

30.3.1993

ÚLOHA BODOVÉHO ODHADU

ZÁKLADNÍ INGREDIENTY

$$P = \{P_\theta, \theta \in \Theta\}$$

(i) $g(\theta) : \Theta \rightarrow \mathbb{R}^1$ odhadová fce (estimator)
kterou chceme odhadnout (nemáme, nepozorovatelná)

(ii) X náhodný vektor pozorovatelný, $X \in \mathcal{X}$
 $X \sim P_\theta \in P$

Pozorované hodnoty x vektoru X tvoří data

Úkolem je stanovit vhodný odhad (estimator)
tj. reálnou fci $T(x) : \mathcal{X} \rightarrow \mathbb{R}^1$ o které doufáme
že je blízko $g(\theta)$.

Jestliže obou hodnot $g(\theta)$ je nějak omezen (kladné,
celočíslné) pak také chceme od odhadu T .

Protože $T(x)$ je náhodná veličina, může být
blízko $g(\theta)$ jen v průměru apod.

Obecně ztrátu, kterou utrpíme, odhadneme-li
(iii) $g(\theta)$ hodnotou t měříme ztrátovou fci $L(\theta, t)$.

a požadujeme

$$L(\theta, t) \geq 0 \quad \forall \theta, t$$
$$L(\theta, g(\theta)) = 0 \quad \forall \theta$$

Ne přesnost (nebo přesnost) odhadu je pak mě-
řena rizikovou fci (rizikem)

$$R(\theta, T) = E_\theta \{L(\theta, T(X))\}$$

Cílem: bychom rádi stepenně nejlepší odhad $\hat{\theta}$
 $R(\hat{\theta}, T) = \min_{\theta \in \Theta} R(\theta, T)$ vzhledem k T

Takový odhad neexistuje, protože v bodě θ_0 dosáhneme minima pro odhadem $T(x) \equiv q(\theta_0)$ (neboli existuje jen v triviálním případě $q(\theta) \equiv \text{konst.}$).

Proto omezuje třídu odhadů, přes kterou minimum hledáme přímo: např. uvažujeme nestranne odhady
nevychylené

$$E_{\theta} T(\hat{\theta}) - q(\theta) = 0$$

bias (jednostrannost, vychylen

Nebo mediánové nestranne odhady

$$P_{\theta} [T(\hat{\theta}) < q(\theta)] = P_{\theta} [T(\hat{\theta}) > q(\theta)]$$

Jestliže se např. jedná o parametry posunutí a $q(\theta) = 0$
 $L(\theta, t) = L(|\theta - t|)$, pak se omezuje na ekvivariantní odhady, $T(x_1+c, \dots, x_n+c) = T(\hat{\theta}) + c$

Místo toho bychom minimalizovali přímo stepenně přes $\theta \in \Theta$, musíme buď

a) minimalizovat přímo přímo

$$\int_{\Theta} R(\theta, T) w(\theta) d\theta \quad (*)$$

vzhledem k váhové fci w . Speciálně Odhady které minimalizují (*) jsou tzv. formulou Bayesovské odhady. vzhledem k apriorní (rozdělení) hustotě $w(\theta)$.

b) Nebo můžeme minimalizovat maximum dosažitelné funkce

$$\sup_{\theta \in \Theta} R(\theta, T)$$

minimálního odhad.

Odporuje-li to povaze problému, je vhodné volit konvexní ztrátovou fci. Řada problémů vede ke ztrátovému řešení pro lib. konvexní ztrátovou fci $L(\theta, t)$, konvexní v t .

KONVEXNÍ ZTRÁTOVÁ FUNKCE.

Definice. Fce $\Phi: I \rightarrow \mathbb{R}^1$, kde $I = (a, b)$, $-\infty \leq a < b \leq \infty$ se nazývá konvexní restliše $\forall x, y, a < x < y < b$ a $\forall 0 \leq \lambda < 1$ platí

$$\Phi(\lambda x + (1-\lambda)y) \leq \lambda \Phi(x) + (1-\lambda)\Phi(y) \quad (1)$$

Fce se nazývá ryze konvexní, restliše nerovnost v (1) je neuhrazená ostrá. Fce Φ se nazývá konkávní, restliše $(-\Phi)$ je konvexní.

Konvexita je velmi silná vlastnost, se které plyne spojitost a existence jednostranných a jednostranných derivací (Rockafellar)

Vlastnosti konvexních fci:

(I) Jestliže Φ je diferencovatelná na (a, b) , pak Φ je konvexní \iff

$$\Phi'(x) \leq \Phi'(y) \quad \forall a < x < y < b \quad (2)$$

Φ je ryze konvexní restliše nerovnost (2) je ostrá.

→ **I** Jestliže Φ je dvakrát diferencovatelná, pak (2) platí \Leftrightarrow

$$\Phi''(x) \geq 0 \quad \forall a < x < b. \quad (3)$$

Ostrá nerovnost ve (3) je postačující (ale nutná) pro pří konvexitu.

Poznámka: Φ je konvexní ale ne pří $\Leftrightarrow \Phi$ je lineární na největším podintervalu (a, b) . Přesněji platí, nerovnost (1) platí jako rovnost pro nějaká x, y a λ , pak Φ je lineární na $[x, y]$.

II Necht Φ je konvexní na $I = (a, b)$ a t_0 je prvním bod I . Pak existuje příčka

$$y = L(x) = c(x - t_0) + \Phi(t_0)$$

bodem $[t_0, \Phi(t_0)]$ taková je

$$L(x) \leq \Phi(x) \quad \forall x \in I.$$

VĚTA (JENSENOVA NEROVNOST)

Jestliže Φ je konvexní na otevřeném intervalu I a X je náhodná veličina taková, že $P(X \in I) = 1$ a $E|X| < \infty$, pak

$$\Phi(EX) \leq E\Phi(X) \quad (5)$$

Jestliže Φ je pří konvexní a nepří $X = \text{const}$ a $P(X = \text{const}) = 1$, pak nerovnost (5) je ostrá.

Důkaz. Necht $L(x)$ je příčka procházející

$$\text{bodem } [t_0, \Phi(t_0)], \quad t_0 = EX$$

a $L(x) \leq \underline{\Phi}(x)$. Pak

$$E \underline{\Phi}(X) \geq E L(X) = E(\theta(X - EX)) + \underline{\Phi}(EX) = \underline{\Phi}(EX)$$

Jestliže $\underline{\Phi}$ je rupe konvexní, pak přímka se dotýká $\underline{\Phi}$ ru bodem t , právě $L(x) < \underline{\Phi}(x)$.

~~$\Rightarrow ELX$~~

Věta nevyplývá možnost $E \underline{\Phi}(X) = \infty$ □

VĚTA (RAO - BLACKWELLOVA).

Necheť X je pozorovatelný náh. vektor ρ rozdělený $P_\theta \in \mathcal{P} = \{P_\theta : \theta \in \Theta\}$ a necheť \mathcal{S} je postadaptivní σ -algebra pro \mathcal{P} .

Necheť T je odhad fee $g(\theta)$ a necheť strážná fee $L(\theta, t)$ je rupe konvexní fee t . Pak, má-li T konečnou střední hodnotu a jistota,

$$\dagger R(\theta, T) = E_\theta L(\theta, T(X)) < \infty \quad \forall \theta$$

a rovná se -li

$$T^*(\mathcal{S}) = E\{T(X) \mid \mathcal{S}(X) = s\}$$

pak jistota odhadu $T^*(\mathcal{S}(X))$ vyhovuje

$$R(\theta, T^*) \leq R(\theta, T)$$

plus neplatí $T(X) = T^*(\mathcal{S}(X))$ s pstí 1.

Důkaz. Položme $\underline{\Phi}(t) = L(\theta, t)$.

$$\begin{aligned} \text{Poté} \\ \underline{\Phi}(T^*(s)) &= L(\theta, T^*(s)) = L[\theta, E(T|S=s)] = \\ &= \underline{\Phi}(E(T|s)) \leq E(\underline{\Phi}(T)|S=s) = \\ &= E[L(\theta, T(X)) | S=s] \quad \text{pokud není } T(X) = T^*(S(X)) \text{ q.s.} \\ \Rightarrow R(\theta, T^*) &= E_{\theta} [L(\theta, T^*(S(X)))] < E_{\theta} [L(\theta, T(X))] \end{aligned}$$

Poznámky: (i) Postupitelnost \mathcal{F} je nutná pro L -tému, že $T^*(s)$ ~~nezávisí na~~ $= E(T(X)|\mathcal{F})$ ~~nezávisí na~~ θ a tedy že je to odhad.

(ii) Pokud $L(\theta, t)$ je nekonzexní, věta platí s ostrou nerovností.

(iii) Pokud L není konvexní, existují protipříklady.

DEFINICE. Odhad T se nazývá **nepřipustný**, pokud existuje jiný odhad T' který dominuje T , tj.

$$R(\theta, T') \leq R(\theta, T) \quad \forall \theta \text{ v ostrou ner. pro alespoň jedno } \theta.$$

Odhad T se nazývá **připustný** (voh. k L), pokud existuje žádný jiný odhad, který ho dominuje.

[4]

Necht

VĚTA (JEDNOZNAČNOST). Jestliže L je ryse konvexní a T je připustný odhad $g(\theta)$ a necht T' je jiný odhad se stejným jízídem, tj.

$$R(\theta, T) = R(\theta, T') \quad \forall \theta \in \Theta.$$

Pak $T(x) = T'(x)$ s pšití 1.

Důkaz. Jestliže $T^* = \frac{1}{2}(T + T')$, pak pokud není $T = T'$

$$R(\theta, T^*) < \frac{1}{2}[R(\theta, T) + R(\theta, T')] = R(\theta, T) \quad \forall \theta$$

pokud není $T = T'$ s pšití 1. To je však ve sporu s připustností T .

Příklady konvexní stráty:

(i) Kvadratická chyba $L(\theta, t) = [t - g(\theta)]^2$

(ii) Vážená kvadratická chyba:
 $L(\theta, t) = w(\theta)(t - g(\theta))^2$

(iii) Absolutní chyba (neryse konvexní)
 $L(\theta, t) = |t - g(\theta)|$

(iv) Huberova strátová fce

$$L(\theta, t) = \begin{cases} (t - g(\theta))^2 & \dots |t - g(\theta)| \leq k \\ 2k|t - g(\theta)| - k^2 & \dots |t - g(\theta)| > k \end{cases} \quad k > 0$$

(v) L_p -chyba $L(\theta, t) = |t - g(\theta)|^p \quad 1 < p < 2$

VEKTOROVÁ ODHADOVÁ FCE :

$$g(\theta) = (g_1(\theta), \dots, g_k(\theta))$$

Odhad $T(x)$ je také k -prvkový vektor.

Reálná fce $\Phi: E \rightarrow \mathbb{R}^1$, kde $E \subset \mathbb{R}^k$ je ^{otevřená} konvexní množina, se nazývá konvexní, když

$$\Phi(\lambda \underline{x}_1 + (1-\lambda)\underline{x}_2) \leq \lambda \Phi(\underline{x}_1) + (1-\lambda)\Phi(\underline{x}_2)$$

$$\forall \underline{x}_1, \underline{x}_2 \in E \text{ a } 0 \leq \lambda \leq 1$$

→ Jestliže Φ je dvakrát diferencovatelná v E , ~~jestliže~~ pak Φ je konvexní \iff

$$\underline{H} = \left(\frac{\partial^2 \Phi(\underline{x}_1, \dots, \underline{x}_k)}{\partial x_i \partial x_j} \right)_{i,j=1, \dots, k} \quad (\text{Hessova matice})$$

~~je~~ pozitivně semidefinitní

a Φ je ~~je~~ konvexní \iff H je pozitivně definitní

→ Jestliže Φ je konvexní definovaná na otevřené konvexní množině $E \subset \mathbb{R}^k$, $\underline{t}_0 \in E$ pevný bod, pak existuje rovnice

$$L(\underline{x}) = \sum_{i=1}^k c_i (x_i - t_i^0) + \Phi(\underline{t}_0)$$

procházející bodem $(\underline{t}_0, \Phi(\underline{t}_0))$ a vyhovující

$$L(\underline{x}) \leq \Phi(\underline{x}) \quad \forall \underline{x} \in E.$$

[9]

→ Jestliže X je náhodný vektor, $P(X \in A) = 1$ pro nějakou omezenou konvexní množinu A pak a jestliže existuje $E\tilde{X}$, pak $E\tilde{X} \in A$.
Důkaz redukcí a sporu. X je lineárně jednodušší fci

NESTRANNÉ ODHADY.

$$E_{\theta}(T(X)) = g(\theta) \quad \forall \theta \in \Theta$$

Nestranný odhad nemusí existovat: Příklad
 $X \sim b(n, p)$, $g(p) = 1/p$

$$\text{Nestrannost} \Rightarrow \sum_{k=0}^n T(k) \binom{n}{k} p^k (1-p)^{n-k} = 1/p \quad \forall p \in (0, 1)$$

Jestliže $p \rightarrow 0$, pak levá strana $\rightarrow T(0)$ a
pravá strana $\rightarrow \infty$

Jestliže existuje nestranný odhad $g(\theta)$, pak g harmonické odhadnutelnou fci θ (nestranné)

LEMMA (struktura třídy nestranných odhadů)

Jestliže T_0 je nestranný odhad $g(\theta)$, pak
třída vs. nestranných odhadů je charakterizována
vztahem

$$T = T_0 - U$$

kde U je libovolný nestranný odhad nuly, tj.

$$E_{\theta} U = 0 \quad \forall \theta \in \Theta$$

Jestliže $L(\theta, t) = (t - g(\theta))^2$, pak $R(\theta, T) =$
 $= E_{\theta}(T - g(\theta))^2 = \text{var}_{\theta} T(X)$ pro nestranné odhady.

Jestliže T^0 minimalizuje $\text{var}_{\theta} T(X)$ pro $\forall \theta$ mezi
 všemi nestrannými odhady T , pak T^0 se nazývá
stopa nejlepší nestranný odhad SNNO

Označme $\Delta =$ množina nestranných odhadů T
 splňujících $E_{\theta} T^2 < \infty \forall \theta \in \Theta$

VĚTA. Necht' $X \sim P_{\theta}, \theta \in \Theta$, necht' $T \in \Delta$ a

necht' \mathcal{M} označuje množinu všech nestranných
 odhadů U , které patří do Δ . Pak

T je SNNO své střední hodnoty $g(\theta) \iff$

$$E_{\theta}(T(X) \cdot U(X)) = 0 \quad \forall U \in \mathcal{M} \text{ a } \theta \in \Theta$$

Důkaz. (i) ^{nutnost} Necht' T je SNNO, $E_{\theta} T(X) = g(\theta)$.

Necht' $U \in \mathcal{M}$ a položíme $T^1 = T + \lambda U, \lambda \in \mathbb{R}^1$.

Pak

$$E_{\theta} T^1(X) = E_{\theta} T(X) = g(\theta) \quad \forall \theta$$

$$\Rightarrow \text{var}_{\theta}(T^1(X)) \geq \text{var}_{\theta} T(X) \quad \forall \lambda \in \mathbb{R}^1 \Rightarrow E_{\theta} T^1{}^2 \geq E_{\theta} T^2$$


$$\text{tj.} \quad E_{\theta} T^2 + \lambda^2 E_{\theta} U^2 + 2\lambda E_{\theta}(T \cdot U) \geq E_{\theta} T^2$$

$$\Rightarrow \lambda^2 E_{\theta} U^2 + 2\lambda E_{\theta}(T \cdot U) \geq 0 \quad \forall \lambda \quad (*)$$

~~to~~ ~~pro~~ ~~že~~ ~~me~~ ~~že~~ ~~řeš~~ ~~íme~~ kvadratickou rovnicí (*)

$$D = \frac{(\text{var}_\theta U)^2}{4} - 4(\text{cov}_\theta(T, U))^2 = 4$$

$$\lambda = 0 \quad \lambda = -2 \text{cov}_\theta(T, U) / \text{var}_\theta U$$



Konvexní fce, která má jediné minimum $\lambda = 0 \Leftrightarrow E_\theta(U) = 0$
 právě když $E_\theta(T^2) > E_\theta(T)^2$

a tedy kvadratická fce může nabývat záporných hodnot pokud není $\text{cov}_\theta(T, U) = 0$

(ii) Postaraditelnost. Necht' $E_\theta(T \cdot U) = 0 \quad \forall U \in \mathcal{U}$.

Necht' T' je nestranný odhad $E_\theta T' = g(\theta)$.
 Jestliže $\text{var}_\theta T' = \infty$, nemůže být lepší než T .

Necht' $\text{var}_\theta T' < \infty$. Pak $\text{var}_\theta(T^\# - T') < \infty$
 a $T^\# - T' \in \mathcal{U} \Rightarrow$

$$\Rightarrow E_\theta(T(T - T')) = 0 \Rightarrow$$

$$\Rightarrow E_\theta T^2 = E_\theta(TT') \Rightarrow E_\theta T^2 - g(\theta)^2 = E_\theta(TT') - g(\theta)^2$$

$$\Rightarrow \text{var}_\theta T = \text{cov}_\theta(T, T')$$

$$\stackrel{0 \leq}{\Rightarrow} \text{var}_\theta(T - T') = \text{var}_\theta T + \text{var}_\theta T' - 2 \text{var}_\theta T$$

$$\Rightarrow \text{var}_\theta T \leq \text{var}_\theta T'. \quad \square$$

VĚTA (jednosměrnost ~~SANO~~) = nestranneho odhadu)
 Necht $X \sim P_\theta \in P$ a necht S je úplná postačující statistika pro P . Pak každá nestranne odhadnutelná funkce $g(\theta)$ má právě jeden nestranne odhad, který je funkcí S .

Důkaz

Necht T je nestranne odhad $g(\theta) \Rightarrow$
 \Rightarrow podle Rao-Blackwell $T^*(S(X)) = E(T(X) | S(X))$
 je nestranne a je fcní S .

Necht $T_1(S)$ a $T_2(S)$ jsou 2 nestranne odhady.
 Pak $E_\theta(T_1 - T_2) = 0 \quad \forall \theta \in \Theta, S \text{ úplná} \Rightarrow$
 $\Rightarrow T_1 - T_2 = 0$ s.j. $[P_\theta], \theta \in \Theta \quad \square$

VĚTA (Lehmann - Scheffe)

Necht $X \sim P_\theta \in P = \{P_\theta : \theta \in \Theta\}$. Necht S je úplná postačující pro P .

(i) Pro každou nestranne odhadnutelnou fcní $g(\theta)$ a pro každou stratovou fcní $L(\theta, t)$ konvergující v t k $g(\theta)$ nestranne odhad který minimálně realizuje riziko. Speciálně, tento odhad je také SANO NOMR

(ii) Tento SANO je jedním nestranne odhadem, který je fcní S . Je to také jedním nestranne odhadem minimálního rizika, pokud je riziko konvexní a L je ryze konvergující v t .

Důkaz (i) R.B. věta platí pro lib. strukturní fci.
Podle předcházející věty je T^* lineárně jednorázová fci.

a $T^*(S) = E_{\theta}(T|S)$ minimální jevíčko vzhledem
k libovolné ~~al~~ konvexní strukture.

Důsledek Jestliže P je exponenciální systém plus

hodnosti (tj. $f(\underline{x}|\underline{\theta}) = \exp\left\{\sum_{j=1}^p \eta_j(\underline{\theta}) T_j(\underline{x}) + A(\underline{\theta}) + B(\underline{x})\right\}$

$\exp\left\{\sum_{j=1}^p \theta_j \xi_j(\underline{x}) + A(\underline{\theta}) + B(\underline{x})\right\}$, $\underline{\theta} \in \Theta$ } kde

Θ obsahuje neprázdný p rozměrný interval, pak
tvrzení Lehmann-Scheffého věty platí pro
 $\underline{\theta} = (\theta_1, \dots, \theta_p)$ a $\underline{\xi} = (\xi_1, \dots, \xi_p)$.

UVEDÁNÍ SNNO: Necht' $S(\underline{x})$ je úplná postava.

(i) SNNO je odhadem četnosti fce $g(\underline{\theta})$ je lib. fce
fce $T(S)$ taková, že

$$(*) \quad E_{\theta} T(S) = g(\theta) \quad \forall \theta \in \Theta$$

Příklad. $P(X_i=1) = p$, $P(X_i=0) = 1-p$, $i=1, \dots, n$

$S(\underline{x}) = \sum_{i=1}^n X_i$. Položíme $g(p) = p(1-p)$. Pak

tvrzení (*) má tvar

$$\sum_{s=0}^n \binom{n}{s} T(s) p^s (1-p)^{n-s} = p(1-p) \quad \forall 0 < p < 1$$

$$\sum_{s=0}^n \binom{n}{s} T(s) \left(\frac{p}{1-p}\right)^s \cdot (1-p)^n = p(1-p)$$

$$\sum_{s=0}^n \binom{n}{s} T(s) \left(\frac{p}{1-p}\right)^s = \frac{p}{(1-p)^{n-1}}$$

Povinnosť $\frac{p}{1-p} = \rho \Rightarrow p = (1-p)\rho \Rightarrow p = \frac{\rho}{1+\rho}$

$$1-p = \frac{1}{1+\rho} \Rightarrow$$

$$\Rightarrow \sum_{s=0}^n \binom{n}{s} T(s) \rho^s = \frac{\rho}{1+\rho} \cdot (1+\rho)^{n-1} = \rho \cdot (1+\rho)^{n-2}$$

binomial

$$= \sum_{i=0}^{n-2} \binom{n-2}{i} \rho^{i+1} = \sum_{s=1}^{n-1} \binom{n-2}{s-1} \rho^s, \quad 0 < \rho < \infty$$

binomial siba *počuvateľ koeficienty*

$T(0) = 0, \quad T(n) = 0$

$$\Rightarrow \binom{n}{s} T(s) = \binom{n-2}{s-1}$$

$$\sum_{s=0}^n \binom{n}{s} T(s) \rho^s = \sum_{s=1}^{n-1} \binom{n-2}{s-1} \rho^s$$

$$T(s) = \frac{\binom{n-2}{s-1}}{\binom{n}{s}} = \frac{(n-2) \dots (n-s) s!}{(s-1)! n \dots (n-s+1)} = \frac{n(n-1)s}{n(n-1)}$$

$$= \frac{s(n-s)}{n(n-1)}$$

SNHO

Odhad

$p(1-p):$

$$\frac{(\sum x_i) (n - \sum x_i)}{n(n-1)}$$

(ii) Metoda dvou: Podmínování.

Vypne od lib. nestranného odhadu $T(X)$. Pak

$$T'(X) = E(T(X) | S) \text{ je SNNO}$$

Příklad. $X_1, \dots, X_n \sim R(0, \theta)$

$$g(\theta) = \frac{\theta}{2}$$

Pak $S = X_{(n)}$ je úplná postačující

$$EX_1 = \frac{1}{\theta} \int_0^{\theta} x dx = \frac{\theta}{2} \Rightarrow X_1 \text{ je nestranný!}$$

$$f(x|\theta) = \begin{cases} \frac{1}{\theta} & \dots & 0 < x < \theta \\ 0 & \dots & \text{inak} \end{cases}$$

$$E[X_1 | S=s] = \dots$$

Jestliže $S = X_{(n)} = s$ podle $(n-1)$ pozorování leti nalevo od s a na místě $f(x|\theta)$

$$1 - F(x|\theta)$$

Jestliže $S = X_{(n)} = s$ pak buď $X_1 = s$ s pšk $\frac{1}{n}$

nebo $X_1 \sim R(0, s)$ s pšk $1 - \frac{1}{n}$.

$$E(X_1 | s) = \frac{1}{n} s + \frac{n-1}{n} \frac{s}{2} = \frac{s}{2} \cdot \frac{n+1}{n}$$

Tedy $\frac{s}{2} \frac{n+1}{n}$ je SNNO pro $\frac{\theta}{2}$

RAO-CRAMÉROVA DOLNÍ HRANICE

Uvažujme systém rozdělení pŕstí $\mathcal{P} = \{p_\theta : \theta \in \Theta\}$
s hustotami $p(x; \theta)$ vzhledem k μ .

Předpokládejme ŕe

(A.1) Θ je otevřený interval

(A.2) $B = \{x : p(x; \theta) > 0\}$ nezávisí na $\theta \in \Theta$.

(A.3) $\frac{\partial p(x; \theta)}{\partial \theta} = p'(x; \theta)$ existuje a je konečná
pro $x \in B$, $\theta \in \Theta$. Poloŕme

$$I(\theta) = E_\theta \left[\frac{\partial}{\partial \theta} \log p(x; \theta) \right]^2 = \int \left(\frac{p'(x; \theta)}{p(x; \theta)} \right)^2 p(x; \theta) d\mu$$

FISHEROVA MÍRA INFORMACE, kterou X obsahuje
o θ .

VĚTA 1. Necht X a Y jsou nezávislé s hustotami
 p_θ a q_θ vzhledem k μ a ν , vyhovujícími (A.1)-(A.3)

Necht $I_1(\theta)$, $I_2(\theta)$ jsou Fisherovy informace X , Y
a $I(\theta)$ je Fisherova míra (X, Y) . Pak

$$I(\theta) = I_1(\theta) + I_2(\theta).$$

Důkaz. Hustota (X, Y) je $p_\theta(x) \cdot q_\theta(y) = h_\theta(x, y)$

$$\frac{\partial \log h_\theta(x, y)}{\partial \theta} = \frac{\partial \log p_\theta(x)}{\partial \theta} + \frac{\partial \log q_\theta(y)}{\partial \theta}$$

VĚTA (INFORMAČNÍ NEROVNOST)

Nechť platí (A.1) - (A.3), $I(\theta) > 0$ a $\int p(x, \theta) d\mu$ lze derivovat za integrálem. Pak Necht $T(X)$ je libovolná statistika taková, že $E_{\theta} T^2 < \infty$ a $E_{\theta} T$ lze derivovat za integrálem.
~~existuje a~~

$$\text{Pak } \text{var}_{\theta} T(X) \geq \frac{\left(\frac{\partial}{\partial \theta} E_{\theta} T\right)^2}{I(\theta)}$$

Důkaz: Podle (*) ~~$\text{var}_{\theta} T =$~~

$$\text{cov}_{\theta} \left(T(X), \frac{\partial \log p(X, \theta)}{\partial \theta} \right) \leq \left(\text{var}_{\theta} T \cdot I(\theta) \right)^{\frac{1}{2}}$$

Položme $g(\theta) = E_{\theta} T(X) = \int T(x) p(x, \theta) d\mu$

$$(g'(\theta))^2 = \left(\int T(x) p'(x, \theta) d\mu \right)^2 = \left(\int (T(x) - g(\theta)) p'(x, \theta) d\mu \right)^2$$

$$\leq \text{var}_{\theta} T \cdot I(\theta) \Rightarrow \text{var}_{\theta} T \geq \frac{(g'(\theta))^2}{I(\theta)}$$

Jestliže T je odhad $g(\theta)$ a $E_{\theta} T = g(\theta) + b(\theta)$

pak

$$\text{var}_{\theta} T \geq \frac{(b'(\theta) + g'(\theta))^2}{I(\theta)}$$

VEKTOROVÝ PARAMETR

$X \sim p(x|\theta)$, $\theta \in \Theta$, $\theta = (\theta_1, \dots, \theta_k)$, odhadujeme $g(\theta)$

(B.1) Θ otevř. interval

(B.2) $A = \{x: p(x|\theta) > 0\}$ ust. na θ

(B.3) $\frac{\partial p(x|\theta)}{\partial \theta_i}$ ex. a p. současně $\forall \theta \in \Theta$
 $x \in A$
 $i = 1, \dots, k.$

Informační matice: $I(\theta) = (I_{ij}(\theta))_{i,j=1,\dots,k}$

$$I_{ij}(\theta) = E \left[\frac{\partial}{\partial \theta_i} \log p(x|\theta) \cdot \frac{\partial}{\partial \theta_j} \log p(x|\theta) \right]$$

Předpokladem $= - E \left[\frac{\partial^2}{\partial \theta_i \partial \theta_j} \log p_\theta(x) \right]$

(B.4) $I_{ij}(\theta)$ lze získat derivováním za integrálu
 a $E \left[\frac{\partial}{\partial \theta_i} \log p(x|\theta) \right] = 0$

~~$X \sim p_\theta(x)$, chceme odhadnout $g_1(\theta), \dots, g_k(\theta)$
 $\theta_1, \dots, \theta_k$~~

VĚTA (INFORMAČNÍ NEROVNOST)

Necheť platí (B.1) - (B.4) a necheť $I(\theta)$ je pozitivně definitní $\forall \theta$. Necheť $T(X)$ je lib. \sim statistická funkce, je $E_{\theta} T(X)$ existuje a lze ji derivovat na intervalu $\theta_1, \dots, \theta_k$. Označme

$$\alpha_i(\theta) = \frac{\partial}{\partial \theta_i} E_{\theta} (T(X)), \quad i=1, \dots, k, \quad \underline{\alpha} = (\alpha_1, \dots, \alpha_k)'$$

Pak

$$\text{var}_{\theta} T(X) \geq (\underline{\alpha}(\theta))' I^{-1}(\theta) \underline{\alpha}(\theta).$$

Důkaz: Položme

$$\psi_i(X; \theta) = \frac{\partial}{\partial \theta_i} \log p_{\theta}(X), \quad i=1, \dots, k.$$

Uvažujme kovlační koeficient

$$\begin{aligned} \text{cor}_{\theta} \left(\sum_{i=1}^k a_i \psi_i(X; \theta), T(X) \right) &= \text{cor}_{\theta} \left(T(X), \sum_{i=1}^k a_i \frac{\partial}{\partial \theta_i} \log \right) \\ &= \frac{\sum_{i=1}^k a_i \text{cov}_{\theta} \left(\sum_{i=1}^k a_i \psi_i(X; \theta), T(X) \right)}{\left(\text{var}_{\theta} \sum_{i=1}^k a_i \psi_i(X; \theta) \cdot \text{var}_{\theta} T(X) \right)^{1/2}} \end{aligned}$$

Chceme maximalizovat vzhledem k a_1, \dots, a_k . Protože je kovvarianční vhl. Σ měnitelná, nepoužijeme a_i určíme předem, a tedy je normujeme podmínkou

$$\text{var} \left(\sum_{i=1}^k a_i \psi_i(X; \theta) \right) = \underline{a}' \underline{I}(\theta) \underline{a} = 1$$

$$\underline{a}' I(\theta) \underline{a} = 1$$

a hledáme maximum of

$$\frac{\text{cov}_{\theta} \left(\sum_{i=1}^k a_i \psi_i(X), T(X) \right)}{(\text{var}_{\theta} T(X))^{1/2}} = \text{max} \text{ za podmínky}$$

$a^T I(\theta) a = 1$
 a_i pro toto max platí Schwarzova nerovnost

$$\Rightarrow \sum_{i=1}^k a_i \text{cov}_{\theta}(\psi_i(X), T(X)) = \text{max}$$

$= \alpha_i$

$$\Rightarrow \sum_i a_i \alpha_i - \frac{1}{2} \lambda (a^T I(\theta) a - 1) = \text{max}$$

$$a^T I(\theta) a = 1$$

$$\alpha_i - \lambda \sum_{j=1}^k I_{ij} a_j = 0$$

$$\alpha_i - \lambda \sum_{j=1}^k I_{ij} a_j = 0$$

$$\alpha - \lambda I(\theta) a = 0$$

$$a = \frac{1}{\lambda} I^{-1} \alpha = \frac{1}{\lambda} I^{-1} \alpha$$

$$a^T \alpha = \lambda a^T I a = \lambda$$

$$\frac{1}{\lambda^2} \alpha^T I^{-1} \alpha = 1, \quad \lambda^2 =$$

$$= \frac{\alpha^T I^{-1} \alpha}{\alpha^T I^{-1} \alpha}$$

$$a = \frac{\pm I^{-1} \alpha}{\sqrt{\alpha^T I^{-1} \alpha}}$$

$$\text{max cov} = \frac{\alpha^T I^{-1} \alpha}{\sqrt{\alpha^T I^{-1} \alpha}} / (\text{var}_{\theta} T(X))^{1/2} \leq 1$$

$$\Rightarrow \text{var}_{\theta} T(X) \geq \alpha^T I^{-1} \alpha$$

Jestliže $E_{\theta} T(X) = \underbrace{g(\theta)} + \underbrace{b(\theta)}$, pak

$$\alpha_i = \frac{\partial}{\partial \theta_i} (b(\theta) + g(\theta))$$

ODHAD PARAMETRU POLOHY

X_1, \dots, X_n iid , $\sim F(x-\theta)$

Hustota $X_1, \dots, X_n \sim \prod_{i=1}^n f(x_i - \theta)$ (1) Chceme odhadnout θ

Předpokládáme, že strata $L(\theta, t) = L(\theta + c, t + c)$ je invariantní. Pak $L(\theta, t) = L(\theta, t - \theta) \Rightarrow$ (2)

\Rightarrow strata závisí jen na odchylce $t - \theta$.

a problém odhadu θ můžeme invariantně
rozhlédnout a posunout. Jestliže $T(X)$ je odhadem
 θ , pak přírodním odhadem $\theta + c$ bude $T(X) + c$

Omezení se na invariantní odhady

$$T(X_1 + c, \dots, X_n + c) = T(X_1, \dots, X_n) + c \quad \forall c$$

LEMMA 1. ~~*~~ Vychýlením, posunem a použitím ekvivalentního odhadu nezávisí na θ (a tedy jsou invariantní).

Důkaz. $X_1 \sim f(x-\theta) \Rightarrow P(X_1 - \theta < z) = P(X_1 < z + \theta) = F(z)$

$$\Rightarrow X_1 - \theta \sim f(x)$$

$$b(\theta) = E_{\theta}(T(X)) - \theta = E_{\theta} T(X - \theta) = E_{\theta}(T(X)) = b$$

$$\text{var}_{\theta} T(X) = E_{\theta} (T(X) - E_{\theta} T(X))^2 =$$

$$X - \theta = X_0 \quad E_{\theta} (T(X - \theta) + \theta - E_{\theta} T(X))^2 =$$

$$= E_{\theta} (T(X - \theta) - b)^2 = E_{\theta} (T(X) - b)^2$$

$$\mu(T, \theta) = E_{\theta} L(T(X) - \theta) = E_{\theta} L(T(X - \theta)) =$$

$$= E_{\theta} L(T(X))$$

ekvovariantní

Budeme hledat odhad ρ minimálního rizika.
(MRE)

LEMMA 2 Necht T_0 je ekvovariantní odhad.
Platí $T(X)$ je ekvovariantní \iff (3) $T(\underline{x}) = T_0(\underline{x}) + U(X)$

kde $U(\underline{x})$ je lib. funkce splývající

$$U(\underline{x} + c, \dots, \underline{x}_n + c) = U(\underline{x}_1, \dots, \underline{x}_n) \quad \forall \underline{x}, c \in \mathbb{R}^1(\mathbb{R})$$

Důkaz ., Necht platí (3) a (4). Pak

$$\begin{aligned} T(\underline{x} + c) &= T_0(\underline{x} + c) + U(\underline{x} + c) = T_0(\underline{x}) + c + U(\underline{x}) \\ &= T(\underline{x}) + c \end{aligned}$$

Necht T je ekvovariantní, T_0 je ekvovariantní.
Položíme $U(\underline{x}) = T(\underline{x}) - T_0(\underline{x}) \implies U(\underline{x} + c) = U(\underline{x})$

LEMMA. For $U(x)$ je equivariant $\Leftrightarrow U$ je pouziti funkci predeli $y_i = x_i - x_n, i=1, \dots, n-1$ pokud $n \geq 2$; U je konst. pokud $n=1$.

$$U(x+c) = U(x) \Rightarrow U(x_1, \dots, x_n) = U(x_1 - x_n, \dots, x_{n-1} - x_n)$$

$$U(x_1, \dots, x_n) = U^*(y_1, \dots, y_{n-1})$$

$$\Rightarrow U(x_1+c, \dots, x_n+c) = U^*(y_1, \dots, y_{n-1}).$$

LEMMA. Jestliže T_0 je equivariant, pak T je equivariant $\Leftrightarrow T(x) = T_0(x) - U^*(y)$.

VĚTA. Necht $X = (X_1, \dots, X_n) \sim (1)$
 $Y_i = X_i - X_n, i=1, \dots, n-1$

$$L(\theta, t) = L(t - \theta)$$

Necht T_0 je equivariant odhad ρ lossesu je invariant.

Jestliže $\forall y$ existuje $v(y) = v^*(y)$ které ρ minimalizuje

$$E_0 \{ L(T_0(X) - v(Y)) | Y=y \}$$

pak MRE existuje a je rovno

$$T^*(x) = T_0(x) - v^*(y)$$

Důkaz. $T(x) = T_0(x) - v(y)$

$$R_\theta(T(x), \theta) = E_\theta L(T_0(x) - v(y) - \theta)$$

$$= R_0(T) = E_0 L(T_0(X) - v(Y)) = E_0 E_0 \{ L(T_0(X) - v(Y)) | Y=y \}$$

$$= \int E_0 (L(T_0(X) - v(y)) | y) dP_0(y) = \min$$

vzhledem k $v(y)$. $R_0(T)$ je minimální podle integrand je minimalizován $\forall y$ \square

Důsledek. Předpokládáme, že $L(t)$ je konvexní a nemonotonní $t > 0$. Pak existuje MRE a je určen funkcí L je typu $\frac{t}{t+1}$ konvexní.
Důkaz

$$E_0 [L(T_0(X) - v(y)) | y] \stackrel{!}{=} \min$$

$$E_0 [L(T_0(X) - v(y)) | y] \geq$$

$$\geq L E [T_0(X) - v(y) | y] =$$

$$= L \{ E(T_0(X) | y) - v(y) \}$$

Důsledek. a) Položíme $L(t-\theta) = (t-\theta)^2$. Pak

$$v^*(y) = E_0 (T_0(X) | Y=y)$$

b) Jestliže $L(t-\theta) = |t-\theta|$, pak $v^*(y)$ je medianu $T_0(X)$ vzhledem k podmíněnému rozdělení $X|y$