. eredmény.

F.tu. $f_{\theta}(x) > 0 \quad \forall \theta \forall x$, amire nem, attól ridebbetjük (nullmértekk)

$$\Rightarrow \partial \log f_{\theta}(X) = \psi_{\theta}(T(X)) \quad \forall \theta, \quad \text{m.m. } x \mapsto$$

$x \in N_{\theta}$, ahol N_{θ} P -o-körök.

↓
 δ -függő!

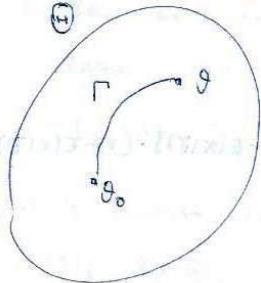
Légyen most $\Theta^* \subseteq \Theta$ megrányaoltatott, sűrű halmaz.

$N_0: x \notin N_0$ -ra $\theta \mapsto \log f_\theta(x)$ pol. diff., (N_0 is P-0)

~~ha~~ $\theta \notin \Theta^*$

$$\text{fűz. } x \notin \left(\bigcup_{\theta^* \in \Theta^*} N_{\theta^*} \right) \cup N_0 \Rightarrow \partial \log f_\theta(x) = \lim_{\substack{\theta^* \rightarrow \theta \\ \theta^* \in \Theta^*}} \varphi_{\theta^*}(\tau(x)) = \tilde{\varphi}_\theta(\tau(x)).$$

Tehát m.m. x -re $\forall \theta: \partial \log f_\theta(x) = \tilde{\varphi}_\theta(\tau(x))$



$\theta_0 \in \Theta$ rögt, $\Gamma \subset \Theta$ görbe, $\Gamma \setminus \theta_0$ köti össze θ -val, vertikálisab. Interpolació:

$$\Rightarrow \partial \log f_\theta(x) - \partial \log f_{\theta_0}(x) = \int_{\Gamma} \tilde{\varphi}_t(\tau(x)) dt \quad \text{es } \tau(x) \text{ fügje.}$$

$$\Rightarrow f_\theta(x) = f_{\theta_0}(x) \cdot e^{\int_{h(x)}^{g(x)} dt} \quad \left. \begin{array}{l} \text{funkcionális tétel} \Rightarrow \text{T elágazás} \\ \text{h(x)} \quad g(x) \end{array} \right\}$$

Az paraméterezés

$P = \{P_\theta : \theta \in \Theta\} \subset \mathbb{R}^p$, $u: G \rightarrow \Theta$: injektív és diff., $G \subset \mathbb{R}^p$ rögt.

$P' = \{P'_\tau = P_{u(\tau)} : \tau \in G\}$ τ a rögi, τ -at új paraméter.

($\mathbb{X}, \mathcal{B}, P'$)-ban a τ -ra vonatkozó információ légyen $I(\tau)$.

a rögi információ $I(\theta)$. Mi köthető a kapcsolat?

$$\frac{\partial P'_\tau}{\partial \tau} = g_\tau, \quad \frac{dP_\tau}{d\tau} = f_\tau, \quad g_\theta = f_{u(\tau)}$$

$$\Rightarrow \frac{\partial \tau}{\partial \theta} \log g_\tau = \underbrace{\partial \theta \log f_\theta}_{q\text{-dim sor}} \Big|_{\theta=u(\tau)} \underbrace{h'(u)}_{p\text{-dim sor}}$$

$p \times q$ -dim mátrix

$$\text{diák-} \Rightarrow I(\tau) = h'(\tau)^T \cdot I(u(\tau)) \cdot h'(\tau) \text{ körüljelzés}$$

Ez pl. jö $N(\cdot, \cdot)$ kettőle paraméterezte zöthi áltérre. σ vagy σ^2 .

Erős regularitási feltételek (RR)

(R) + $\exists \delta^2 \in \mathbb{R}$ ilyen, és ha $M(X) = \sup_{\theta \in \Theta} \|\delta^2 \log f_\theta(X)\|^2$, akkor $\sup_{\theta \in \Theta} E_\theta(M(X)) < +\infty$ legyen.

(Ezért még leme összefüggésben megfogalmazni, de most elég globálisan.)

Def. (RR) teljesítése szerint:

(BN)

$$(1) \quad 0 = \int_X \delta^2 f_\theta d\lambda \quad (\text{kétnel bérletihatóság})$$

$$(2) \quad I(\theta) = -E_\theta(\delta^2 l(\theta))$$

Becsleselmélet

Pontbecsleseket fogunk véni. (van intervallumbeli is)

$g: \Theta \rightarrow \mathbb{R}^k$, $g(\theta)$ -t nemről becslünk

Def. $g(\theta)$ becslese $T(X)$, ahol $T: X \rightarrow \mathbb{R}^k$, azaz amilyen, hogy ugyanazt reprezentálja.

Def. T körülítő, ha $\forall \theta: E_\theta(T) = g(\theta)$

Def. T torlásai $b_T(\theta) = E_\theta(T) - g(\theta)$ (Bias)

Def. Veszteségtípus: $w: \mathbb{R}^k \times \Theta \rightarrow \begin{cases} \mathbb{R} & (\text{általában}) \\ \mathbb{R}^{k \times k} & (\text{szűkebb, de népszerű}) \end{cases}$

Ha a parameter θ , és $g(\theta) + y \in \mathbb{R}^k$ -val szoruljuk, a vezetésgörbe $w(y, \theta)$.

$$(1) \quad w(g(\theta), \theta) = 0$$

$$(2) \quad w(y, \theta) \geq 0 \quad (\text{pos. nemidef., ha matix})$$

(3) w az előző rövidítésekben konvex

Példa. Négyzetes vezetésgörbe: a leggyakrabban használt, deit jelentősebb is van.

$$\rightarrow \text{szálasítási}: v_1(y) = \|y\|^2 \in \mathbb{R}$$

$$\rightarrow \text{matixról}: v_2(y) = y \cdot y^T \in \mathbb{R}^{k \times k}$$

$v_1 = \text{Tr } v_2 \Rightarrow$ elég v_2 -re korlátozni a def. feltételeit. (Poz. nemidef - nyome nemnegatív.)
(1) és (2) világos.

$$\begin{aligned} (3): \quad y_1 \neq y_2, 0 < \alpha < 1: \quad & x \cdot v_2(y_1) + (1-x) v_2(y_2) - v_2(\alpha y_1 + (1-\alpha) y_2) = \\ & = x \cdot y_1 y_1^T + (1-x) y_2 y_2^T - \left(\alpha^2 y_1 y_1^T + (1-\alpha)^2 y_2 y_2^T + \alpha \cdot (1-\alpha) \cdot (y_1 y_2^T + y_2 y_1^T) \right) = \\ & = \alpha \cdot (1-\alpha) \cdot (y_1 y_1^T + y_2 y_2^T - y_1 y_2^T - y_2 y_1^T) = \alpha \cdot (1-\alpha) \cdot v_2(y_1 - y_2) \geq 0 \end{aligned}$$

\Rightarrow szigorúan is konvex

2017.03.08.

Def. Legyen $T: \Xi \rightarrow \mathbb{R}^k$ a $g(\theta)$ becslese, $g: \Theta \rightarrow \mathbb{R}^k$.

$$T$$
 növekvőfogúja $R_T: \Theta \rightarrow \begin{cases} \mathbb{R} \\ \mathbb{R}_{\geq 0} \end{cases}, R_T = E_\theta(w(T, \theta))$

Példa. Mátix értékű négyzetes növekvő:

$$R_T(\theta) = E_\theta([T - g(\theta)] \cdot [T - g(\theta)]^T) = \mathbb{E}_\theta(T) + b_T(\theta) \cdot b_T(\theta)^T$$

Speciálisan torzítatlan becsles növekvőja $R_T(\theta) = \mathbb{E}_\theta(T)$

Def. Legyenek T_1, T_2 a $g(\theta)$ becslesei, T_1 egynelzetesen jobb (érthetően nevezetessé), ha $R_{T_1}(\theta) \leq R_{T_2}(\theta) \quad \forall \theta \in \Theta$

Ha $R_{T_1}(\theta) = R_{T_2}(\theta) \quad \forall \theta \in \Theta \Rightarrow T_1$ és T_2 eredmény becslesek.

Megj. Mátixokra nem minden; speciálisan ez azt jelenti, hogy az oszlopok összehasonlíthatók.

Def. Legyen \mathcal{D} a $g(\theta)$ becsleseinek egy mintája (nem feltételezve az összes becsles). $T \in \mathcal{D}$ optimalis becsles, ha $\forall T' \in \mathcal{D}: T$ egy. jobb T' -nél.

A $T \in \mathcal{D}$ megengedhető (admissible), ha $\forall T' \in \mathcal{D}: \text{ha } T \in T'$ összehasonlítható, akkor T egynelzetesen jobb T' -nél.

Def. Szlávártiánus véteségű esetén $T \in \mathcal{D}$ minimax becsles, ha $\forall T' \in \mathcal{D}: \sup_\theta R_T(\theta) \leq \sup_\theta R_{T'}(\theta)$. (A pessimista elvben becslese.)

Torzítatlan becsles és négyzetes véteségű esetén
egynelzetesen jobb = hatásosabb
Optimalis = hatásos (efficient) = UMVU

All. 1) T optimalis \Rightarrow minimax is megengedhető.

2) Ha \mathcal{D} konvex is w elők vált. mig. szövex, akkor az optimalis becsles egységtelen P-m.m.

B: 1) trivialis

2) T_1, T_2 optimalis, $T := \frac{T_1 + T_2}{2} \in \mathcal{D}$. (a személyes oszlopokban állt)

$$\begin{aligned} R_T(\theta) &= E_\theta\left(w\left(\frac{T_1 + T_2}{2}, \theta\right)\right) \leq E_\theta\left(\frac{w(T_1, \theta) + w(T_2, \theta)}{2}\right) = \\ &= \frac{R_{T_1}(\theta) + R_{T_2}(\theta)}{2} = R_{T_1}(\theta) \end{aligned}$$

Optimalitás $\Rightarrow R_{T_1}(\theta) = R_T(\theta)$, egységes ált.

$$\Rightarrow w\left(\frac{T_1 + T_2}{2}, \theta\right) = \frac{w(T_1, \theta) + w(T_2, \theta)}{2} \quad P_\theta\text{-m.m. } \forall \theta$$

$$\Rightarrow T_1 = T_2 \quad \underbrace{P_\theta\text{-m.m.}}_{P_\theta\text{-m.m.}}$$

□

Kör. A metáros becslés egységtelmi.

B: A körültekercs összegére vonatkozik, a négyzetfüggvény nincs szerepe. □

Tétel. (Blackwell — Rao, B. 1945, R. 1947, Kolmogorov 1950)

Legyen T a $g(\theta)$ becslése, S elégsges statisztika. $\tilde{T} := E_S(T|S)$ (S fréq.)

$$1) \delta_{\tilde{T}}(\theta) = b_T(\theta) \quad \forall \theta \in \Theta$$

$$2) R_{\tilde{T}}(\theta) \leq R_T(\theta) \quad \forall \theta \in \Theta \quad (\text{egységesen jobb})$$

Ezértükben minden esetben az elégsges statisztika függvényeivel érdemes.

B: 1) Teljes várható érték tétel: $E_\theta(\tilde{T}) = E_\theta(T) \quad \forall \theta \in \Theta$

2) Feltételezés: Fejlett csupánthosság:

$$R_{\tilde{T}}(\theta) = E_\theta(w(E_\theta(T|S), \theta)) \leq E_\theta(w(E_\theta(T, \theta) | S)) \stackrel{\text{F.V.E.}}{=} E_\theta(w(T, \theta)) = R_T(\theta).$$
 □

Def. A T statisztika teljes, ha körülleges le függvénye minden

$$E_\theta(h(T)) = 0 \Rightarrow h(T) = 0 \quad \text{P.m.m. (A másik irányú nyilag igaz.)}$$

Van használó tétel, mint elégességi a faktorizáció.

All. 1) Ha T teljes, és $E_\theta(h_1(T)) = E_\theta(h_2(T)) \quad \forall \theta \in \Theta \rightarrow h_1(T) = h_2(T)$

P.m.m. Ez becsülésben eredményes $b_{h_1(T)}(\theta) = b_{h_2(T)}(\theta)$ -val.

Következmény: teljes statisztika minden legfeljebb egy körültekercs becslés van.

2) Ha T körültekercs, S pedig teljes és elégsges, akkor \tilde{T} metáros.

B: 1) trivialis

2) Jelölje T körültekercsét mindenhol \tilde{T} minden megnyarás lese.

Ez az eljárás a Blackwellizálás.

1. Keresünk $g(\theta)$ -ra „minél egyszerűbb” körültekercs becslést. (ha van)

2. Keresünk teljes és elégsges statisztikát. (ha van)

3. $\tilde{T} = E_S(T|S)$ metáros.

T valamint a \tilde{T} nem függ, de a. művekben szereplők függ a valamint a.

Tétel. (Cramér — Rao) (R) legrosszabb tételével, az legyen T a $g(\theta)$ körültekercs becslése 100% korlátos művek momentumai. Többször, minden erről gyakorlati, deriváltja legyen $G(\theta)$, \exp -s mátrix.

Erről $R_T(\theta) = \sum_{\theta} g(T) \geq G(\theta) \cdot I(\theta)^{-1} \cdot G(\theta)^T$, a jobb oldal neve információs metrrix. Információs csupánthosság.

Megj. Ha Θ -ra vonatkozik általánosan $\rightarrow T$ matrrix. Fordítva nem igaz.

Megj. Tpl. a minta n elemű független. $\rightarrow \Sigma(\theta) = I_n(\theta) = n \cdot I_1(\theta)$,

$$\text{és } \Sigma_{\theta}(\tau) \geq \frac{1}{n} \cdot G(\theta) I_n(\theta)^{-1} \cdot G(\theta)^T, \text{ mivel } (I_n(\theta))^{-1} = \frac{1}{n} \cdot I_1(\theta)^{-1}.$$

Ez azt mondja, hogy bár GC minden a valószínűségi, de csak lassan.

$$\begin{aligned} B_T: 0 &\leq \Sigma_{\theta}(\tau - G I^{-1} \cdot \Delta \theta^T) = \text{cov}_{\theta}(\tau - G I^{-1} \Delta \theta^T, \tau - G I^{-1} \Delta \theta^T) = \\ &= \underbrace{\text{cov}_{\theta}(\tau, \tau)}_{\mathbb{E}(\tau)} - \underbrace{\text{cov}_{\theta}(\tau, \Delta \theta^T)}_{G I^T \cdot \text{cov}_{\theta}(\Delta \theta^T, \tau)} \cdot I^{-1} \cdot G^T + \cancel{\text{cov}_{\theta}(G I^{-1} \cdot \text{cov}_{\theta}(\Delta \theta^T, \Delta \theta^T) I^T G^T -} \\ &= \Sigma(\tau) - G I^{-1} G^T \end{aligned}$$

KÖV. Legyen θ diffinab, T nem felt. hozzáírtan bocsátja θ -re,
 T második momentumára les. kölcsön. Erről $b_T(\theta)$ os diffinab,
jel. $B(\theta) = \Delta b_T(\theta)$, ett tulajd.

$$\Rightarrow \text{A négyzetes ritardára } R_T(\theta) \geq (G(\theta) + B(\theta)) \cdot I(\theta)^{-1} \cdot (G(\theta) + B(\theta))^T + B_T(\theta) \cdot B_T(\theta)^T.$$

B : a CR-egyeletszeggel. $R_T(\theta) = \Sigma_{\theta}(\tau) + B_T(\theta) \cdot B_T(\theta)^T$.

$\Sigma_{\theta}(\tau)$ -re az előző tételek gyakorlati alkalmazása.

Athasánétes: régi paraméter $\theta \in \Theta$, $\pi \in G$. Legyen $\tau = u(\theta)$,
ahol $u: \Theta \rightarrow G$ diffeomorfizmus.

$$\Rightarrow P_{\pi}^{\theta} = P_{u(\theta)}$$

τ -ban az új információs matrrix.

$g(\theta)$ tulajd. $g(u(\tau))$, deriváltja $G(u(\tau)) \cdot H(\tau)$, ahol

$H = u'$, $p \times p$ -es mátrix.

$$[G(u(\tau)) \cdot H(\tau)] \cdot \underbrace{[H(\tau)^T \cdot I(u(\tau)) \cdot H(\tau)]^{-1}}_{\mathbb{E} J(\tau)} \cdot [G(u(\tau)) \cdot H(\tau)]^T =$$

$$= G(u) \cdot H H^T \cdot I \cdot (u)^{-1} \cdot (H^T)^{-1} \cdot H^T \cdot G^T(u) = G(u) \cdot I(u)^{-1} \cdot G(u)^T,$$

azaz az információs matrrix nem változik áthasánéteséssel.

Dkt. legyenek Y_1, \dots, Y_k független $N(0,1)$ val. vektorok, $Y = (Y_1, \dots, Y_k)^T$.

Ha Y eloszlása k-dim. std. normális eo.

Legyen $A \in \mathbb{R}^{n \times k}$, $a \in \mathbb{R}^k$, $X = AY + a$. Ekkor X eloszlása n-dim. normális eo.

All. 1) $EX = a$, $\mathbb{E}(X) = AAT$. (Mert $EY = 0$, $\mathbb{E}(Y) = EY$ egységháix.)

2) Ha X n-dim normális, $B \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m \Rightarrow BX + b$ normális, azaz a normális eloszlású mindenkor történik.

Speciálisan ha X n-dim normális, akkor $\forall X_i$ marginális is normális, de ez megfelelve nem igaz.

3) $\forall m \in \mathbb{R}^k \forall \frac{1}{2} \geq 0, \frac{1}{2} \in \mathbb{R}^{n \times n}, \exists X$ normális, hogy $EX = m$, $\mathbb{E}(X) = \frac{1}{2}$ (U. Y n-dim std. normális, $a = m$, $A = \frac{1}{2}^{1/2}$)

All. Ha $\frac{1}{2} \geq 0 \Rightarrow$ az eloszlásnak van szűrőfüggvénye, és $f(x) = (2\pi)^{-n/2} (\det \frac{1}{2})^{-1/2} \exp\left(-\frac{1}{2}(x-m)^T \frac{1}{2}^{-1}(x-m)\right)$.

Megj. Ez a $\frac{1}{2}$ nem hat. meg X -et; meg A mérete is sorfele lehet így, hogy $AAT = \frac{1}{2}$ legyen.

Megj. Ha rang $\frac{1}{2} = r < n \Rightarrow X$! val. egy r-dim affin alakban eloszló, illetve az n-dim Lebesgue-mérhető névre nevezett poliéderen X . De lehet az aff. alakban is Lebesgue-mérhető definíció, és csak. már lemeztér.

B: A többi esetben $\mu = m$.

$$X = AY + \mu, \frac{1}{2} = AAT, A \in \mathbb{R}^{n \times k}$$

Elsőnél törli. $k = n$.

$$\Rightarrow Y$$
 eloszlása $f_Y(y) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} e^{-\frac{y_i^2}{2}} = (2\pi)^{-n/2} \exp\left(-\frac{1}{2}\|y\|^2\right)$

$\Rightarrow X$ eloszlása súlyozásos formával: az inverz $Y = A^{-1}(X - \mu)$,

$$\text{Jacobi } |\det A^{-1}| = \frac{1}{|\det A|} = \frac{1}{\sqrt{\det \frac{1}{2}}},$$

$$\begin{aligned} f_X(x) &= f_Y(A^{-1}(x - \mu)) \cdot \frac{1}{\sqrt{\det \frac{1}{2}}} = \\ &= (2\pi)^{-n/2} \left(\det \frac{1}{2}\right)^{-1/2} \cdot \exp\left(-\frac{1}{2} \cdot \underbrace{(x - \mu)^T (A^{-1})^T A^{-1}(x - \mu)}_{\|A^{-1}(x - \mu)\|}\right) \end{aligned}$$

Legyen $k > n \rightarrow$ elég $\mu = 0$ -ra bizonyítani, $(AAT)^T = \frac{1}{2}^{-1}$

azaz csak eloszlásparaméter.

(Az előbb is lehetséges.)

Megj. $\frac{1}{2} = U \Lambda U^T$, ahol Λ diagonális, az átlóban a $\lambda_1, \dots, \lambda_n$ számok találhatóak, $\lambda_i \geq 0$ ($\forall i \frac{1}{2} \geq 0$), és U orthonormált mátrix, azaz sorai orthonormált rendszert alkotnak (és orthonormális), azaz $U^T = U^{-1}$, U orthonormális \Rightarrow megfelelő orthonormált rendszert.
 $\frac{1}{2} = U \Lambda^{1/2} U^T$, ahol $\Lambda = \text{diag}(\lambda_1^{1/2}, \dots, \lambda_n^{1/2})$.

2017.03.22.

Felügye A-t most A_1 .

$$\begin{array}{c} k \\ \boxed{\begin{array}{c} A_1 \\ \vdots \\ A_2 \end{array}} \end{array}$$

Legyen A_2 $(k-n) \times k$ -as mátrix,
a sorai elvi feltételezés szerint A_1 ortogonális.
Sorára, azaz $A_1 A_2^T = 0$

$$\Rightarrow \text{rang } A = \text{rang } \begin{bmatrix} A_1 \\ A_2 \end{bmatrix} = k$$

$$X = AY = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} \quad X_1 = A_1 Y \quad n \text{ dim.}, \\ X_2 = A_2 Y \quad k-n \text{ dim.}$$

X sűrűségfünye, azaz X_1, X_2 egymással fünye:

$$f(x_1, x_2) = (2\pi)^{-k/2} (\det \Sigma)^{-1/2} \exp\left(-\frac{1}{2} x^T \Sigma^{-1} x\right)$$

$$\Sigma = A A^T = \begin{array}{|c|c|} \hline A_1 A_1^T & A_1 A_2^T \\ \hline A_2 A_1^T & A_2 A_2^T \\ \hline \end{array} = \text{diag}(A_1 A_1^T, A_2 A_2^T)$$

$$\Sigma^{-1} = \text{diag}((A_1 A_1^T)^{-1}, (A_2 A_2^T)^{-1})$$

$$x^T \Sigma^{-1} x = x_1^T (A_1 A_1^T)^{-1} x_1 + x_2^T (A_2 A_2^T)^{-1} x_2$$

$$\det \Sigma = \det A_1 A_1^T \cdot \det A_2 A_2^T$$

$$\Rightarrow f(x_1, x_2) = (2\pi)^{-n/2} (\det A_1 A_1^T)^{-1/2} \cdot \exp\left(-\frac{1}{2} x_1^T (A_1 A_1^T)^{-1} x_1\right) \cdot (2\pi)^{-(k-n)/2} (\det A_2 A_2^T)^{-1/2} \cdot \exp\left(-\frac{1}{2} x_2^T (A_2 A_2^T)^{-1} x_2\right)$$

$\Rightarrow X_1, X_2$ függetlenek és a zet normális konstansnak
a megfelelő sűrűségfünye

De ha az egységes, a másik is az:

Válasszuk A_2 , sorait úgy, hogy az A_1 sorai által

kifejtett áltér ortogonális "régiót" azonban ortognális

bánjat adjunk, ez megtehető.

$\Rightarrow A_2 A_2^T = E_{k-n} \Rightarrow f(x_1, x_2)$ második tényezője a $k-n$
dimenziós std. normális sz. fünye

$A_1 A_1^T = \Sigma(X_1) \Rightarrow$ rovatbeli, amit eredménytani alakba rakunk. \square

All. A többdim. normális sz. x is Σ meghatározta.

B: Ha $\Sigma > 0 \Rightarrow \exists$ sz. fünye, ami minden Σ -höz függően,
és meghatározza az eloszlást.

Ha $\text{rang } \Sigma = r < n \Rightarrow X$ -nel van a helyi koordinátája,
mely a többi rész lineáris fünye (gyak.)

Ezen r koordináta koo. matika invál (nem tőkében nem leme
az, arra r-nél részletebb koordinátaval is feljegyelhető lenne minden,
de erről vagy $\Sigma < \infty$ lenne).

Észt eur az r koordinátaval már van s fréje,
ezek előlásat megfelelően μ és $\Sigma \Rightarrow$ a többiért is.

Tel: $N_n(\mu, \Sigma)$ az n-dim normális el., (n ritkán nem kell, ha
 μ és Σ dimenziója adott, hisz az csak n).

Alg: X_1, X_2 egyszeres előlásás normális: $X = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix}_{n=2}^T, EX = \mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix}$
 $\Rightarrow \Sigma(X) = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix}, \text{ ahol } \Sigma_{11} = \Sigma(X_1), \Sigma_{22} = \Sigma(X_2),$
 $\Sigma_{12} = \text{cov}(X_1, X_2)$

Igy $\Sigma > 0$. Ekkor

- (1) $\text{cov}(X_1, X_2) \Leftrightarrow X_1 \text{ és } X_2$ független
- (2) $X_1 - \Sigma_{12} \Sigma_{22}^{-1} X_2$ és X_2 független
- (3) $X_1 | X_2$ feltételez. es. $N_e(m_{1|2}, \Sigma_{1|2})$, ahol

$$m_{1|2} = E(X_1 | X_2) = \mu_1 + \Sigma_{12} \Sigma_{22}^{-1} (X_2 - \mu_2) \quad (\text{lineáris } X_2\text{-ben}),$$

$$\Sigma_{1|2} = \Sigma(X_1 | X_2) = \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21} \quad (\text{konstans})$$

B: (1) $\Sigma > 0 \Rightarrow \exists$ sv. és mint látható, nemtól bontatlanul, ha

$$A_1 A_2^\top = \text{cov}(A_1 Y, A_2 Y) = \Sigma_{12} = 0.$$

(A másik irány mindenig igaz.)

Meg: (1) azaz is igaz, ha Σ nem invál:

X_1 -től és X_2 -ből kiválasztottak megfelelő koordinátákat,
mint az előző példában:

$$(2) \begin{bmatrix} X_1 - \Sigma_{12} \Sigma_{22}^{-1} X_2 \\ X_2 \end{bmatrix} = \begin{bmatrix} E_e & -\Sigma_{12} \Sigma_{22}^{-1} \\ 0 & E_{n-2} \end{bmatrix} X \Rightarrow \text{egyszeres normális.}$$

Ez gyakorlati belátási, mert $\text{cov}(X_1 - \Sigma_{12} \Sigma_{22}^{-1} X_2, X_2) = 0$

$$\underbrace{\text{cov}(X_1, X_2)}_{\Sigma_{12}} - \underbrace{\Sigma_{12} \Sigma_{22}^{-1} \text{cov}(X_1, X_2)}_{\Sigma_{21}} = 0$$

(3) $x_1 - \frac{1}{\hat{\sigma}_{12}} \hat{\sigma}_{22}^{-1} x_2 \mid x_2$ felt. es. megfelelő a könszéges elvezetésre. (2). miatt

$$x_1 - \frac{1}{\hat{\sigma}_{12}} \hat{\sigma}_{22}^{-1} x_2 \sim N_{\ell}\left(\underbrace{\mu_1 - \frac{1}{\hat{\sigma}_{12}} \hat{\sigma}_{22}^{-1} \mu_{21}}_{m_{1,2}}, \hat{\sigma}_{11}^2 + \frac{1}{\hat{\sigma}_{12}^2} \hat{\sigma}_{22}^{-1} \hat{\sigma}_{22}^{-1} \right)$$

$$\begin{aligned} \text{Ezután } \text{E}(x_1 - \frac{1}{\hat{\sigma}_{12}} \hat{\sigma}_{22}^{-1} x_2) &= \text{cov}(x_1 - \frac{1}{\hat{\sigma}_{12}} \hat{\sigma}_{22}^{-1} x_2, x_1 - \frac{1}{\hat{\sigma}_{12}} \hat{\sigma}_{22}^{-1} x_2) = \\ &= \hat{\sigma}_{11} - \frac{1}{\hat{\sigma}_{12}} \hat{\sigma}_{22}^{-1} \hat{\sigma}_{21} - (\frac{1}{\hat{\sigma}_{12}} \hat{\sigma}_{22}^{-1} \hat{\sigma}_{21})^T + \hat{\sigma}_{12} \hat{\sigma}_{22}^{-1} \cdot \hat{\sigma}_{22}^{-1} \cdot \frac{1}{\hat{\sigma}_{12}} \hat{\sigma}_{22}^{-1} \hat{\sigma}_{12} = \\ &= \hat{\sigma}_{11} - \frac{1}{\hat{\sigma}_{12}} \hat{\sigma}_{22}^{-1} \hat{\sigma}_{12} = \hat{\sigma}_{11,2} \end{aligned}$$

Ebből az ill. rész.

Asymptotikus Cramér-Rao:

Tétel: (Barndorff-Nelson) Tfl. (RR). Legyen $g(\theta)$ folyt. differenciálható,

$g: \Theta \rightarrow \mathbb{R}^k$. $T_n = T_n(x_1, \dots, x_n)$ becslése $g(\theta)$ -re.

Tfl. $\sqrt{n}(T_n - g(\theta)) \xrightarrow{d} N_k(0, V(\theta)) \quad \forall \theta \in \Theta$

Ekkor $V(\theta) \geq \underbrace{G(\theta) I_1(\theta)^{-1} G(\theta)^T}_{\text{információ}} \quad \text{variancia (hossz. m.m.)}$
 $I_1(\theta) = \int_{\Omega} \frac{\partial^2 \ell(\theta, x)}{\partial \theta^2} dx$ Lebesgue-m.m. θ -ra. ($G^T = g'$)

Mj. minden θ -ra az általás nem igaz.

Def. Ha minden θ -ra $V(\theta) < G(\theta) I_1(\theta)^{-1} G(\theta)^T$, akkor T_n szorosan θ -ban nyerelhető (tilthatatlan).

A tétel nem köt kötöttet a nyerelhetőségek nem lehetsége til soron.

Példa: $N(\theta, 1)$ $\theta \in \mathbb{R}$ paraméter, $g(\theta) = \theta +$ becsültü

\bar{x} terítetlen, sőt lehetséges becslés, és előre az inf. matár 1.

$I_1(\theta) = 1 \Rightarrow$ az asymptotikus inf. matár 1.

$$T_n(\bar{x}) = \begin{cases} \bar{x}, & \text{ha } |\bar{x}| \geq \alpha_n \\ c \cdot \bar{x}, & \text{ha } |\bar{x}| < \alpha_n, \quad \text{ahol } 0 \leq c < 1 \end{cases}$$

összehűtés (shrinkage) $\alpha_n > 0; \alpha_n \rightarrow 0, \sqrt{n} \alpha_n \rightarrow \infty$,

$$\text{pl. } x_n = \frac{1}{\sqrt{n}}$$

Ekkor $\sqrt{n} \cdot (T_n - \theta) \xrightarrow{d} N_{\ell}(0, V(\theta))$,

$$\text{ahol } V(0) = c^2, \quad V(\theta) = 1 \quad (\theta \neq 0)$$

$\Rightarrow (T_n)$ tilthatatlan $\theta = 0$ -ban

Penze T_n nem lehetséges terítetlen.

Becslesi módszerek

Volt: tapasztalati becsles.

Momentumos módszerek: $\theta \in \mathbb{R}^p$.

Általánosított MM-ben $u: \mathbb{X} \rightarrow \mathbb{R}^p$ fügveny, és $\varphi(\theta) := E_\theta(u(x_i))$

Olyan θ kell, amire φ invertálható.

$$\vartheta = \varphi^{-1}(E_\theta(u(x_i))) \Rightarrow \hat{\vartheta}_n := \varphi^{-1}\left(\frac{1}{n} \sum_{i=1}^n u(x_i)\right)$$

Voltaképp ez is tapasztalati becsles.

NSzET \Rightarrow ha φ^{-1} folytonos, akkor ez minden környezetben becsles, arattal a valemíniműséggel $\hat{\vartheta}_n \rightarrow \theta$ A.F.

Klasszikus MM: x koordinátai hatályfrejúej

Ha $\mathbb{X} = \mathbb{R}$, p paraméter van \Rightarrow kisszámú tiszta p momentumos.

$$\mu_1, \dots, \mu_p \text{ momentumos, ahol } \mu_i = \mu_i(\theta) = E_\theta(X_1^i)$$

$$\vartheta = \varphi^{-1}(\mu_1, \dots, \mu_p) \Rightarrow \hat{\vartheta}_n = \varphi^{-1}(\hat{\mu}_1, \dots, \hat{\mu}_p), \text{ ahol}$$

$$\hat{\mu}_i = \frac{1}{n} \sum_{k=1}^n x_k^i$$

Pé. ha az ied. mineműs, arattal a 1. momentum 0, nem érdemes azt venni.

maximum-likelihood-becsles

X minta, $f_\theta(X)$ likelihood-fv., (θ -ra névre)

$$\hat{\theta} = \hat{\theta}(X) = \arg \max_{\theta} f_\theta(X)$$

$\hat{\theta}$ nem biztos, hogy létezik, és nem feltétlenül egyértelmű.

Ha $\theta \mapsto f_\theta(X)$ diffi \Rightarrow ekkor $\partial f_\theta(X)$ zálogja nincs

n elemű minta esetén az egymás likelihood $\prod_{i=1}^n f_\theta(x_i)$, ennek logaritmusát van maximálva, ahol a logaritmusszabály:

$$L(\theta) = \sum_{i=1}^n \log f_\theta(x_i) = \sum_{i=1}^n l_i(\theta), \text{ ezt ellenőrizzük deriváltai.}$$

$$\partial L(\theta) = 0 \quad \text{likelihood-ezenfelül}$$

Tulajdonságok

① Nem függ a domináló mérőtől (a sv. függ!)

Ha μ^a eredélyes val. mérő, és λ felsz. dom. mérő,
akkor $\mu \ll \lambda$ (mert λ dominálja az egész P-t)

$$\Rightarrow \frac{dP_\theta}{d\lambda} = \frac{dP_\theta}{d\mu} \cdot \underbrace{\frac{d\mu}{d\lambda}}$$

λ -tól független \Rightarrow a max. likely növekedik lesz.
(azaz az érték nem!)

$$\operatorname{argmax}_{d\mu} \frac{dP_\theta}{d\mu} = \operatorname{argmax}_{d\lambda} \frac{dP_\theta}{d\lambda}$$

② Ha \exists ML-belecs., akkor olyan is van, mely az elégiség stat. fréq.

A maxlikely halvaya az elégiség stat. fréq.:

ha μ eredélyes mérő, akkor $f_\theta(x) = g_\theta(T(x))$ (T egs.)

Példa: $\mu [0, \theta + 1]$ -osz ML S-va.

maxlikely halvaya:

$$x_{n+1}^* \leq \theta \leq x_1^*, \text{ az } x_1^*, x_n^* \text{ elégiség}$$

$$\Rightarrow \hat{\theta}_1 = x_1^* \text{ jd}, \quad \hat{\theta}_2 = x_1^* - (x_1^* - x_{n+1}^* + 1) \cdot \frac{|x|}{1+|x|} \text{ nem jd } n \geq 3 \text{-ra},$$

akkor $\hat{\theta}_2$ nem van csak min
és csak van a mintából

2017.03.29.

Legyen $g: \Theta \rightarrow \Gamma$.

Def. $\forall \gamma \in \Gamma$ -ra $\tilde{f}_\gamma := \sup_{\theta \in \Theta} \{f_\theta \mid g(\theta) = \gamma\}$ Lehár felé indirekt likelihood-fü.

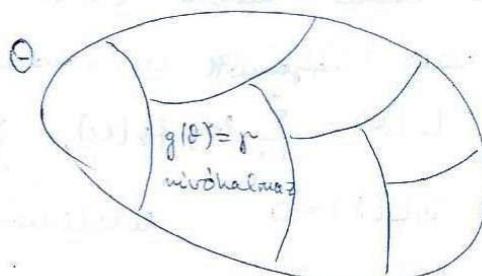
$g(\theta)$ ML-belecs. $\hat{g}(X) = \operatorname{argmax}_{\theta \in \Theta} \tilde{f}_\gamma(X)$

El. $\hat{\theta}$ ML-belecs. θ -nál $\Rightarrow g(\hat{\theta})$ ML-belecs. $g(\theta)$ -nál.

$$\text{B: } \sup_{\theta \in \Theta} f_\theta = \sup_{\gamma \in \Gamma} \tilde{f}_\gamma \geq \tilde{f}_{g(\hat{\theta})} \geq f_{\hat{\theta}} =$$

$$= \sup_{\theta \in \Theta} f_\theta$$

$$\Rightarrow \tilde{f}_{g(\hat{\theta})} = \sup_{\gamma \in \Gamma} \tilde{f}_\gamma, \text{ és ez zálelt.}$$



Ezután elég a paraméter ML-belecsit vizsgálni,

Mikor azs. tulajdonságai vanak a ML-becslésnek?

Tétel (RR) \Rightarrow a paraméter ML-becslése érősen konsztans, és

- (1) 1 val. & elegendő nagy n-re a likelihood-egyenletnek van györe, sőt van olyan $\hat{\theta}_n$ is, mely a likelihood-fn. loc. maximuma, és csak egyetlen konsztans, tehát $\hat{\theta}_n \rightarrow \theta$ P.s.m. Vd.
- (2) Egy a $\hat{\theta}_n$ -ra $\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{d} N_p(0, I(\theta)^{-1})$

Mi: it Bahadur-tétel nevűt $\hat{\theta}_n$ asymptotikusan optimális: az ar. Kovarianciamatrix eléri az info. határát.

1. rész

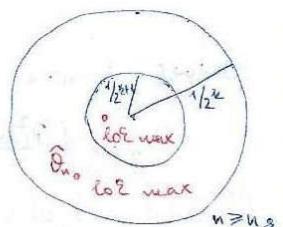
B.(1) Megmutatjuk, hogy & elég csak exponenciális 1 val. & elég nagy n-re

$$\sup_{\|u\|=\epsilon} \frac{1}{n} L(\theta+u) < \frac{1}{n} L(\theta) \quad (*)$$

Ebből mi köv., hogy a görbék van maximum, és az nem lehet e felünen \Rightarrow az e megfelelő belsőpontban van $L(\cdot)$ maximum, ami loc. maximum, jöölje $\hat{\theta}_n$, és erről $\partial L(\hat{\theta}_n) = 0$.

Megadható $n_1 < n_2 < \dots$ véletlen rögzítések, hogy $n \geq n_2$ esetén már a θ köüli $\frac{1}{2}\epsilon^2$ sugarú görbék, van $\hat{\theta}_n$.

$$\Rightarrow \hat{\theta}_n \rightarrow \theta \text{ 1 val.}$$



Igazoljuk, hogy $(*)$ -öt!

$$\frac{1}{n} L(\theta+u) = \frac{1}{n} L(\theta) + \frac{1}{n} \partial L(\theta) u + \frac{1}{2n} u^T \partial^2 L(\theta) u + R_n$$

$$\text{Taylor-sor, } |R_n| \leq \frac{\|u\|^2}{2} \sup_{\|\theta-\theta\| \leq \epsilon} \left\| \frac{\partial^2 L(\theta)}{n} - \frac{\partial^2 L(\theta)}{n} \right\| \quad (\text{Taylor-formula})$$

$$= \frac{\epsilon^2}{2} \sup_{\|\theta-\theta\| \leq \epsilon} \left\| \frac{\partial^2 L(\theta)}{n} - \frac{\partial^2 L(\theta)}{n} \right\|$$

a görbék a 2. derivált

Itt a norma az operátornorma (de ez minte mindenleg).

$$\begin{aligned} \sup_{\|\theta-\theta\| \leq \epsilon} \left\| \frac{1}{n} \partial^2 L(\theta) - \frac{1}{n} \partial^2 L(\theta) \right\| &= \sup_{\|\theta-\theta\| \leq \epsilon} \left\| \frac{1}{n} \sum_{i=1}^n (\partial^2 l_i(\theta) - \partial^2 l_i(\theta)) \right\| \leq \left| \begin{array}{l} L(\theta) = \sum_{i=1}^n l_i(\theta) \\ \text{fleu., minden } i \end{array} \right. \\ &\leq \frac{1}{n} \sum_{i=1}^n \underbrace{\sup_{\|\theta-\theta\| \leq \epsilon} \|\partial^2 l_i(\theta) - \partial^2 l_i(\theta)\|}_{\text{fleu., minden } i} \end{aligned}$$

NSET miatt ez rövidítés

$$\rightarrow E_{\theta} \left(\sup_{\|\theta - \theta^*\| \leq \varepsilon} \|\partial^2 \ell_i(\theta) - \partial^2 \ell_i(\theta^*)\| \right) =: \eta(\varepsilon)$$

$\lim_{\varepsilon \searrow 0} \eta(\varepsilon) = 0$. Mert $\partial^2 \ell_i$ folytonos (RR) miatt, ezért a $\sup \rightarrow 0$ től, és van intuitív majoráns: $2 \sup \|\partial^2 \ell_i(\theta)\|$ (kulonbság nem növekszik), ez (RR) miatt intuitív Dominált szomsz.-tétel.

\Rightarrow Ha n elég nagy, akkor $\sup_h |R_n| < \varepsilon^2 \cdot \eta(\varepsilon)$ becslés a variancia-fogra

$$\frac{1}{n} \partial L(\theta) = \frac{1}{n} \sum_{i=1}^n \partial \ell_i(\theta) \xrightarrow[\text{NSET}]{\text{(RR)}} E_{\theta} (\partial \ell_i(\theta)) = 0$$

$$\Rightarrow \sup_{\|h\|=\varepsilon} \frac{1}{n} \partial L(\theta) \cdot h = o(\varepsilon), \text{ ezért elég nagy } n \text{-re } < \varepsilon^2 \cdot \eta(\varepsilon),$$

számítás

tehet meggyes a becslés jól az 1. fogra is.

Most a 2. tag:

$$\sup_{\|h\|=\varepsilon} h^T \frac{\partial^2 \ell(\theta)}{n} h \leq \varepsilon^2 \cdot \lambda_{\max} \left(\frac{\partial^2 \ell(\theta)}{n} \right)$$

\uparrow
a max. részről az argumentumról

$$\frac{\partial^2 \ell(\theta)}{n} = \frac{1}{n} \sum_{i=1}^n \partial^2 \ell_i(\theta) \xrightarrow[\text{NSET}]{\text{(RR)}} E_{\theta} (\partial^2 \ell_i(\theta)) = -I(\theta)$$

Mivel λ_{\max} folytonos fréje a mátrixok additív, vagy

$$\lambda_{\max} \left(\frac{\partial^2 \ell(\theta)}{n} \right) \rightarrow \lambda_{\max} (-I(\theta)) = -\lambda_{\min} (I(\theta)) < 0$$

$\frac{\lambda_{\min}}{2}$
 \downarrow
pot. def. $\quad -\lambda_{\min}$

$$\Rightarrow \forall \text{ elég nagy } n \text{-re } \sup_{\|h\|=\varepsilon} \frac{1}{2} h^T \frac{\partial^2 \ell(\theta)}{n} h < -\frac{\varepsilon^2}{4} \lambda_{\min}(I(\theta))$$

\downarrow
ide erie elég nagy
 $n \text{-re}$

$$\Rightarrow \sup_{\|h\|=\varepsilon} \left(\frac{1}{n} L(\theta+h) - \frac{1}{n} L(\theta) \right) < \varepsilon^2 \left(2\eta(\varepsilon) - \frac{1}{4} \lambda_{\min} \right) < 0, \text{ itt}$$

$$\varepsilon \text{ elég kicsi}, \text{ csak ha } \eta(\varepsilon) < \frac{1}{8} \lambda_{\min}(I(\theta))$$

$$(2) Tükrük, hogy $\hat{\theta}_n \rightarrow \theta$, $\sqrt{n} (\hat{\theta}_n - \theta) = \hat{\theta}_n - \theta = \frac{\hat{\theta}_n - \theta}{\sqrt{n}} \rightarrow 0$.$$

$$0 = \frac{1}{\sqrt{n}} \partial L(\hat{\theta}_n)^T = \underbrace{\frac{1}{\sqrt{n}} \partial L(\theta)^T}_{\text{sorties}} + \underbrace{\frac{1}{\sqrt{n}} \partial^2 L(\theta) (\hat{\theta}_n - \theta)}_{\frac{1}{n} \partial^2 L(\theta)} + R_n^2, \text{ ahol}$$

$$\|R_n^2\| \leq \|h_n\| \cdot \sup \left\| \frac{1}{n} \partial^2 L(\theta) - \frac{1}{n} \partial^2 L(\theta') \right\|$$

$$\|\theta - \theta'\| \leq \|h_n\| \cdot \frac{1}{\sqrt{n}} = \|\hat{\theta}_n - \theta\|$$

Ha n elég nagy, akkor $\|R_n^2\| \leq \|h_n\| \cdot \sup \underbrace{\left\| \frac{1}{n} \partial^2 L(\theta') - \frac{1}{n} \partial^2 L(\theta) \right\|}_{\|\theta - \theta'\| \leq \varepsilon} < 2 \cdot n(\varepsilon)$, ha n elég nagy.

$$\Rightarrow \|R_n^2\| \leq \|h_n\| \cdot 2 \cdot n(\varepsilon) \quad \forall \varepsilon \text{ van minden, ami körül van igaz.}$$

De $n(\varepsilon)$ bárhány kicsi lehet $\rightarrow \|R_n^2\| = o(\|h_n\|)$.

$$\frac{1}{n} \partial^2 L(\theta) \rightarrow -I(\theta) \quad (\text{ez már láttuk})$$

$$h_n = \left[-\frac{1}{n} \partial^2 L(\theta) \right]^{-1} \cdot \left[\frac{1}{\sqrt{n}} \cdot \partial L(\theta)^T + R_n^2 \right]$$

$\downarrow n \rightarrow \infty$

$I(\theta)^{-1}$

$$\frac{1}{\sqrt{n}} \cdot \partial L(\theta)^T = \frac{1}{\sqrt{n}} \sum_{i=1}^n \underbrace{\partial l_i(\theta)^T}_{\text{flecn, az. eo., vételtek vételek}}$$

$$E(\partial l_i(\theta)^T) = 0 \quad (\text{RR miatt}, \sum_{\theta} (\partial l_i(\theta)^T) = I(\theta))$$

Többdimenziós CHT: $\underbrace{\frac{1}{\sqrt{n}} \sum_{i=1}^n \partial l_i(\theta)^T}_{\frac{1}{\sqrt{n}} \partial L(\theta)^T} \xrightarrow{d} N_p(0, I(\theta))$

$\Rightarrow h_n$ a Cramér-Szűcsij-lemma többdimenziós változata miatt elég. eur.: $h_n \xrightarrow{d} I(\theta)^{-1} \cdot N_p(0, I(\theta)) = N_p(0, I(\theta)^{-1})$ \square

Megj.: Ha meg teljesül a

(*) $\lim_{\delta \searrow 0} \liminf_{n \rightarrow \infty} P_{\theta} \left(\sup_{\|\theta - \theta'\| \geq \delta} \left(\frac{1}{n} \cdot L(\theta + \theta') - \frac{1}{n} L(\theta) \right) < -\delta \right) = 1$
feltély akkor a tételes ML-féle módszer is igaz.

Ez egy teljesen ellenőrizhető feltétel.

Bayes-becslés

Itt eddigiek a fővonalta hozzállás.

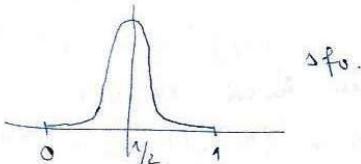
Bayes-féle hozzállás: a θ paraméter is val. változó, értékeit t -vel jelöljük, mely megfelelőbbessé t a v.v.-t az előző.

Vannak előzetes (a priori) eloszlásai a kerest eloszlásról:

θ eloszlása Q val. mérte a $\Theta \subset \mathbb{R}^p$ Borel-halmazain.

Meg köszönjük, hogy ez tartalmaz a előzetes inf.

Pk. pénzme működéséigényével



sfo.

Minta: X , most P_t az X felt. eloszlása a $\theta = t$ feltétele mellett. $P_t(B) = P(X \in B | \theta = t)$.

X (feltétele nélküli) eloszlása az in. precízióról eloszlás

$$\text{A TTV-val } P_Q(B) = P(X \in B) = \int_{\Theta} P_t(B) Q(dt) \quad \text{keresi eloszlás}$$

θ feltételezés eloszlása $X = x$ mellett:

$Q^*(\cdot | x)$ a posteriori eloszlás (többszörösen utáni)

Bayes-tétel: P -m.m. $x \in X$ esetén $Q^*(\cdot | x) \ll Q$ és a

(new Bayes bz.)

$$\frac{dQ^*(\cdot | x)}{dQ}(t) = \frac{f_t(x)}{f_Q(x)}$$

ahol P_t störzje f_t (valamelyen \mathcal{X} -ra),

P_Q störzje f_Q (magamra a \mathcal{X} -ra).

$$\Rightarrow f_Q(x) = \int_{\Theta} f_t(x) Q(dt). \quad \text{a faktor nem.}$$

Mj. Spec. ha Q -nak van (pl. lebesgue) störzje: $q(t)$, akkor

$$Q^*(\cdot | x)-ver is, és annak a störzje $q^*(t | x) = \frac{f_t(x) q(t)}{f_Q(x)}$.$$

Mj. Ha \mathcal{X} is Ω diszkr., és a sűrűségr.-ról a némánakéntére vonatkozóan nincs, akkor használjuk a zökönleges Bayes-tételt.

Stat. mérő helyett egyetemi val. mérőrére von, X és θ a rét val. várakoz. Egyéb esélyes eloszlása az $\mathbb{X} \times \Theta$ területén (a norm. σ -algebrával): $B \subset \mathbb{X}$, $C \subset \Theta$ mérhetőre $P(B \times C) =$

$$= \int_C P_t(B) Q(dt)$$

↑
az nem ugyanaz,
minthető a P

Ez rögzítendő esélyterületen a norm. σ -algebrára. \rightarrow általánosított mérőműködés.

Def. $g(\theta)$ Bayes-becslése az a (illetve: egy olyan) $T(X)$ statisztikára, melyre $E(\|T(X) - g(\theta)\|^2)$ minimális.

Tudjuk, hogy van minimálás T , és ez esélyterületi: az őpp a feltételezett változó érték, hisz itt L^2 -tárolásig minimálásról van mű, és a felt. v. d. őpp egy L^2 -változó.

\Rightarrow a $\hat{g}(X)$ Bayes-becslése $\hat{g}(X) = E(g(\theta) | X)$, ahol

$\hat{g}(X)$ a $g(\theta)$ a posteriori változó értéke, ahol

$$\hat{g}(X) = \int_{\Theta} g(t) Q^*(dt | X) = \frac{\int_{\Theta} g(t) f_t(x) Q(dt)}{\int_{\Theta} f_t(x) Q(dt)}$$

$\Rightarrow \hat{g}$ az a posteriori változó értéke.

All. A Bayes-becslés az elég. stat. fréqúencia módszerrel.

2017.04.05.

B: Már az a posteriori becslés is az őps. stat. fréqúencia módszerrel:

$$f_t(x) = g_t(T(x)) \cdot u(x) \quad (T \text{ őps.})$$

$$\Rightarrow f_Q(x) = u(x) \cdot \int_{\Theta} g_t(T(u)) \cdot Q(dt)$$

$$\Rightarrow \frac{dQ^*(\cdot | x)}{dQ}(t) = \frac{f_t(x)}{f_Q(x)} = \frac{g_t(T(x))}{\int_{\Theta} g_s(T(x)) Q(ds)}$$

Egyetlenül $\hat{g}(x) = E(g(\theta) | X)$ $P_{\theta, Q}$ -minim. esélyterület

Ahol: $P_Q(B) = \int_{\Theta} P_t(B) Q(dt) \Rightarrow P_{\theta, Q}$ -minim. = Q -minim. t-re P_t -minim.

$\checkmark P$ -minim. = $\forall t$ -re P_t -minim.

Ez nem mindenkor ugyanaz, de gyakran igaz (Q -függő)

Megengedhetőségek? Legyen $\hat{g}(X)$ Bayes-becsles, T egyszeresen jobb valószínűséggel.

Legyen S tetszőleges becsles, $\hat{g}(X)$ minimalitája az

$R_S(Q) = \mathbb{E}(\|S(X) - g(\theta)\|^2)$ ahol a priori valószínűséget, azaz a minimális Bayesi valószínűséget.

$$\begin{aligned} \text{TVET: } R_S(Q) &= \mathbb{E}\left(\mathbb{E}\left(\|S(X) - g(\theta)\|^2 \mid \theta\right)\right) = \\ &= \int_{\Theta} \mathbb{E}\left(\|S(X) - g(t)\|^2 \mid \theta=t\right) Q(dt) \\ &= \int_{\Theta} \underbrace{\mathbb{E}_t(\|S(X) - g(t)\|^2)}_{R_S(t)} Q(dt), \end{aligned}$$

$R_S(t)$ megnyílt valószínűségi funkció.

$$\text{tény: } R_S(Q) = \int_{\Theta} R_S(t) Q(dt)$$

Ez filozofikailag is elfogadhatóval tenni a Bayes-becslestermeléshez kapcsolódóan a törzsfüggvényet. (Ahol a priori becslés megbízhatósága penze marad.)

Visszaférve a megengedhetőségekhez: $R_T(t) \leq R_{\hat{g}}(t)$

$$\Rightarrow R_T(Q) \leq R_{\hat{g}}(t). \quad < \text{new becslés, esetleg } =$$

$\Rightarrow T$ is Bayes-becsles.

Esztétikai Bayes-becsles szempontjából, aránylag meghatározott.

Törzsfeltevés

Ull.: A Bayes-becsles — trivi esetben elkerülve — nem törzsfeltevés.

Ellenpéldák: díszjelentő törzsfeltevés a minta meghonosítása mögött valójában előfordulhat.

A minimalitás ilyen fogalmazáshoz meg:

$$Q-\text{minimális } t_1, t_2 \text{ esetén } g(t_1) \neq g(t_2) \Rightarrow P_{t_1} \perp P_{t_2}$$

B: $\hat{g}(X) = \mathbb{E}(g(\theta) \mid X)$ Bayes-becsles, törzsfeltevés,

azaz $\forall t \quad \mathbb{E}_t(\hat{g}(X)) = g(t)$, vagyis $\mathbb{E}(\hat{g}(X) \mid \theta) = g(\theta)$ val.

$$\mathbb{E}(\|\hat{g}(X) - g(\theta)\|^2) = \mathbb{E}(\|\hat{g}(X)\|^2) + \mathbb{E}(\|g(\theta)\|^2) - 2 \mathbb{E}(\hat{g}(X)^T g(\theta))$$

$$\mathbb{E}(\hat{g}(X)^T g(\theta)) \stackrel{\text{TVET}}{=} \mathbb{E}(\mathbb{E}(\hat{g}(X)^T g(\theta) \mid X)) =$$

$$= \mathbb{E}(\hat{g}(X)^T \cdot \mathbb{E}(g(\theta) \mid X)) =$$

$$= \mathbb{E}(\hat{g}(X)^T \cdot \hat{g}(X)) = \mathbb{E}(\|\hat{g}(X)\|^2)$$

$$\mathbb{E}(\hat{g}(X)^T g(\theta)) \stackrel{\text{TVET}}{=} \mathbb{E}(\mathbb{E}(\hat{g}(X)^T g(\theta) \mid \theta)) =$$

$$= \mathbb{E}(\mathbb{E}(\hat{g}(X)^T \mid \theta) \cdot g(\theta)) \stackrel{\text{törzsfeltevés}}{=} \mathbb{E}(g(\theta)^T \cdot g(\theta)) = \mathbb{E}(\|g(\theta)\|^2)$$

$$\Rightarrow E(\|\hat{g}(x) - g(x)\|^2) = 0 \Rightarrow \hat{g}(x) = g(x) \text{ P-m.m.}$$

\Rightarrow Q-m.m. t esetén $\hat{g}(x) = g(t)$ P_t-m.m. x-re.

\Rightarrow ha $g(t_1) \neq g(t_2)$, akkor $P_{t_1} \perp P_{t_2}$

Asymptotikus viseldeles

All. (RR) + (*) es az a priori eloszlás Lebesgue-alatt. poltg. Θ -n, $g(t) > 0$, (BN)

$$\int_{\Theta} \|t\| \cdot q_p(t) dt < \infty. \text{ Error a } \hat{g}_n \text{ Bayes-Becslés (n elemű mintától)$$

$$\text{stánoit: } \sqrt{n} (\hat{g}_n - g) \Big|_{t=t \text{ feltélel}} \xrightarrow{d} N(0, I_n(t)^{-1})$$

negatív dimenziós

nemális

igaz m.m. t-re.

All Ha a $\hat{g}(x)$ Bayes-Becslés visszaférje hosszú, akkor a Bayes-Becslés minimax.

B: Legyen T tetszőleges Becslés.

$$\sup_t R_{\hat{g}}(t) = \int_{\Theta} R_{\hat{g}}(t) Q(dt) \stackrel{\text{Bayes minimalista a }}{\leq} \int_{\Theta} R_T(t) Q(dt) \leq \sup_t R_T(t)$$

Hipotézisvizsgálat

$$\mathcal{P} = \{ P_\theta : \theta \in \Theta \}$$

Hipotézis: $P_0 \subseteq \mathcal{P}$, $P_0 \neq \emptyset$

Ervállás: $\Theta_0 \subseteq \Theta$, $\Theta_0 \neq \emptyset$ -ra $P_0 = \{ P_\theta : \theta \in \Theta_0 \}$.

Nullhipotézis: $\theta \in \Theta_0$, aazat $P \in P_0$. Tel.: H_0 Et lépési ut cérvezet.

Ellenhipotézis: $\theta \in \Theta_1 = \Theta \setminus \Theta_0$; aazat $P \in P_1 = \mathcal{P} \setminus P_0$, Tel.: H_1 .

Mivel a null-, mind az ellenhipotézist meg kell mondani.

Minta alapján döntünk: elfogadjuk vagy elvetjük H_0 -t.

$X = X_0 \sqcup X_1$, X_0 a elfogadási tartomány: $X \in X_0$ -ra elfogadjuk H_0 -t,
 X_1 a utasítás tartomány: $X \in X_1$ -re elvetjük H_0 -t.

A libás döntés típusai:

1) H_0 igaz, de elvetettük \rightarrow elsőfajú liba

Et his esélyel akarunk elkövetni, mert H_0 az, amit elvettük.

2) H_0 hamis, de elfogadtuk \rightarrow másodfajú liba

Civel se örülik, de inkább ett eugedjük.

A rit liba valszínűsége csökkenő irányban nő.

A döntést hívjuk (statistikai) problémát.

(X_0, X_1) próba esetén $\psi(\theta) = P_\theta(\text{elvetjük } H_0\text{-t}) = P_\theta(X_1)$ elutáritás fr.

$\theta \in \Theta_0$ -ra $\psi(\theta)$ a elsőfajú liba valószínűsége.

$\theta \in \Theta_1$ -re $\psi(\theta)$ a jó döntés valószínűsége, $1 - \psi(\theta)$ a másodfajú liba valszínűsége. Et a próba ereje θ -ban.

$\psi|_{\Theta_1}$ erőfeszítés

A próba terjedelme $\sup_{\Theta_0} \psi(\theta)$,

Ene norott felső korlát leni, pl. $\alpha = 0.05$

A próba minimális terjedelme: $1 - \psi(\theta)$ a gyakran %-ban.

Problák összetartozása:

φ_1, φ_2 rit próba, ψ_1, ψ_2 erőfeszítés

Error φ_1 egyenletesen erősebb φ_2 -nél, ha $\psi_1(\theta) \geq \psi_2(\theta) \quad \forall \theta \in \Theta_1$.
(nem szükséges)

A φ_1 és φ_2 erősségeket, ha az elutáritás frinnél $\forall \theta \in \Theta$ -ra megegyezik.

Légyen \mathcal{D} próbaé ész országa. (pl. $\leq \alpha$ terjedelmi próbaé)

$\varphi \in \mathcal{D}$ egyenletesen legerősebb (optimalis), ha egyenletesen erősebb minden \mathcal{D} -beli próbánál.

Egy φ próba törzstételű, ha φ ereje $\geq \varphi$ terjedelme

Olyan próbat aranyozunknak, amik, ha csak lehet, elfogadják H_0 -t, el arányuk kisebb az elvártuknál. Akkor ezzel elutasítják H_0 -t, ha az elterés már signifikáns. Mivelük az információ abban van, hogy elvártjuk.

Általánosítás: véletlenített (randomizált) próbaé.

Próba: $\varphi: \mathcal{X} \rightarrow [0,1]$ statisztika (próbafü.)

Ha X a minta, $\varphi(X)$ mondja meg, milyen valószínűséggel vettük el H_0 -t.

Mire jó ez? Ehhez nem les több infóra. Ez arra hármasít, hogy a teljes megengedettséget terjedelmet elvesszük. (diszkrét eset)

Az eddigi próbaé deterministaek, ezenél $\varphi = I(\mathcal{E}_1)$ indikátor volt.

Elutasításf. $\psi(\mathcal{E}) = P_{\mathcal{G}}(\text{elvárt}) = \mathbb{E}_{\mathcal{G}}(P_{\mathcal{G}}(\text{elvárt} | X))$,
tehát $\psi(\mathcal{E}) = \mathbb{E}_{\mathcal{G}}(\varphi(X))$

Jelen részben minden funkció definíció működik az általánosított esetben is.

A: Minden próbatörzs \exists való elvártus próba, mely az elégsges stat. következménye.

B: $\varphi^*(X) := \mathbb{E}_{\mathcal{G}}(\varphi | T)$ próbatörzs. (mert a való. esetben $[0,1]$ -beli len),
ez a T egyszerű stat. függeszeti. $\mathbb{E}_{\mathcal{G}}(\varphi^*) = \mathbb{E}_{\mathcal{G}}(\varphi) \quad \forall \mathcal{E}$. □

A próbaé szakrál olyan akciáról, hogy van ezs T egyszerű. próbatörzstatisztika és $c = c_\alpha$ crit. érték, és elvártjuk H_0 -t, ha $T(X) > c_\alpha$. $T(X)$ meri, hogy megnöve húr el H_0 -köl.

D: A p-érték amar a H_0 melletti valószín, hogy $T(X)$ legalább arra, mint tanti kapta. Ha et $< \alpha$, akkor elvártjuk H_0 -t.

Dkt. Egy hipotézis (H_0 vagy H_1) ellenőrzi, ha az adott elosztás van vétele. Különben összetett.

Legegyenűbb feladat: ellenőri H_0 és ellenőri H_1 .

$$\rightarrow \mathcal{P} = \{P_0, P_1\}, \quad H_0 = \{P_0\}, \quad H_1 = \{P_1\}.$$

Ez dominált, pl. $P_0 + P_1$ dominál. \rightarrow itt van néha a szükséges feltétel.

$$\text{Tel. } T(x) = \frac{f_1(x)}{f_0(x)} \text{ likelihood-ratio-statistika.}$$

Lemma. (Neyman-Pearson)

$$(1) \text{ Legyen } \varphi = \begin{cases} 1, & \text{ha } T(x) > c \\ \text{teh.,} & \text{ha } T(x) = c, \text{ akkor a tetszőleges } [0, 1]\text{-ban} \\ 0, & \text{ha } T(x) < c \end{cases} \text{ őrtű.}$$

Ez a próba legrosszabb a való való nagyobb terjedelműk részére.

$$(2) \forall \alpha \in (0, 1) \exists c_\alpha \geq 0, \quad p_\alpha \in [0, 1], \quad \text{ilyen, hogy a}$$

$$\varphi(T) = \begin{cases} 1, & \text{ha } T > c_\alpha \\ p_\alpha, & \text{ha } T = c_\alpha \text{ próba terjedelme. } \alpha. \\ 0, & \text{ha } T < c_\alpha \end{cases}$$

$$(3) \text{Tf. } \varphi' \text{ legrosszabb a legfeljebb } \alpha \text{ terjedelműk részére.}$$

Eller m.m. x -re olyan, mint (1)-ben.

Továbbá φ' terjedelme pontosan α , vagy az erreje 1.

2017.04.19.

B: (1) Izzolje φ terjedelmét α , errejét ψ

Legyen φ' próba, $\alpha' \leq \alpha$, errejé ψ' .

$$\psi - \psi' = \int_{\mathbb{X}} \varphi f_1 d\lambda - \int_{\mathbb{X}} \varphi' f_1 d\lambda = \int_{\mathbb{X}} (\varphi - \varphi') f_1 d\lambda = *$$

$$\mathbb{X} = \mathbb{X}_+ \cup \mathbb{X}_0 \cup \mathbb{X}_-, \quad \text{ahol} \quad \mathbb{X}_+ = \{x \in \mathbb{X} \mid f_1(x) > c f_0(x)\} = \\ \mathbb{X}_0 = \{x \in \mathbb{X} \mid f_1(x) = c f_0(x)\} \\ \mathbb{X}_- = \{x \in \mathbb{X} \mid f_1(x) < c f_0(x)\}$$

$$* = \int_{\mathbb{X}_+} + \int_{\mathbb{X}_0} + \int_{\mathbb{X}_-} \geq;$$

$$\textcircled{1} \int_{\mathbb{X}_+} (1-\varphi) \frac{c f_0}{f_1} d\lambda + \int_{\mathbb{X}_0} (\varphi - \varphi') c f_0 d\lambda + \int_{\mathbb{X}_-} (0-\varphi') c f_0 d\lambda =$$

$$= c \int_{\mathbb{X}} (\varphi - \varphi') f_0 d\lambda = c \cdot (\alpha - \alpha') \textcircled{2} 0 \Rightarrow \varphi errejé negatív-egyenlő$$

(2) $t \mapsto P_0 \left(\frac{f_t(x)}{f_0(x)} \geq t \right)$

\uparrow
a nevező 1-val
pontosan
(v.v. a szűrőjeleit)

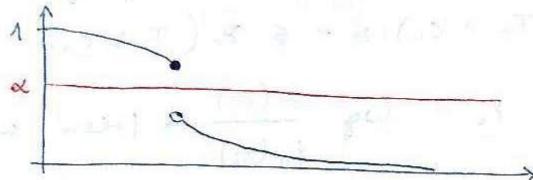
$t = 0$ - ben 1

$t \rightarrow \infty$ - ben 0

Balról folytonos

monoton fogyó

$$c := \sup_{\overline{T}} \left\{ t \mid P_0 \left(\frac{f_t(x)}{f_0(x)} \geq t \right) > \alpha \right\}$$



Ha most $P_0(T = c) > 0$

$$\rightarrow \text{legyen } p := \frac{\alpha - P_0(T > c)}{P_0(T \geq c) - P_0(T > c)} \in (0, 1],$$

másrólönben legyen $p := 0$.

Erre $E_0(\varphi) = \underbrace{P_0(T > c)}_{=\alpha} + P_0(T = c)p$ az elvetés visszége
= az mindenről eredő.

(3) Tf. φ' legf. α terjedelmi optimalis (azaz legnöveltebb) próba.
Legyen φ a (2)-ben kapott partosan α terjedelmi próbájú

- miatt legnöveltebb α legf. α terjedelmiel köszönhető.

$$\Rightarrow \varphi = \varphi'$$

Az (1) bonyolításában lincs egyszerűsítésben - mindenről
egyszerűség kell álljon.

$$\left. \begin{array}{l} \text{1. egyszerűség:} \\ \Rightarrow X_+ - \text{on } \lambda-\text{m.m. } \varphi' = 1, \\ X_- - \text{on } \lambda-\text{m.m. } \varphi' = 0. \end{array} \right\}$$

$\Rightarrow \varphi'$ m.m. X -re alkja, mint az (1)-beli példát monda.

2. egyszerűség:

$$\alpha = \alpha' \quad \text{vagy } c = 0$$



H. mellett $P_1(f_1(x) > 0) = 1 \rightarrow 1$ val. esetünk

$$\text{De } \frac{f_1(x)}{f_0(x)} > 0 \Rightarrow \text{az előző 1.}$$

a terjedelmi

α

□

Asymptotische Elemente

$$n \text{ Elemente mita, } T_n = \frac{\prod_{i=1}^n f_1(x_i)}{\prod_{i=1}^n f_0(x_i)}, \text{ cu exit. este } \bar{x}$$

$$P_0(T_n > c_n) \leq \alpha \leq P_0(T_n < c_n)$$

Def. $y_i = \log \frac{f_0(x_i)}{f_1(x_i)}$ \Rightarrow fthen annes eo:

teilul negativ logarithm verneur

$$P_0\left(\sum_{i=1}^n y_i < -\log c_n\right) \leq \alpha \leq P_0\left(\sum_{i=1}^n y_i > -\log c_n\right)$$

Def.

$$\text{fle. } D^2(y_1) = \sigma^2 < \infty$$

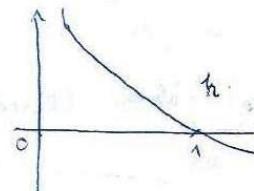
$$E_0(y_i) = \int \log \frac{f_0}{f_1} f_0 d\lambda = D(P_0 \parallel P_1)$$

Et P_0 is P_1 (információs) divergenciája,
a relativ entropia,

ill. P_0 is P_1 Kullback - Leibler - távolsága. (Ezer mind átverés)

Altas. Fennall, hogy $D(P_0 \parallel P_1) \geq 0$ és $0 \Leftrightarrow P_0 = P_1$

B: $h(x) = -\log x$ konvex,



$$D(P_0 \parallel P_1) = E_0\left(h\left(\frac{f_1(x)}{f_0(x)}\right)\right) \geqslant$$

$$\geqslant h\left(E_0\left(\frac{f_1(x)}{f_0(x)}\right)\right) =$$

$$= h\left(\int_{\{f_0 > 0\}} \frac{f_1}{f_0} \cdot f_0 d\lambda\right) = h\left(\underbrace{\int_{\{f_0 > 0\}} f_1 d\lambda}_{\leq 1}\right) \geq 0$$

Egyenlőség $\Leftrightarrow \frac{f_1(x)}{f_0(x)} = \text{konstans } P_0$ -nál, $f_1(x) = c \cdot f_0(x)$,

$$\int_{\{f_0 > 0\}} \frac{f_1}{f_0} \cdot f_0 d\lambda = 1 \Rightarrow c = 1 \Rightarrow f_1 = f_0$$

$$P_0\left(\frac{\sum_{i=1}^n y_i - n D(P_0 \parallel P_1)}{\sqrt{n} \sigma} < \frac{-\log c_n - n D(P_0 \parallel P_1)}{\sqrt{n} \sigma}\right) \leq \alpha \leq P(\dots \leq \dots)$$

Erre zappjuk \downarrow standardizálásval.

$N(0,1)$

Emiatt:

$$P\left(\frac{\sum y_i - n D(P_0 \parallel P_1)}{\sqrt{n} \sigma} \leq t_n\right) \rightarrow \Phi(t) \Leftrightarrow t_n \rightarrow t$$

$$\Rightarrow \frac{-\log C_n - n D(P_0 \parallel P_1)}{\sqrt{n}} \rightarrow \Phi^{-1}(\alpha)$$

Mj. $\Phi(-t) = 1 - \Phi(t)$

$$\Rightarrow \Phi^{-1}(\alpha) = -\Phi^{-1}(1-\alpha)$$

$$\Leftrightarrow \frac{-\log C_n - n D(P_0 \parallel P_1)}{\sqrt{n}} = -\Phi^{-1}(1-\alpha) + o(1)$$

All.

$$C_n = \exp\left(-n D(P_0 \parallel P_1) + \sqrt{n} \Phi^{-1}(1-\alpha) + o(\sqrt{n})\right),$$

bármilyen ilyen alaki C_n sorozattal a próba terjedelme $n \rightarrow \infty$ mellett $\rightarrow \alpha$.

Körülhető esetben D is török námitab, $o(\sqrt{n})$ -et elhagyjuk \Rightarrow α -hoz tartó C_n .

All. A likelihood-ratio-próba erje (ψ_n) exp. sebességgel tart 1-hez (kérhet a próba ellenőrzés).

B:

$$\begin{aligned} 1 - \psi_n &= P_1(\text{elfogadás}) \leq P_1\left(\frac{\prod_{i=1}^n f_0(x_i)}{\prod_{i=1}^n f_1(x_i)} \leq c_n\right) = \\ &= P_1\left(\frac{\prod_{i=1}^n f_0(x_i)}{\prod_{i=1}^n f_1(x_i)} \geq \frac{1}{c_n}\right) \stackrel{\text{Márván}}{\leq} E_1\left(\left(\frac{\prod_{i=1}^n f_0(x_i)}{\prod_{i=1}^n f_1(x_i)}\right)\right) \cdot \frac{1}{1/c_n} = c_n \cdot \left(E_1\left(\frac{f_0(x_1)}{f_1(x_1)}\right)\right)^n = \\ &= c_n \cdot \left(\int \frac{f_0}{f_1} \cdot f_1 d\lambda\right)^n \leq c_n \cdot 1^n = c_n = \underbrace{e^{-n D(P_0 \parallel P_1)}}_{\rightarrow 0 \text{ exp.}} + o(n) \end{aligned}$$

Említjük a Neyman-Pearson-lemmát.

□

Nevezetes eloszlások

χ^2_N -eloszlás: N a szabadságú független $N(0,1)$ félék

$$Y_1, \dots, Y_N \text{ félék } N(0,1)$$

$$Y_1^2 + \dots + Y_N^2 \sim \chi^2_N \text{ (centrális) } \chi^2_{N-\infty} = (\infty)^2$$

$$\chi^2_n * \chi^2_m = \chi^2_{n+m} \text{ definícióból}$$

$$\chi^2_1 = N(0,1)^2 \quad P(N(0,1)^2 < t) = P(-\sqrt{t} < N(0,1) < \sqrt{t}) =$$

$$\text{Sf.: } F_1(t) = 2 \varphi(\sqrt{t}) \cdot \frac{1}{2\sqrt{t}} = \frac{1}{\sqrt{2\pi t}} e^{-t/2} \sim \Gamma_{1/2, 1/2}$$

$$\Rightarrow \chi^2_n = \Gamma_{n/2, 1/2}$$

t-eloszlás (Student-eloszlás)

W. S. Gosset (1876 - 1937) minőséggellenőrzésre fejlesztette ki, Student néven publikált (1908)

$$X \sim N(0,1) \quad Y \sim \chi^2_n \text{ független} \quad \rightarrow \quad \frac{X}{\sqrt{\frac{Y}{n}}} \text{ n szabadságformában} \quad t\text{-eloszlás: } t_n$$

All. t_n szimmetrikus

$$\text{B: } -X \text{ is } N(0,1) \rightarrow t_n = -t_n$$

All. $t_n \rightarrow N(0,1)$, ha $n \rightarrow \infty$.

$$\text{B: } \frac{Y}{n} \rightarrow 1 \text{ NSZET, miatt.}$$

Cramér-Szucréj \Rightarrow a nemlakóhoz tart.

$$t_n = \frac{N(0,1)}{|N(0,1)|} \Rightarrow t_n = \text{Cauchy-eloszlás}$$

F-eloszlás

$$X \sim \chi^2_n \quad Y \sim \chi^2_m \text{ független} \quad \Rightarrow \quad \frac{\frac{X}{n}}{\frac{Y}{m}} \text{ eloszlása } (n, m) \text{ szabadságformában} \quad F\text{-eloszlás (Fisher)}$$

$$\text{All. } \frac{1}{F_{n,m}} = F_{m,n}$$

All. $X \sim N_n(m, E_n)$, ahol a koordináták $N(m_i, 1)$ eloszlásúak.

Erre a $\|X\|^2$ eloszlása csupán $\|m\|^2$ -en kívül függ m-től.

Dkt. $\|X\|^2$ n szab. formában, $\lambda = \|m\|^2$ nemcentralitási paraméterrel
nemcentrális χ^2 -eloszlás: $\chi^2_n[\lambda]$.

Spec. $\lambda = 0$ -ra et a részleges (centrális) χ^2 -re.

B: Legyen U ortogonális műtrix, hogy $Um = \|m\| \cdot (1, 0, \dots, 0)^T$.
(U leosztásba). Error $UX \sim N_n(\|m\| \cdot (1, 0, \dots, 0)^T, E_n) \Rightarrow$
 $\Rightarrow \|UX\|^2 = \|X\|^2$.

Né. $X \sim N_n(m, \sigma^2 E_n)$. $\mathbb{R}^n = L_1 \oplus \dots \oplus L_k$ páronként ortogonális altér,

$\dim L_i = r_i$. Az L_i -re való merőleges vektorok P_i .

$$X = X^{(1)} + \dots + X^{(k)}$$
 ötfelbontás, ahol $X^{(i)} = P_i(X)$. Error:
(1) $X^{(i)} \sim N_n(m^{(i)}, \sigma^2 P_i)$ fülemer
(2) $\|X^{(i)}\| \sim \sigma \chi_{r_i}^2 \left[\frac{\|m^{(i)}\|^2}{\sigma^2} \right]$

B: (1) $X^{(i)} = N_n(P_i m, \sigma^2 P_i P_i^T)$

P_i szimmetrikus és idempotens ($P_i = P_i^T$ és $P_i^2 = P_i$)

$$\Rightarrow X^{(i)} = N_n(m^{(i)}, \sigma^2 P_i)$$

$X^{(1)}, \dots, X^{(k)}$ egymáshoz viszonyítva normális, mert X lin. transzformáltja. Ezért elég belátni, hogy rendelkezik a korrelációkkal.

$$\text{cov}(X^{(i)}, X^{(j)}) = \text{cov}(P_i X, P_j X) =$$
$$= P_i \text{cov}(X, X) P_j^T = P_i \cdot \sigma^2 E_n \cdot P_j^T =$$
$$= \sigma^2 \cdot P_i P_j = \sigma^2 \cdot O = O, \text{ ha } i \neq j.$$

(2) Fth. $\sigma = 1$: az általános eset viszonyítva $\frac{X}{\sigma} - ra$.

Legyen e_1, \dots, e_r ONB L_i -ben $\Rightarrow Q = [e_1, \dots, e_r] \in \mathbb{R}^{n \times r}$

(A többi minden i indexet elhagyja, az i besít minden harmadik)

$$\Rightarrow Q^T Q = E_r \text{ és } P = Q Q^T = \sum_{i=1}^r e_i e_i^T,$$

mert $\forall i: P e_i = e_i$, és $a \perp L_i$ -re $P a = \sum_{i=1}^r e_i e_i^T a = 0$,

és a vektor csak minden i -re teljesít.

$$\|PX\|^2 = X^T \cdot P^T P \cdot X = X^T \cdot Q \underbrace{Q^T Q}_{E} Q^T X = \|Q^T X\|^2$$

$Q^T X$ is normális, $Q^T X \sim N_r(Q^T m, \underbrace{Q^T Q}_{E})$

$$\Rightarrow \|Q^T X\|^2 \sim \chi_r^2 \left[\frac{\|Q^T m\|^2}{\|Pm\|^2} \right], \text{ és epp ennek a kellett.}$$

2017.04.26.

□

Kép (Fisher-Bartlett-tétel) $X_1, \dots, X_n \sim N(\mu, \sigma^2)$ mintha error

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right), \quad S_n^{*2} \sim \frac{\sigma^2}{n-1} \chi_{n-1}^2, \quad \text{és ez a két statisztika}$$

Mi. Ez a füleség karakterisztikája is a normális eloszlás. (BN)

B: $\underline{x} = (x_1, \dots, x_n)^T \sim N(\mu e, \sigma^2 E)$, ahol $e = (1, \dots, 1)^T \in \mathbb{R}^n$

$$\mathbb{R}^n = L_1 \oplus L_2, \quad \text{ahol } L_1 = \langle e \rangle, \quad L_2 = L_1^\perp,$$

$$\dim L_1 = 1, \quad \dim L_2 = n-1.$$

$$X = X^{(1)} + X^{(2)} \quad \text{orthogonal decomposition}$$

$$L_1-\text{re való vertes: } p = \frac{e e^T}{n}, \quad \text{mert } L_1 \text{-ben } \frac{e}{\sqrt{n}} \text{ ONB,}$$

$$\text{így } X^{(1)} = P X = e \cdot \frac{1}{n} \cdot e^T X = e \cdot \bar{X} = \bar{X} \cdot e$$

$$\Rightarrow X^{(2)} = X - X^{(1)} = X - \bar{X} \cdot e$$

$$\Rightarrow \|X^{(2)}\|^2 = \sum_{i=1}^n (X_i - \bar{X})^2 = (n-1) S_n^{*2}$$

$$X^{(1)} \text{ és } X^{(2)} \text{ függ } \Rightarrow \bar{X} \text{ és } S_n^{*2} \text{ függ.}$$

$$\text{Továbbra } \|X^{(2)}\|^2 \sim \sigma^2 \chi_{n-1}^2 \text{ centralis, mert: } \mu e \in L_1 \text{ a vár. érték}$$

$$\Rightarrow \mu e \perp L_2 \Rightarrow (\mu e)^{(2)} = 0 \Rightarrow \text{centralitás.}$$

A normális eloszlás paramétereire vonatkozó klasszikus próbák

μ -probák (\bar{x} -probák)

Egyenlítés: $X_1, \dots, X_n \sim N(\mu, \sigma^2)$, σ ismeret, $\mu \in \mathbb{R}$ paraméter

• $H_0: \mu = \mu_0$, $H_1: \mu \neq \mu_0$ kitöldeli ellenügyipotenciál

• $H_0: \mu = \mu_0$, vagy $H_0: \mu \leq \mu_0$, $H_1: \mu > \mu_0$ egysödölő ipotenciál

$$T := \frac{\bar{X} - \mu_0}{\frac{\sigma}{\sqrt{n}}} = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \underset{H_0}{\sim} N(0, 1)$$

H_1 esetén is normális T , de $n \rightarrow \infty$ mellett elhelyezik $\pm \infty$ -be

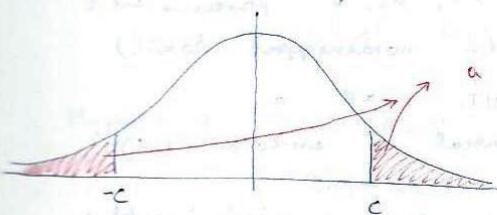
Probák: elvezetés H_0 -t, ha

• egysödölő esetben: $|T| > c_{\text{krit}}$, ahol $c_{\text{crit}} = c_\alpha$, α a térfogat

$\Rightarrow c_\alpha = \Phi^{-1}(1-\alpha)$ az $(1-\alpha)$ -százalékos eredménytelenítés

$$c_\alpha = \Phi^{-1}(1-\alpha)$$

- kódalali esetben: if a file name is a file icon is boy,



a pius rivel cognit & tenuifer

$$\rightarrow |T| > c_{\text{init}} - \epsilon \quad \text{where } \epsilon \text{ is small, } c_{\text{init}} = c_{\alpha/2} \\ = \Phi^{-1}(1 - \frac{\epsilon}{2})$$

$$\begin{aligned} \text{Kontinuierl. : } & \left. \begin{array}{l} X_1, \dots, X_n \sim N(\mu_1, \sigma_1^2) \\ Y_1, \dots, Y_m \sim N(\mu_2, \sigma_2^2) \end{array} \right\} \text{f\"uggetl\"oser} \quad \begin{array}{l} \text{Gesamtwk} \\ G_1, G_2 \text{ isomet} \end{array} \\ & \mu_1, \mu_2 \in \mathbb{R} \text{ parameter} \end{aligned}$$

- Kitoldali: $H_0: \mu_1 = \mu_2$ $H_1: \mu_1 \neq \mu_2$
 - Egyoldali: $H_0: \mu_1 = \mu_2$ $H_1: \mu_1 > \mu_2$
vagy $H_0: \mu_1 \leq \mu_2$

$$T = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \sim H_0 \sim N(0, 1)$$

Standardization

Proba: mint at coprinus ethen.

- Eggoldali: elevated, $\text{ta } T > c_\alpha = \Phi^{-1}(1-\alpha)$
 - Kitoldali: elevated, $\text{ta } |T| > c_{\alpha/2} = \Phi^{-1}(1-\frac{\alpha}{2})$

t - probač

Egyenlítés: $x_1, \dots, x_n \sim N(\mu, \sigma^2)$ $\sigma > 0$, $\mu \in \mathbb{R}$ paraméterek

Hipotézisek mint az a-probabálás

$$T = \frac{\bar{X} - \mu_0}{\sqrt{\frac{s_n^2}{n}}} \sim N(0, 1)$$

H_0

Az első és a második
témavezető fórum (FB-típus)

$$T \sim t_{n-1}$$

Proba: • Egyoldali: elvétés, ha $T > c_{\text{crit}}$, ahol c_{crit}
 a törlesztő. $(1-\alpha)$ -kvantilise, az c_α .

- Kitedali : elevés, sa $|T| > C_{\text{exit}}$ (tun, mimétiques etc.),
alors $C_{\text{exit}} = C_{\alpha/2}$

Kétnéhaias: $x_1, \dots, x_{n_1} \sim N(\mu_1, \sigma^2)$, $y_1, \dots, y_{n_2} \sim N(\mu_2, \sigma^2)$ fűről, μ_1, μ_2, σ paraméterek (a módszertől függ!

Sőt esetben $\sigma_1^2 = \sigma_2^2$ tennéssetek, például a CHT miatt, nemrégis ezt is leírja a mérések szisztematikai eltérését mellett, azaz a hibahalmaz a mérési hibával. Ez nem minden alkalmazható, oktatott F-próba kell a módszertől.

Hipotézisek: mint az u-próbához.

$$T = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} = \frac{\bar{X} - \bar{Y}}{\sigma \cdot \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

$\approx \hat{\sigma}^2 = \frac{(n_1-1) s_x^{*2} + (n_2-1) s_y^{*2}}{n_1+n_2-2} = \frac{\sum_{i=1}^{n_1} (x_i - \bar{X})^2 + \sum_{j=1}^{n_2} (y_j - \bar{Y})^2}{n_1+n_2-2}$

u-próba
alapján

$$\Rightarrow T = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{(n_1-1) s_x^{*2} + (n_2-1) s_y^{*2}}{n_1+n_2-1}}} \cdot \sqrt{\frac{n_1 n_2}{n_1+n_2}}$$

független

$$= \frac{\bar{X} - \bar{Y}}{\sigma \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \cdot \sqrt{\frac{\hat{\sigma}^2}{\hat{\sigma}^2}}$$

$\underset{H_0}{\sim} N(0,1)$

$\underset{H_0}{\sim} \chi^2_{n_1+n_2-2}$

$$\hat{\sigma}^2 = \frac{\sigma^2 \chi^2_{n_1-1} + \sigma^2 \chi^2_{n_2-1}}{n_1+n_2-1} =$$

$$= \frac{\sigma^2 \chi^2_{n_1+n_2-2}}{n_1+n_2-2}$$

$\bar{X}, \bar{Y}, s_x^{*2}, s_y^{*2}$ függetlenek $\Rightarrow T$ -ben az 1. és 2. tényező fűről

$$\Rightarrow T \underset{H_0}{\sim} t_{n_1+n_2-2}$$

U-próbához mint az egynéhaias esetben:

- Egyszerű: elvetírni, ha $T > c_\alpha$
- Kikötések: elvetírni, ha $|T| > c_{\alpha/2}$,

ahol c_α a $t_{n_1+n_2-2}$ -es $(1-\alpha)$ -quantile

Vannak olyan módszerek, amik kétnéhaiasnak $\sigma_1 + \sigma_2 \neq 0$ is minősök, és ezek közelítő próbat ad, nem egyszer. $\rightarrow s$ -próba

F-proba

$$\left. \begin{array}{l} x_1, \dots, x_{n_1} \sim N(\mu_1, \sigma_1^2) \\ y_1, \dots, y_{n_2} \sim N(\mu_2, \sigma_2^2) \end{array} \right\} \text{függetlenek} \quad \mu_1, \mu_2, \sigma_1^2, \sigma_2^2 \text{ paraméterek}$$

- Hipotézisek:
- Kétoldali: $H_0: \sigma_1^2 = \sigma_2^2$ $H_1: \sigma_1^2 \neq \sigma_2^2$
 - Egyoldali: $H_0: \sigma_1^2 \leq \sigma_2^2$ $H_1: \sigma_1^2 > \sigma_2^2$
vagy $H_0: \sigma_1^2 \geq \sigma_2^2$

$$T = \frac{s_x^{*2}}{s_y^{*2}} \underset{H_0}{\sim} F_{n_1-1, n_2-1}$$

Proba:

- Egyoldali: elvét, ha $T > c$ krit. érték, ahol c_α az $F_{n_1-1, n_2-1} - \infty$ $(1-\alpha)$ -quantile.

- Kétoldali: adott α -ra $0 < c_1 < c_2 < \infty$ krit. érték, és elvét, ha $T < c_1$ vagy $T > c_2$.

Ha X -et és Y -t felcseréljük:

az (n_1-1, n_2-1) -re

az (n_2-1, n_1-1) -re

c'_1, c'_2 krit. ért.

c''_1, c''_2 krit. ért.

és erről $c''_1 = \frac{1}{c'_2}, c''_2 = \frac{1}{c'_1}$

A gyakorlatban használt α -ra $c_1 < 1 < c_2$ fennáll.

(ezért $T = 1 - \frac{s_x^2}{s_y^2} = \frac{s_y^2}{s_x^2}$, illetve ugyanúgy el számít fogadni.)

Gyakorlatban T -hez a magasabb tap. módszerrel számítás
évi a manálába $\Rightarrow 1 \leq T$ automátius, csak a felső-
vel zárt összehasonlításon: $T > c_2$ -re elvét.

Most, hogy az egyoldali esetben használt krit. értékek a
kétoldali esetben is használhatók legyenek, mivel c_1 -nek $c_{\alpha/2}$ -t
használjuk. Ez nem minden matematikai lag (szíves, ha $n_1=n_2$),
de kényelmes.

Tulajdonságok

Az empirikus egyoldali u-próba egyszerűen legénysébb.

A többi osz a torzításnál rövidt egs. legénysébb (mivel ennyi olyan, ami minden egs. legénysébb lenne).

Kivétel: az $\alpha/2$ -es F-próba $n_1 \neq n_2$ esetén nem is körültek!

(De a rendszer, amit minden másik hibás C_2 -vel jó lenne.)

Ezek a próbák $n \rightarrow \infty$, ill. $n_1, n_2 \rightarrow \infty$ mellett t-teszt
tartós eredményei θ_1 -en, azaz konzisztens próbák.

χ^2 -próbák

Tétel. i osztály, n objektum az osztályra sorolva (mindegyik pontban egysége): minden objektum p_i valószínűséggel kerül az i -edik osztályba ($p_i > 0, \sum_{i=1}^r p_i = 1$)

Az i -edik osztályba N_i objektum került.

$$\text{Tel. } T_n := \sum_{i=1}^r \frac{(N_i - np_i)^2}{np_i}$$

Erre $n \rightarrow \infty$ esetén $T_n \xrightarrow{d} \chi^2_{r-1}$

B: i az osztályon, j az objektumon megy mindegy.

$I_{ij} := I(\text{a } j\text{-edik objektumot az } i\text{-edik osztályba soroltuk})$

Legyen Y_1, \dots, Y_n egymáshoz viszonyítottan az i -edik osztályhoz (azaz az j -edik objektumhoz) fogadott $N(0, 1)$ val. változók.

$$X_{ij} = \frac{I_{ij} - p_i}{\sqrt{p_i}} + \sqrt{p_i} Y_j \quad (i=1, \dots, r, \quad j=1, \dots, n)$$

$$X_j = (X_{1j}, \dots, X_{rj})^T \quad (j=1, \dots, n)$$

Ezek füle, azaz es. véletlen vektorok.

Meg fogjuk mutatni: $E X_j = 0$, $D(X_j) = E_r$
(minim.)

$$\begin{aligned} \text{cov}(X_{ij}, X_{kj}) &= \text{cov}\left(\frac{I_{ij} - p_i}{\sqrt{p_i}}, \frac{I_{kj} - p_k}{\sqrt{p_k}}\right) + \text{cov}\left(\frac{I_{ij} - p_i}{\sqrt{p_i}}, \sqrt{p_k} Y_j\right) + \\ &+ \text{cov}\left(\sqrt{p_k} Y_j, \frac{I_{kj} - p_k}{\sqrt{p_k}}\right) + \text{cov}\left(\sqrt{p_k} Y_j, \sqrt{p_k} Y_j\right) = \end{aligned}$$

$$= \frac{\text{cov}(I_{ij}, I_{kj})}{\sqrt{p_i p_k}} + 0 + 0 + \sqrt{p_i p_k} D^2(y_j) = * \quad \text{Dokument}$$

\downarrow
 y_j fürem
 $I_{ij}-l\ddot{o}$ és $I_{kj}-l\ddot{o}$

$$\text{cov}(I_{ij}, I_{kj}) = E(I_{ij} \cdot I_{kj}) - \underbrace{E(I_{ij}) E(I_{kj})}_{p_i \text{ ha } i=k} - \underbrace{0}_{0, \text{ ha } i \neq k}$$

$$* = \begin{cases} 1, & \text{ha } i=k \\ 0, & \text{ha } i \neq k \end{cases}$$

CHT v dimenzióban: $\frac{1}{\sqrt{n}} \sum_{j=1}^n X_j \xrightarrow{\text{distr}} N_r(0, E_r)$

$$\rightarrow \left\| \frac{1}{\sqrt{n}} \sum_{j=1}^n X_j \right\|^2 \xrightarrow{\text{distr}} \chi_r^2 \quad \text{nomát vevé.}$$

$$\begin{aligned} \left\| \frac{1}{\sqrt{n}} \sum_{j=1}^n X_j \right\|^2 &= \sum_{i=1}^r \left(\frac{1}{\sqrt{n}} \sum_{j=1}^n X_{ij} \right)^2 = \sum_{i=1}^r \left[\frac{1}{\sqrt{n} p_i} \sum_{j=1}^n (I_{ij} - p_i) + \sqrt{\frac{p_i}{n}} \sum_{j=1}^n Y_j \right]^2 \\ &= \sum_{i=1}^r \frac{(N_i - n p_i)^2}{n p_i} + \underbrace{\sum_{i=1}^r p_i Z_n^2}_1 + 2 \cdot \underbrace{\frac{Z_n}{\sqrt{n}} \sum_{i=1}^r (N_i - n p_i)}_{n-n=0} = \end{aligned}$$

$$* Z_n := \frac{1}{\sqrt{n}} \sum_{j=1}^n Y_j \sim N(0, 1)$$

$$= T_n + Z_n^2$$

Ez a fürem tagja, mert az egyikben indíciók, a másikban Y_j -ek varáz, és azaz fürem.

Ez a χ_r^2 is szovolítás, de a szovolítás félcsatornában általában nem lehet egyszerűsíteni.

Legyen f_n a T_n , $\neq k$ a χ_r^2 karakterisztikus fürem.

Gyenge rövés: $f_n \cdot f_1 \rightarrow f_r = f_1 \cdot f_1$ párhuzamt

Ha $f_i(t) \neq 0 \quad \forall t \in \mathbb{R} \rightarrow$ le lehet osztani, és az adódi, akit nevezünk.

Definíció. Egy Q -val. ω -os horáitlanul ortoasis, ha $\forall n \exists Q_n$:

$$Q = \underbrace{Q_1 * \dots * Q_n}_{n \text{ db}}. \text{ Kev. fréqüenciával: } \psi \text{ hor. ortoasis,}$$

ha $\forall n \exists \psi_n$, hogy $\psi = \psi_n^n$ is ψ_n kar. fv.

Lemmas. Horáitlanul ortoasis kar. fv. szabály sem nulla.

B: Ha ψ kar. fv., akkor $|\psi(t)|^2 = \psi(t) \cdot \psi(-t)$ is az.

Ha ψ hor. ortoasis $\Rightarrow |\psi|^2 = (|\psi_n|^2)^n$, $|\psi_n|^2 = |\psi|^{\frac{2}{n}}$

$$|\psi_n(t)|^2 = |\psi(t)|^{\frac{2}{n}} \xrightarrow{n \rightarrow \infty} \begin{cases} 0, & \text{ha } \psi(t) = 0 \\ 1, & \text{ha } \psi(t) \neq 0 \end{cases}$$

Folytonos-e a határfiggőny 0-ban?

$\psi(t) \neq 0 \Leftrightarrow 0$ egy részben, mert $\psi(0) = 1$ is lehet.

\Rightarrow a határfa. kar. fv. (folytonossági tétele)

\Rightarrow folytonos mindenütt, azaz 2 részben lehet csak 1-et felvenni

$\Rightarrow \lim_{n \rightarrow \infty} |\psi_n(t)|^2 = 1 \Rightarrow \psi(t)$ szabály sem 0.

$\Rightarrow \chi_r^2$ kar. fréqüenciája szabály sem 0, mert $\chi_r^2 = \Gamma_{\frac{r}{2}, \frac{1}{2}}$

és Γ hor. ortoasis: $\Gamma_{\alpha, \lambda} = (\Gamma_{\frac{\alpha}{n}, \lambda})^{+n}$ (n -előre konvergencia-tulajdonság).

Illérediszívizsgálat

n meghosszúság, r osztály, N_i az i -edie osztály gyakorisága

Tisztta illérediszívizsgálat

H_0 : a vásárlás (p_1, p_2, \dots, p_r)

H_1 : nem az elmondás

$$T_n = \sum_{i=1}^r \frac{(N_i - np_i)^2}{np_i} \xrightarrow[H_0]{d} \chi_{r-1}^2$$

Probe: elvétjük. H_0 -t, ha $T_n > \text{crit} = \chi_{r-1}^2$ -es. $(1-\alpha)$ -szinálás

$$T_n = n \cdot \sum_{i=1}^r \frac{\left(\frac{N_i}{n} - p_i\right)^2}{p_i}$$

Látható, hogy ha H_0 nem igaz, akkor $T_n \rightarrow \infty$

\Rightarrow a probe racionális, A elválikotáist 1-hez tartó valószínűsége

Ez ugyan asymptotikus próbával a szükségesen nem α , csat. $n \rightarrow \infty$ mellett tart α -hoz.

Kell, hogy n elég nagy legyen: $\forall N_i \geq 4$ legyen, ebben nem capcsolód a maradvány.

Ha ez nem áll fenn: öntalpát, zell összefonni. Praktikusan eis öntalpát előnevez összefonni.
Az összefonás esetében az erőt.

Becslesek ellenőrzési szabály

$H_0: \theta = (\theta_1, \dots, \theta_r)$ eloszlás eggy $\{p(\theta): \theta \in \Theta\}$ öntalpy eleme, $\Theta \subset \mathbb{R}^r$

Fisher tétel. Tth. $s \leq r-2$, továbbá $p(\theta)$ θ -ban folyt. différenciálható, rang $\underbrace{p'(\theta)}_{r \times s \text{-es mátrix}} = s \quad \forall \theta \in \Theta$. Legyen $\hat{\theta}_n \in \theta$ ML-becslése.

$$\text{Ekkor } \sum_{i=1}^r \frac{N_i - n p_i(\hat{\theta}_n)}{n p_i(\hat{\theta}_n)} \xrightarrow{d} \chi^2_{r-1-s}.$$

Tehát a becslések a $p(\hat{\theta}_n)$ eloszlását illetően χ^2 -probával, $r-1-s$ nob. fölkel.

Homogenitásvizsgálat

r öntalpy, kit fűzz mintát minden be

a berakolási valszékei p_1, \dots, p_r ill. q_1, \dots, q_r ,

a gyakraniságai pedig N_1, \dots, N_r ill. M_1, \dots, M_r ,

$$\sum_{i=1}^r N_i = n, \quad \sum_{i=1}^r M_i = m$$

$$H_0: p = q \quad H_1: p \neq q$$

$N_1, \dots, N_r, M_1, \dots, M_r$ előállításmók valszége (likelihood) =

$$= \underbrace{\frac{n!}{\prod_{i=1}^r N_i!}}_{\text{monoton}} \cdot \underbrace{\frac{m!}{\prod_{i=1}^r M_i!}}_{\text{exponens rögzítés}} \cdot \underbrace{\prod_{i=1}^r p_i^{N_i} \cdot \prod_{i=1}^r q_i^{M_i}}_{\text{exponens rögzítés}}$$

$H_0: p = \frac{m}{m+n}, q = \frac{n}{m+n}$, ahol $\delta = (\delta_1, \dots, \delta_{r-1}) \in \Delta$, és

$$\Delta = \left\{ z \in \mathbb{R}^{r-1} \mid \forall z_i > 0, \sum_{i=1}^{r-1} z_i < 1 \right\} \text{ simplex}$$

$$\text{tel.: } \delta_r = 1 - \sum_{i=1}^{r-1} \delta_i, \quad s = r-1$$

Tudjuk:

$$\sum_{i=1}^r \frac{(N_i - n p_i)^2}{n p_i} + \sum_{i=1}^r \frac{(M_i - n q_i)^2}{n q_i} \xrightarrow[H_0]{d} \chi^2_{(r-1) \cdot 2}, \quad f = 2r-2$$

A mab. bár $s = (r-1)$ - gyel fog csökkenni

$$\text{likelihood} = C \cdot \prod_{i=1}^r \delta_i^{M_i + N_i} \text{ est meretűnek maximalizáló}$$

$$\log \left[\sum_{i=1}^r (M_i + N_i) \cdot \log \delta_i - t \right] \text{ kell maximalizálni}$$

$$\frac{\partial}{\partial \delta_i} : \frac{M_i + N_i}{\delta_i} - \frac{M_r + N_r}{\delta_r} = 0 \text{ legyen}$$

$$\Rightarrow \forall i: \frac{M_i + N_i}{\delta_i} = C \Rightarrow \delta_i = C \cdot (M_i + N_i)$$

$$\Rightarrow \underbrace{\sum_{i=1}^r \delta_i}_{1} = C \cdot (m+n) \Rightarrow C = \frac{1}{m+n}$$

$$\Rightarrow \text{a ML - becslés } \hat{\delta}_i = \frac{M_i + N_i}{m+n}, \text{ amin az összehasonlítás mintától a relativ gyakoriság}$$

És áll $i = r - r_e$ is, mert az összeg 1.

$$\Rightarrow T_n = \sum_{i=1}^r \left[\frac{\left(N_i - n \cdot \frac{M_i + N_i}{m+n} \right)^2}{n \cdot \frac{M_i + N_i}{m+n}} + \frac{\left(M_i - m \cdot \frac{M_i + N_i}{m+n} \right)^2}{m \cdot \frac{M_i + N_i}{m+n}} \right]$$

$$\text{Fisher alapján } T_n \xrightarrow{d} \chi^2_{(2r-2) - (r-1)} = \chi^2_{r-1}.$$

Még alakíthatunk rövidit T_n -et.

$$\begin{aligned} \left(N_i - n \cdot \frac{M_i + N_i}{m+n} \right)^2 &= \frac{(mN_i - nM_i)^2}{(m+n)^2} = \\ &= \frac{m^2 n^2}{(m+n)^2} \cdot \left(\frac{N_i}{n} - \frac{M_i}{m} \right)^2 \end{aligned}$$

Ugyanezt számítunk a 2. tag működésére is.

$$\Rightarrow T_n = \sum_{i=1}^r \frac{m^2 n^2}{(m+n)^2} \cdot \frac{(m+n) \left(\frac{1}{n} + \frac{1}{m} \right)}{M_i + N_i} \left(\frac{N_i}{n} - \frac{M_i}{m} \right)^2 =$$

$$= \sum_{i=1}^r m \cdot n \cdot \frac{\left(\frac{N_i}{n} - \frac{M_i}{m} \right)^2}{N_i + M_i}$$

probabilitás törölt végénél
 χ^2_{r-1} - probát

Függetlenségsvizsgálat

n megfigyelés, r csoportban s cella öntettségi

az (i,j) kombináció arány cella valószínűsége p_{ij} ($1 \leq i \leq r$, $1 \leq j \leq s$),
gyakorisága pedig N_{ij} .

Marginalisök:

$$p_{i\cdot} = \sum_{j=1}^s p_{ij}, \quad p_{\cdot j} = \sum_{i=1}^r p_{ij},$$

$$N_{i\cdot} = \sum_{j=1}^s N_{ij}, \quad N_{\cdot j} = \sum_{i=1}^r N_{ij}$$

		2. csoport				
		1	2	...	s	
1	1	N_{11}	N_{12}	\dots	N_{1s}	$N_{1\cdot}$
	2	N_{21}	N_{22}		N_{2s}	$N_{2\cdot}$
:						
r	r	N_{r1}	N_{r2}		N_{rs}	$N_{r\cdot}$
		$N_{\cdot 1}$	$N_{\cdot 2}$		$N_{\cdot s}$	n

kontingenciatabla

$r \times s$ cella

H_0 : a két csoport független, azaz $p_{ij} = p_{i\cdot} \cdot p_{\cdot j} \quad \forall i, j$

H_1 : nem független

Ha a marginalisök addikcióval → tiszta illetékedetlenségszabály

Ha nem: beszélünk illetékedetlenségszabály $r+s-2$ paramétere (a marginalisök); ezért enyki, mert az utolsó sorból már addikció.

$$(\vartheta_1, \dots, \vartheta_{r-1}) \in \Delta_{r-1}$$

$$(\tau_1, \dots, \tau_{s-1}) \in \Delta_{s-1}$$

tel. $\vartheta_r = 1 - \sum_{i=1}^r \vartheta_i, \quad \tau_s = 1 - \sum_{j=1}^s \tau_j$

Orsz. $H_0: p_{ij} = \vartheta_i \tau_j \quad (1 \leq i \leq r, 1 \leq j \leq s)$

My. Error $p_{i\cdot} = \sum_{j=1}^s \vartheta_i \tau_j = \vartheta_i \sum_{j=1}^s \tau_j = \vartheta_i \cdot 1, \quad$ használva $p_{\cdot j} = \tau_j$

Ez nyilván magának számít, esetleg $i=r$ -re vagy $j=s$ -re kideres.

mint az ellenőri H_0 .

$$\text{Ez ott is jó, pl. } p_{rj} = p_{\cdot j} \sum_{i=1}^{r-1} p_{ij} = p_{\cdot j} - \sum_{c=1}^{r-1} p_{ci} \cdot p_{\cdot j} = \\ = p_{\cdot j} \left(1 - \sum_{i=1}^{r-1} p_{ci} \right) = p_{\cdot j} \cdot p_r. \quad \checkmark$$

Nem ide
való!

(Ettől még
igaz.)

$$\text{Hasonlóan } p_{is} = p_{i\cdot} \cdot p_{\cdot s} \quad \checkmark$$

$$\text{Végül } p_{rs} = 1 - \sum_{(i,j) \neq (r,s)} p_{ij} = \sum_{(i,j) \neq (r,s)} p_{i\cdot} \cdot p_{\cdot j} - \sum_{(i,j) \neq (r,s)} p_{i\cdot} \cdot p_{\cdot j} = \\ = p_{r\cdot} \cdot p_{\cdot s}. \quad \checkmark$$

Tehát H_0 -hoz elég, ha $p_{ij} = p_{i\cdot} \cdot p_{\cdot j}$ minden $i \leq r-1, j \leq s-1$.

ML-becslés kell.

$$\text{likelihood} = C \prod_{i=1}^r \prod_{j=1}^s p_{ij} = C \prod_{i=1}^r \prod_{j=1}^s (\vartheta_i \tau_j)^{N_{ij}} = \\ = C \prod_{i=1}^r \vartheta_i^{N_{i\cdot}} \prod_{j=1}^s \tau_j^{N_{\cdot j}}$$

külön maximalitás a λ függvény

A ML-becslés a relatív gyak. lelt:

$$\hat{\vartheta}_i = \frac{N_{i\cdot}}{n}, \quad \hat{\tau}_j = \frac{N_{\cdot j}}{n}, \quad \text{et } i=r\text{-re és } j=s\text{-re is igaz.} \\ \Rightarrow T_n = \sum_{i=1}^r \sum_{j=1}^s \frac{(N_{ij} - \frac{N_{i\cdot} N_{\cdot j}}{n})^2}{N_{i\cdot} N_{\cdot j}} \xrightarrow[\substack{d \\ H_0}]{\chi^2} \chi^2_{rs-1-(r+s-2)} = \chi^2_{(r-1)(s-1)}$$

Ez végtelen tetsz. χ^2 -probát $f = (r-1)(s-1)$ valószínűségi függel.

T_n -et előbb meg kell alakra vonni.

Speciális eset: $r = s = 2$.

Két igen-nem tökéletesen van.

($I=1, N=2$)

	I	N	
I	N_{11}	N_{12}	$N_{1\cdot}$
N	N_{21}	N_{22}	$N_{\cdot 2}$
	$N_{\cdot 1}$	$N_{\cdot 2}$	n

T_n 4 tagú. Valamennyi egy cellát,

tegyen a gyakorisága a, a vele egy sorban levő b,
vele egy sorban c, a megfelelő (átlos helyzetű) d.

Példá a (2.1) cellára:

$$\rightarrow \frac{\left(a - \frac{(a+b)(a+c)}{n}\right)^2}{\frac{(a+b)(a+c)}{n}} \quad \text{c} \quad \text{d}$$

(a) b

$$n = a+b+c+d \rightarrow \text{a művelet: } \left[\frac{1}{n} \left(a(a+b+c+d) - (a+b)(a+c) \right) \right]^2 = \frac{(ad-bc)^2}{n^2}$$

$$\Rightarrow T_n = \frac{(N_{11}N_{22} - N_{12}N_{21})^2}{n} \cdot \left(\underbrace{\frac{1}{N_{11}N_{11}} + \frac{1}{N_{11}N_{22}}}_{\frac{1}{N_{11}} \cdot \frac{N_{22} + N_{11}}{N_{11}N_{22}}} + \underbrace{\frac{1}{N_{22}N_{11}} + \frac{1}{N_{22}N_{22}}}_{\frac{1}{N_{22}} \cdot \frac{n}{N_{11}N_{22}}} \right)$$

er mind
 a h tagra
 megjelenik!

$$T_n = \frac{(N_{11}N_{22} - N_{12}N_{21})^2}{N_{11}N_{22}N_{12}N_{21}} \cdot n \xrightarrow[H_0]{\chi^2}$$

Egyenülterű rétegt, mint általánosan.

Sőt: erre egyszerűbb ellenőrzés is megy!

H_1 : a két tulajdonság között van szorosabb korreláció (H_0 : független továbbra is)

(igen - nem esetén negatív korreláció is vizsgálható)

A pozitív korreláció egy lehetséges megfejtése:

$$P(2. I | 1. I) > P(2. I | 1. N)$$

$$\frac{p_{11}}{p_{11} + p_{12}} > \frac{p_{21}}{p_{21} + p_{22}}$$

$$p_{11} p_{22} > p_{12} \cdot p_{21}$$

$$\Leftrightarrow \begin{vmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{vmatrix} > 0$$

$$\chi^2_1 = N(O_{11})^2 \Rightarrow \text{Plausibilis (de nem igazoljuk), hisz}$$

$$\sqrt{T_n} \rightarrow |N(O_{11})|. \text{ Ennek alapján az } U_n = \sqrt{n} \frac{N_{11}N_{22} - N_{12}N_{21}}{N_{11}N_{22}N_{12}N_{21}}$$

$$\text{eloszlásra } U_n \xrightarrow[H_0]{\text{d}} N(0,1).$$

H_1 esetén U_n "nagy" (sőt: végtelen terület: $U_n \approx \sqrt{n} \cdot \frac{n^2}{n^2} \rightarrow \infty$)

$\rightarrow U_n$ -re egyszerű u-probát végezzük.

(Míg a részleges u-proba χ^2 -probával lenne eredményes.)

Illesztéderivizsgálat folytonos esetben

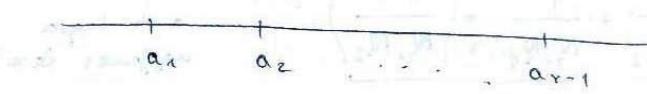
X_1, \dots, X_n minta polyt. eloszlásból

$$H_0: P(X_1 < t) = F(t) \quad \forall t$$

$$\text{egyszerű } H_1: P(X_1 < t) \geq F(t) \quad \forall t \quad \text{és} \quad \exists t: P(X_1 < t) > F(t)$$

$$\text{kétold. } H_1: \exists t: P(X_1 < t) \neq F(t).$$

Kétoldali esetben diszkrétítés:



Felvenniük $a_1 < \dots < a_{r-1}$, működik, az ott különök

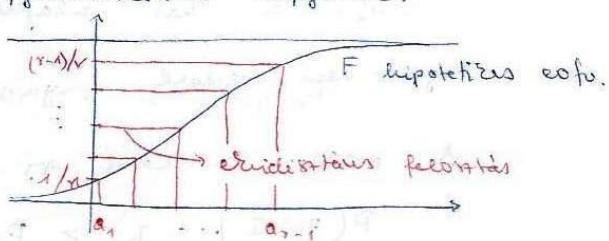
gyakran már elve eloperálható adatok
vannak, pl.
évenként

$$(-\infty, a_1), [a_1, a_2], \dots, [a_{r-2}, a_{r-1}], [a_{r-1}, \infty) \rightarrow r \text{ db.}$$

$$F(a_1), F(a_2), \dots, F(a_{r-1}), 1 - F(a_{r-1}) \text{ valóság}$$

χ^2 -probálval ellenőrizni

Ilyen magas valószínűség az ott kívántak, amikor úgy állunk,
hogy az ott különök valóságai minél gyakrabban legyenek.



Ilyen F_n a tapasztalati esfu.,

$$D_n^+ = \sup_t (F_n(t) - F(t))$$

$$D_n^- = \sup_t (F(t) - F_n(t))$$

$$D_n = \sup |F(t) - F_n(t)| = \max \{D_n^+, D_n^-\}$$

All. H_0 esetén az eloszlásmentes, azaz az eloszlás nem függ F -től.

B: $F_n(t) - F(t)$ monoton fogyni hét részarácsos megfigyelés között:

(x_i^*, x_{i+1}^*) -on mon. csök.

\Rightarrow a \sup a bal végpontban vett. jobbként:

$$F_n(x_i^* + 0) - F(x_i^* + 0) = \frac{i}{n} - F(x_i^*) \quad \text{ér } i=n-r \text{ is jö,$$

és $(-\infty, x_i^*]$ -on a rövidség ≤ 0 , de ez nem járni,

mert $i=n-r$ $\frac{n}{n} - F(x_i^*) \geq 0$.

$$\Rightarrow D_n^+ = \max_{1 \leq i \leq n} \left(\frac{i}{n} - F(X_i^*) \right)$$

$$\text{Hasoldában } D_n^- = \max_{1 \leq i \leq n} \left(F(X_i^*) - \frac{i-1}{n} \right), \text{ a kicsúsó fülegyelésen}$$

a részben negatív-, és az nem játik, mert $i=1$ -re nem neg.

Ha X v.v.F eloszlású folyékony $\Rightarrow F(X)$ eloszlása $U[0,1]$

$\Rightarrow F(X_1^*), \dots, F(X_n^*)$ egy $U[0,1]$ -beli rendesett minta

\Rightarrow eloszlásmentes.

Kör. A próbá: egyszerű esetben elvétől, ha $D_n^+ > c_{n,\alpha}$,
kétszerű esetben elvétől, ha $D_n > c'_{n,\alpha}$. \rightarrow F-független!

Ha n nagy: asymptotikus próba is végesítő, mert van határérték: $y > 0$ -ra

$$\lim_{n \rightarrow \infty} P(\sqrt{n} D_n^+ < y) = 1 - e^{-2y^2} \quad (\sqrt{n} \text{ es monoton növekvő} \\ \text{O-WT tartánya})$$

$$\lim_{n \rightarrow \infty} P(\sqrt{n} D_n < y) = K(y) = \sum_{k=-\infty}^{+\infty} (-1)^k e^{-2k^2 y^2}$$

Kolmogorov-eloszlás, mely rögtől elér.

Egy alapvető: elvétől H-t, ha egyszerűen $\sqrt{n} D_n^+ > \sqrt{\frac{1}{2} \log \frac{1}{\alpha}}$,
kétszerűen $\sqrt{n} D_n > K^{-1}(1-\alpha)$

Ez a próba konzisztens.

Az egyszerűit Simmerr-, a kétszerűt Kolmogorov-probabilitás vezeti.

azaz (X_1, X_2, \dots, X_n) eloszlása $F(x_1, x_2, \dots, x_n)$

$$P(D_n > y) = P\left(\sqrt{n} D_n > \sqrt{n} y\right) = P\left(\sqrt{n} D_n > \sqrt{\frac{1}{2} \log \frac{1}{\alpha}}\right)$$

$$P(D_n > y) = P\left(\sqrt{n} D_n > \sqrt{\frac{1}{2} \log \frac{1}{\alpha}}\right) = P\left(\sqrt{n} D_n > K^{-1}(1-\alpha)\right)$$

Homogenitásvizsgálat poltikus esetben

$X_1, \dots, X_n \sim F$ folyt.

$Y_1, \dots, Y_m \sim G$ folyt.

} független

$$H_0: F = G$$

$$\text{egy. } H_1: F(t) \geq G(t) \quad \forall t, \exists t: F(t) > G(t)$$

$$\text{kéts. } H'_1: F \neq G.$$

$$D_{n,m}^+ = \sup_t (F_n(t) - G_m(t))$$

$$D_{n,m}^- = \sup_t (G_m(t) - F_n(t))$$

$$D_{n,m} = \sup |G_m(t) - F_n(t)| = \max (D_{n,m}^+, D_{n,m}^-)$$

A'LL. H_0 nulltet eset előállításmentes.

B: $D_{n,m}^+$ -ra a körülbeli gyakorlatmentes

$$D_{n,m}^+ = \max \left\{ \frac{i}{n} - G_m(X_i^* + \delta) \mid 1 \leq i \leq n \right\}$$

Szimmetriázó eljel:

$$D_{n,m}^- = \max \left\{ \frac{i}{m} - F_n(Y_i^* + \delta) \mid 1 \leq i \leq m \right\}$$

$$G_m(X_i^* + \delta) = \frac{1}{m} \sum_{j=1}^m I(Y_j \leq X_i^*) \stackrel{\delta \rightarrow 0 \text{ miatt}}{\approx} \frac{1}{m} \sum_{j=1}^m I(G(Y_j) \leq F(X_i^*))$$

Mátrixat

$F = G$

$$G_m(X_i^* + \delta) \geq \frac{1}{m} \sum_{j=1}^m I(G(Y_j) < F(X_i^*))$$

Ez a 1 val megegyezik,

mert $G(Y_j)$ és $F(X_i^*)$ független, $G(Y_j) \sim U[0,1]$,

$(F(X_i^*)) \stackrel{d}{=} U_i^* \sim \text{Beta}(i, n+1-i)$ is finál, de ez nem rélt (gyer.)

$$\Rightarrow P(F(X_i^*) = G(Y_j)) = 0$$

Tehát $D_{n,m}^+, D_{n,m}^-$ is $D_{n,m}$ előállítása ugyanaz, mintha minden minta $\text{U}[0,1]$ -ból minőségi.

Asymptotikus proba:

$$\lim_{n,m \rightarrow \infty} P\left(\sqrt{\frac{nm}{n+m}} D_{n,m}^+ < y\right) = 1 - e^{-2y^2}$$

$$\lim_{n,m \rightarrow \infty} P\left(\sqrt{\frac{nm}{n+m}} D_{n,m}^- < y\right) = K(y)$$

Probá mint az illetékes vizsgálatnál.

Megj. Nincs öcclesiás ellenzéklelés nincs járat.

Ha iH d-t beenlyjus, es allor illesthus, as a naturales-
last is beslyjusolja.

A névzetes családorok története esetében vanak próbák, de általában nincs.

Lineáris modell

$y_1, x_{11}, x_{12}, \dots, x_{1p}$ finizai megnézisek,

$$y = \sum_{j=1}^p a_j x_j \quad a_1, \dots, a_p \text{ nem követően együtthatók}$$

n mérésről végzünk: $y_i = \sum_{j=1}^p a_j x_{ij} + \varepsilon_i \quad 1 \leq i \leq n$
 $p \ll n$ váletlen mérési liba

Feltevés, hogy a mérésről szóló az ε_i liba \mathcal{O} várható értékű, korelációfánk, amelyet szórásnak.

$$y = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} \in \mathbb{R}^n \text{ váletlen vektor, } a = \begin{bmatrix} a_1 \\ \vdots \\ a_p \end{bmatrix} \in \mathbb{R}^p \text{ paraméterek,}$$

$$\varepsilon = \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix} \in \mathbb{R}^n \text{ váletlen libavolt, } X = \begin{bmatrix} x_{ij} \end{bmatrix} \in \mathbb{R}^{n \times p} \text{ követő elosztás}$$

$$y = Xa + \varepsilon, \quad E(\varepsilon) = 0, \quad E(\varepsilon) = \sigma^2 \cdot E_n$$

↓
 σ^2 is paraméter, de nem érdellet
 (m. zavaró paraméter, nuisance parameter)

Gél: a, illetve frégeinek becslése, valamint hipotézisvizsgálat
 a-ra (ellenőrzi az extern rögzítés előfordulása is → m. munkás
 lineáris modellben $\varepsilon \sim N_p(0, \sigma^2 E_n)$)

$p \ll n \Rightarrow$ az egyenletekrendszer ε miatt nem tilthatáronként, monoton
 ellentmondás

Gauss: legkisebb négyzeterrel elv

\hat{a} olyan, hogy $\|y - X\hat{a}\|^2$ minimális; erről a legkisebb négyzetes becslés (LNB)

$$\|y - X\hat{a}\|^2 = \sum_{i=1}^n \left(y_i - \underbrace{\sum_{j=1}^p x_{ij} \hat{a}_j}_{\hat{\varepsilon}_i \text{ residualis}} \right)^2 = \sum_{i=1}^n \hat{\varepsilon}_i^2$$

$$y - Xa = \varepsilon \Rightarrow y - X\hat{a} = \hat{\varepsilon}$$

$\|y - X\hat{a}\|^2$: QR residualis négyzetösszeg, RSS (residual sum of squares)

Védeges, hogy \hat{x} az y merőleges vetítése $\text{Im } X$ -re. (és hogy \hat{x} egyszerű)

\hat{x} legrövidebb négyszöges belseje $\Leftrightarrow \underbrace{y - \hat{x}}_{\in (\text{Im } X)^\perp} \perp \text{Im } X$

$$y - \hat{x} \in (\text{Im } X)^\perp = \ker X^T$$

$$\text{Termi } \hat{x} \text{ LNB} \Leftrightarrow X^T(y - \hat{x}) = 0$$

$$\Leftrightarrow X^T X \hat{x} = X^T y \quad \text{Gauss-féle módszerrel}$$

Ez $p \times p$ -es egyszerűsítendő. $r := \text{rang}(X) = \text{rang}(X^T X)$

Eszer:

- $r = p \Rightarrow \exists! \hat{x}$:

- $r < p$ és ellentmondás \rightarrow ez nem lehet, mert tudjuk, hogy \exists megoldás.
- $r < p$ és a megoldások egy affin altér.

Teljes rangú eset: $\hat{x} = (X^T X)^{-1} X^T y$ az LNB egyszerű.

$$E\hat{x} = (X^T X)^{-1} X^T E_y = a$$

$$\hat{x} = (X^T X)^{-1} X^T \underbrace{\underbrace{E_y}_{\in \mathbb{C}^n}}_{\in \mathbb{C}^p} \times (X^T X)^{-1} = \sigma^2 (X^T X)^{-1}$$

Rölk: a Gauss-egyenlet megoldásai $p-r$ dim. aff. altérrel alkotnak, az LNB-nak egyszerű.

Az altér egy spec. elme a min. normájú:

$\hat{x} = (X^T X)^{-1} X^T y$, ahol $(X^T X)^{-1}$ a Moore-Penrose-féle pseudoinverz, amire $X^T X = U \Lambda U^T$ $\xleftarrow{\text{spektrális állítás}}$ ahol

$\Lambda = \text{diag}(\lambda_1, \dots, \lambda_p)$ szítfélez (pont. nemdef. miatt $\forall \lambda_i \geq 0$),

U orthonormális: $U = [u_1, \dots, u_p]$, ahol u_1, \dots, u_p a megfelelő orthonormális svartorosai alkó bázis (SONB),

$$U U^T = U^T U = E_p.$$

Ezre $(X^T X)^{-1} = U \bar{\Lambda} U^T$, ahol $\bar{\Lambda} = \text{diag}(\bar{\lambda}_1, \dots, \bar{\lambda}_p)$, ahol

$$\bar{\lambda}_i = \begin{cases} 0 & \lambda_i = 0 \\ 1/\lambda_i & \lambda_i > 0 \end{cases}$$

Ez valóban jó (BN), minimális normájú ad.

Mj. $r = p$ P_X jel. az $\text{Im } X$ -re való merőleges vetítést.

$$P_X y = X \hat{x} = X(X^T X)^{-1} X^T y \quad \forall y \in \mathbb{R}^n$$

$$\Rightarrow P_X = X(X^T X)^{-1} X^T$$

2017.05.17.

$$y - X\hat{a} = \hat{\epsilon} \quad \text{rendelálosz verora}$$

$$\|\hat{\epsilon}\|^2 = Q_R \quad \text{rendelálos négyzetesség}$$

$$R^* = L_X \oplus L_R \quad \text{ortogon. felbontás} \quad L_X = \text{Im } X$$

↑
rend. altern. rá vétér P_R

$$y = y^X + y^R \quad \text{ortogon. felbontás}$$

$$\uparrow \quad \underbrace{y^R}_{P_R y} = P_R y = \hat{\epsilon}$$

$$y^X = P_X y = X\hat{a}$$

$$\dim L_X = r, \quad \dim L_R = n-r$$

$$\sigma_R^2 = \frac{Q_R}{n-r} \quad \text{rendelálos módszereppet}$$

All: σ_R^2 tömtetések becslése σ^2 -re.

$$B: E Q_R = E \|P_R y\|^2 = E \left(y^T \underbrace{P_R^T P_R}_\text{skálár} y \right) =$$

$$= E \left(\text{tr}(y^T P_R y) \right) = E \left(\text{tr}(P_R y y^T) \right) =$$

$$\uparrow \quad \text{tr}(AB) = \text{tr}(BA)$$

$$\uparrow \quad \text{tr lineáris}$$

$$= \text{tr} \left(E(P_R y y^T) \right) = \text{tr} \left(P_R \underbrace{E(y y^T)}_\text{P_R lineáris} \right) =$$

$$\uparrow \quad \text{tr}(y) + E y E y^T$$

$$= \text{tr} \left(P_R \left(\sigma^2 E_n + X a a^T X^T \right) \right) = \sigma^2 \text{tr}(P_R) + 0$$

$$P_R X a = 0, \quad \text{mert } X a \perp L_R$$

$\text{tr}(P_R) = \dim L_R$, mert a részter összege, az idempotencia

nincs csak 0 vagy 1 lehet sélesebb, amelynek L_R dimenziója, de

$$\Rightarrow E Q_R = \sigma^2 \text{tr}(P_R) = \sigma^2 \cdot (n-r).$$

Def:

Legyen C $q \times p$ -es mátrix, $\psi = \psi(a) = Ca$ a paraméter lineáris függvénye. Ekkor ψ becslésű, ha van tömtetán lineáris becslés: $T(y) = By$, ahol B $q \times n$ -es.

$$E(By) = \psi$$

Ael. ψ bennéhető, ha C sorai bene vanak egy X sorai
által kifejtett alakban (lin. függetl.),
ez tűn X T.

az egyes mérések
közülöngyüt
hodolják

B: ψ bennéhető $\Leftrightarrow \forall a \in \mathbb{R}^p : \psi = Ca = E(By) = BEy = BXa$.

$$\Leftrightarrow C = BX$$

\Leftrightarrow C sorai az X sorainak lin. kombinációi. □

Tétel. (Gauss-Markov) Legyen ψ bennéhető, és legyen \hat{a} (tethetőleges)

LNB. Legyen $\hat{\psi} = C\hat{a}$. Erről $\hat{\psi}$ független \hat{a} valamennyi tőle,
 $\hat{\psi}$ tömítetlen lineáris becslés ψ -re és az ilyen között minimális szórásnégyzetű (azaz a legnagyobb valószínűséggel ér vért optimális).

B: $\hat{\psi} = C\hat{a} = BX\hat{a} = BP_X y \Rightarrow \hat{a}$ -ről függetlenül
lineáris becslés, mert y -nél minden

$$E\hat{\psi} = BP_X E y = BP_X Xa = BXa = Ca = \psi \Rightarrow \text{tömítetlenesség}$$

legyen $T = T(y) = By$ tömítetlen lineáris becslés ψ -re.

Erről $C = BX$ a tömítetlenesség miatt.

$$E(T(y) \cdot T(y)^T) = E(By(By)^T)$$

depedőtől kizártan
mert mindenhol négyszögletű
Ell. riománi, hogy $\not= 0$ legyen

$$By = B(P_X y + P_R y)$$

$$\rightarrow By(By)^T = (\hat{\psi} + BP_R y) \cdot (\hat{\psi} + BP_R y)^T = \hat{\psi}\hat{\psi}^T + \hat{\psi}(BP_R y)^T + (BP_R y)\hat{\psi}^T + (BP_R y)(BP_R y)^T$$

$$E(\hat{\psi}(BP_R y)^T) = BP_X \underbrace{E(yy^T)}_{BP_X y} P_R B^T = *$$

$$\hat{y}y + E y \cdot E y^T = \sigma^2 \cdot I_E + (Xa)(Xa)^T$$

$$** = \sigma^2 \cdot \underbrace{B P_X P_R B^T}_0 + BP_X (Xa)(Xa)^T \underbrace{P_R \cdot B^T}_{(P_R Xa)^T = 0} = 0$$

Megjegyzés: a másik vegyér tag minden összegje is 0.

$$\Rightarrow \mathbb{E}(T) - \mathbb{E}(\hat{\psi}) = E(By(By)^T) - E(\hat{\psi}\hat{\psi}^T) = E((BP_R y)(BP_R y)^T) \geq 0$$

□

Mj. $\hat{\beta}$ -ot is LNB-nek nevezik.

Mj. Teljes rögzítés esetben $\hat{\alpha}$ lin. f. becslés

$$C = \underbrace{C(X^T X)^{-1} X^T}_{B} X$$

$\Rightarrow \hat{\alpha}$ is igy $C\hat{\alpha}$ is optimalis.

Normalis lineáris modell

$$\varepsilon \sim N_n(0, \sigma^2 I_n) \rightarrow y \sim N_n(x_a, \sigma^2 I_n)$$

$$\text{H}^0: Q_R = \|P_R y\|^2 \sim \sigma^2 \cdot \chi_{n-r}^2 \left[\frac{1}{\sigma^2} \|P_R \varepsilon\|^2 \right]$$

$$0, \text{mert } E[y] = x_a + \varepsilon$$

Továbbá $X\hat{\alpha}$ fülek $\hat{\varepsilon} = \hat{y} - \hat{X}\hat{\alpha}$ is igy $Q_R = \hat{\varepsilon}^T \hat{\varepsilon}$.

Ez a norm. lin. modell.

Lineáris hipotézis: $H_0: B_a = b$, $H_1: B_a \neq b$

$$H_1: B_a \neq b,$$

ahol B $q \times p$ -es mátrix és $b \in \mathbb{R}^q$. (ezt nem teszi H_0)

$$\text{Ftu. } r(B) = q \quad (\text{azaz lin. fülek}).$$

Feltehető, hogy $b = 0$: legyen u. a_0 olyan, hogy $Ba_0 = b$.

$$(\text{ilyen pusztán van}) \Rightarrow \tilde{\alpha} = a - a_0, \tilde{y} = y - x_a - \varepsilon$$

$\tilde{y} = X\tilde{\alpha} + \varepsilon$ lin. modell, és ebben $H_0: B\tilde{\alpha} = 0$

Aktálásos elv

Aktálásosított likelihood-hányados-statistika:

$$T(y) = \frac{\sup \{ f_{a,\sigma}(y) \mid a \in \mathbb{R}^p, \sigma > 0 \}}{\sup \{ f_{a,\sigma}(y) \mid \underbrace{Ba=0}_{H_0}, \sigma > 0 \}} \geq 1,5173$$

Elvetjük H₀t, ha T nagy (aktálásosított elv-párba).

(Reguláritás esetén erre asymptotikus probót lehet enni a köt.)

T helyett ennek helye vagy másik fizikai variánsból.

$$f_{a,\sigma}(y) = (2\pi)^{-\frac{n}{2}} \cdot \sigma^{-n} \cdot \exp \left(-\frac{1}{2\sigma^2} \|y - X\alpha\|^2 \right)$$

y_1, \dots, y_n fülek σ módszerrel

Rögt. σ esetén a -ban maximalizálva $\|y - X\alpha\|^2$ minimális

\rightarrow az $\hat{\alpha}$ ML-becslés = $\hat{\alpha}$ LNB

$$f_{\hat{\alpha}, \sigma}(y) = (2\pi)^{-\frac{n}{2}} \cdot \sigma^{-n} \cdot \exp\left(-\frac{1}{2\sigma^2} \|y - X\hat{\alpha}\|^2\right)$$

$$\log: -n \log \sigma - \frac{1}{2\sigma^2} \|y - X\hat{\alpha}\|^2 + C$$

$$\frac{\partial}{\partial \sigma} = 0: -\frac{n}{\sigma} + \frac{1}{\sigma^3} \|y - X\hat{\alpha}\| = 0 \Rightarrow \hat{\sigma}^2 = \frac{1}{n} \|y - X\hat{\alpha}\|^2$$

$$\Rightarrow \sup_{H_0} f_{\hat{\alpha}, \sigma}(y) = \left(\frac{2\pi e}{n}\right)^{-\frac{n}{2}} \|y - X\hat{\alpha}\|^{-n}$$

$$\sup_{H_0} f_{\hat{\alpha}, \sigma}(y) = \left(\frac{2\pi e}{n}\right)^{-\frac{n}{2}} \|y - X\hat{\alpha}\|^{-n}$$

ahol $\hat{\alpha}$ minimalitálya $\|y - X\hat{\alpha}\|^2$ -et H_0 -on, azaz $\text{Ker } B = 0$.

$$\Rightarrow T = \frac{\|y - X\hat{\alpha}\|^n}{\|y - X\hat{\alpha}\|^n}$$

$$\mathbb{R}^n = \mathcal{L}_X \oplus \mathcal{L}_R$$

$$\mathcal{L}_X = X\mathbb{R}^p = X(\text{Ker } B \oplus \text{Im } B^\top) = \mathcal{L}_0 \oplus \mathcal{L}_1, \quad \text{ahol } \mathcal{L}_0 = X\text{Ker } B = \{x_a \mid Ba = 0\}.$$

$$y^X = X\hat{\alpha} = y^0 + y^1$$

$$\hat{\alpha}: X\hat{\alpha} \text{ az } y \text{ vertélete } \mathcal{L}_0\text{-ra, azaz } X\hat{\alpha} = y^0$$

$$y = y^0 + y^1 + y^R \quad \text{ort. felektás}$$

$$y - y^0 = y^1 + y^R$$

$$\left. \begin{aligned} \|y - X\hat{\alpha}\|^2 &= \|y - y^0\|^2 = \|y^1\|^2 + \|y^R\|^2 \\ \|y - X\hat{\alpha}\|^2 &= \|y^R\|^2 \end{aligned} \right\} \Rightarrow T = \left(\frac{\|y^1\|^2}{\|y^R\|^2} + 1 \right)^{n/2}$$

$$r_0 := \dim \mathcal{L}_0 \Rightarrow \dim \mathcal{L}_i = r - r_0$$

$$\text{Legyen a stat. \& rövekhez: } F(y) = \left(T(y)^{\frac{2}{n}} - 1\right) \cdot \underbrace{\frac{n-r}{r-r_0}},$$

ez míg. mon. nincs fréje T-vel.

szükséges a
nevezőt is le-
osztjuk a dimen-
ziójával

$$\text{Akk. } H_0 \text{ esetén } F(y) \sim F_{r-r_0, n-r}$$

Ezért eure kell egyszerűbb F-problát végezni.

$$B: F(y) = \frac{s_1^2}{s_R^2}, \text{ ahol } s_1^2 = \frac{Q_1}{r-r_0}, Q_1 = \|y^*\|^2 = (y^*)_{\perp}^2$$

s_R^2 a rendelési módszerrel.

$$s_R^2 \sim \frac{s^2}{n-r} \chi_{n-r}^2 \quad \text{Ou } \|Ax - b\| \frac{1}{\sigma_1} + \frac{\|x\|}{\sigma_1} = \frac{\|Ax - b\|}{\sigma_1}$$

$$s_1^2 \sim \frac{s^2}{n-r} \cdot \chi_{r-r_0}^2[x], \text{ ahol } \lambda = \frac{1}{s^2} \cdot \|(\chi_a)^{\perp}\|^2 \geq 0$$

$$H_0 \Rightarrow x_a \in L_0 \Rightarrow (x_a)^{\perp} = 0 \Rightarrow \lambda = 0$$

$L_1 \perp L_R \Rightarrow y^* \in y^R$ fűlén $\rightarrow s_1^2 \leq s_R^2$ fűlén,
mert y^* a y^R fréjén.

Ortogonal valóban F-claszt röpir.

y^* is minimális, enne van való való.

Bontásuk alatt $A^T y^* = (A^T A^{-1} B + A^T C)x = A^T x = y^*$

minimális $y^* = A^T x$ minden $x \in E_1$ fűjén.

Minimális $y^* = A^T x$ minden $x \in E_1$ fűjén.

Minimális $y^* = A^T x$ minden $x \in E_1$ fűjén.

Minimális $y^* = A^T x$ minden $x \in E_1$ fűjén.

Minimális $y^* = A^T x$ minden $x \in E_1$ fűjén.

Minimális $y^* = A^T x$ minden $x \in E_1$ fűjén.

Minimális $y^* = A^T x$ minden $x \in E_1$ fűjén.

Minimális $y^* = A^T x$ minden $x \in E_1$ fűjén.

Minimális $y^* = A^T x$ minden $x \in E_1$ fűjén.

Minimális $y^* = A^T x$ minden $x \in E_1$ fűjén.