

A december 5-i szeminárium témája

Rövid összefoglaló

A matematikai statisztika rendkívül fontos témái a becsléelmélet, a hipotézisvizsgálat és konfidencia intervallumok meghatározása. A gyakorlat utolsó két óráján ezekkel a témákkal foglalkozunk. Ennek a gyakorlatnak a témája a becsléelmélet. A tipikus becsléelméleti problémák a következő jellegűek.

Adott független, egyforma eloszlású valószínűségi változók egy ξ_1, \dots, ξ_n sorozata, melyek eloszlása valamely $F_\vartheta(\cdot)$ eloszlásfüggvény valamilyen ismeretlen ϑ paraméterrel. Becsüljük meg ezt a ϑ paramétert, azaz az $F_\vartheta(\cdot)$ eloszlásfüggvényt minél jobban. Formálisan, definiáljunk olyan $T_n(x_1, \dots, x_n)$ n -változós függvényt, melyre a megfigyelt véletlen ξ_1, \dots, ξ_n sorozat segítségével kiszámítható $\hat{\vartheta}_n = T_n(\xi_1, \dots, \xi_n)$ valószínűségi változó valamilyen értelemben jól közelíti az ismeretlen ϑ paramétert.

Vizsgálhatjuk azt az általánosabb problémát, amikor az ismeretlen $F_{\vartheta_1, \dots, \vartheta_k}(\cdot)$ eloszlásfüggvény k ismeretlen $\vartheta_1, \dots, \vartheta_k$ paramétertől függ, (ahol k valamely rögzített egész szám,) és becsüljük meg az összes $\vartheta_1, \dots, \vartheta_k$ paramétert. Előfordulhat olyan eset is, amikor ezen ismeretlen paraméterek közül csak néhányat akarunk megbecsülni, de nem mindegyiket. Az ilyen jellegű problémákat nevezzük paraméteres becslési problémának. Előfordulhat, hogy a következő problémával foglalkozunk. Adott független, egyforma eloszlású valószínűségi változók egy ξ_1, \dots, ξ_n sorozata, melyek eloszlása valamely ismeretlen $F(\cdot)$ eloszlásfüggvény. Jelen esetben nem tudunk semmit az ismeretlen eloszlásfüggvényről. Becsüljük meg a ξ_k valószínűségi változók várható értékét, szórásnégyzetét vagy az eloszlását. Az ilyen problémákat hívják nem paraméteres becslési problémának.

Először tekintünk néhány példát.

1. Egy pénzdarabot sokszor egymás után feldobunk. Becsüljük meg annak a valószínűségét, hogy a pénzdarab a fejtoldalra esik.

Írjunk 1-t fejdobás és 0-t írásdobás esetén. Ekkor a probléma formálisan a következő módon fogalmazható meg: Adott független $B(1, p)$ eloszlású (binomiális eloszlású, 1 és p paraméterekkel), valószínűségi változók ξ_1, \dots, ξ_n sorozata (az egyes dobások eredményei), ahol a p paraméter ismeretlen. Becsüljük meg ezt az ismeretlen p paramétert.

A természetes becslés, $\hat{p}_n = \frac{1}{n} \sum_{k=1}^n \xi_k$, azaz $T_n(x_1, \dots, x_n) = \frac{1}{n} \sum_{k=1}^n x_k$. Ekkor

$$\hat{p}_n = T_n(\xi_1, \dots, \xi_n) = \frac{1}{n} \sum_{k=1}^n \xi_k = \frac{\text{A fejdobások száma}}{n}.$$

A nagy számok törvénye szerint $\hat{p}_n \Rightarrow p$, ahol \Rightarrow sztochasztikus konvergenciát jelöl, azaz $\lim_{n \rightarrow \infty} P(|\hat{p}_n - p| > \varepsilon) \rightarrow 0$ minden $\varepsilon > 0$ számra.

2. Arra vagyunk kíváncsiak, hogy egy dobókocka milyen valószínűséggel esik különböző oldalaira. Ennek meghatározása érdekében a dobókockát feldobjuk sokszor, és megjegyezzük, hogy a különböző dobások során melyik oldalára esett a kocka.

Formálisan megfogalmazva a probléma a következő: Adott F_{p_1, \dots, p_6} eloszlássorozat, (ez az eloszláscsalád valójában csak 5 paramétertől függ, mert a $p_1 + \dots + p_6 = 1$ reláció teljesül.) úgy, hogy egy F_{p_1, \dots, p_6} eloszlású ξ valószínűségi változóra $P(\xi = j) = p_j$, $j = 1, 2, \dots, 6$. Becsüljük meg az ismeretlen p_j paramétereket. A természetes becslés a következő:

$$\hat{p}_j = \frac{\text{A } j \text{ eredményű dobások száma}}{n}, \quad 1 \leq j \leq 6.$$

Formálisan, $\hat{p}_j = T_j(\xi_1, \dots, \xi_n)$, $1 \leq j \leq n$, ahol

$$T_j(x_1, \dots, x_n) = \frac{\text{a } j \text{ értékek száma az } x_1, \dots, x_n \text{ sorozatban}}{n}.$$

A nagy számok törvénye alapján érvényes a $\hat{p}_j \Rightarrow p_j$, $1 \leq j \leq 6$ reláció, ahol \Rightarrow sztochasztikus konvergenciát jelöl.

E feladat egy módosított változata: Az előző problémát tekintjük, de minket csak az érdekel, hogy milyen valószínűséggel esik a kocka a hatos oldalra. Ez egy természetes példa arra, amikor egy több paramétertől függő eloszláscsaládot figyelünk meg, de minket csak néhány, (jelen esetben egy) paraméter értéke érdekel.

3. Ledobunk egymástól függetlenül n pontot, melyek egy $[\vartheta, \vartheta + 1]$ intervallumba esnek egyenletes eloszlással, azaz annak valószínűsége, hogy egy pont a $[\vartheta, \vartheta + 1]$ egy részintervallumába esik megegyezik ennek az intervallumnak a hosszával. Jelölje ξ_1, \dots, ξ_n a ledobott pontok helyét. Becsüljük meg ezek ismeretében az ismeretlen ϑ paramétert.

Erről a feladatról már volt szó a november 14-i gyakorlaton. Megbeszéltük, hogy két természetes becslés jelenik meg. Az egyik: $\tilde{\vartheta}_n = \frac{\xi_1 + \dots + \xi_n}{n} - \frac{1}{2}$, a másik $\hat{\vartheta}_n = \frac{\xi_1^* + \xi_n^*}{n} - \frac{1}{2}$, ahol $\xi_1^* < \xi_2^* < \dots < \xi_n^*$, a ξ_1, \dots, ξ_n (véletlen) számok nagyság szerinti sorrendbe rakva. (Ezt hívják az irodalomban rendezett mintának.) Láttuk, hogy mind a két becslés jó, de a második becslés jobb az elsőnél a következő értelemben: $E\tilde{\vartheta}_n = \vartheta$, és $E\hat{\vartheta}_n = \vartheta$, azaz mind a két becslés várható értéke megegyezik a keresett paraméterrel. Viszont a várható érték körüli ingadozást természetes módon mérő szórásnégyzetekre a következő reláció érvényes: $\text{Var } \tilde{\vartheta}_n = \frac{1}{12n}$, és $\text{Var } \hat{\vartheta}_n = \frac{1}{2(n+1)(n+2)}$. Ezért $\text{Var } \tilde{\vartheta}_n \geq \text{Var } \hat{\vartheta}_n$ minden $n \geq 2$ számra.

4. Legyen egy lámpa élettartama exponenciális eloszlású valószínűségi változó ismeretlen λ paraméterrel, azaz $f(x) = \lambda e^{-\lambda x}$, ha $x \geq 0$, és $f(x) = 0$, ha $x \leq 0$. Megvizsgáljuk n lámpa élettartamát. Ezek (egymástól független) ξ_1, \dots, ξ_n exponenciális eloszlású valószínűségi változók λ paraméterrel. Becsüljük meg a λ paramétert.

Első ránézésre nem tudunk kitalálni egy természetes becslést erre a λ paraméterre. Természetes kívánság egy olyan általános elv megfogalmazása, mely az általános esetben, például erre a problémára is egy jó módszert ad egy ismeretlen paraméter

becslésére. Ilyen módszer az alább ismertetett maximum likelihood módszer. Ez általános elvet fogalmaz meg ismeretlen paraméter(ek) becslésére. Másik jó tulajdonsága a maximum likelihood módszernek az, hogy bizonyos itt nem ismertetett eredmények azt mondják ki, hogy a maximum likelihood módszer általános feltételek esetén nagy mintaelemszám esetén aszimptotikusan optimális eljárást nyújt.

Maximum likelihood módszer. Legyen adva eloszlásfüggvényeknek egy λ vagy véges sok $(\lambda_1, \dots, \lambda_k)$ valós számal paraméterezett családja, melyeknek van

$$f_\lambda(x) = f(\lambda, x) \quad \text{vagy} \quad f_{\lambda_1, \dots, \lambda_k}(x) = f(\lambda_1, \dots, \lambda_k, x), \quad -\infty < x < \infty,$$

alakú sűrűségfüggvényük. Legyen ξ_1, \dots, ξ_n független, egyforma eloszlású valószínűségi változók sorozata ezzel az $f_\lambda(x) = f(\lambda, x)$ vagy $f(\lambda_1, \dots, \lambda_k, x)$ sűrűségfüggvénnyel az ismeretlen λ paraméterrel vagy ismeretlen $(\lambda_1, \dots, \lambda_k)$ paramétercsaláddal. Ekkor a ξ_1, \dots, ξ_n sorozat együttes sűrűségfüggvénye az $f(\lambda, x_1, \dots, x_n) = \prod_{j=1}^n f(\lambda, x_j)$ il-

letve az $f(\lambda_1, \dots, \lambda_k, x_1, \dots, x_n) = \prod_{j=1}^n f(\lambda_1, \dots, \lambda_k, x_j)$ n -dimenziós sűrűségfüggvény.

Helyettesítsük be ebbe a paraméterektől függő sűrűségfüggvénybe a megfigyelt ξ_1, \dots, ξ_n valószínűségi változókat, azaz tekintsük az

$$f(\lambda_1, \dots, \lambda_k, \xi_1, \dots, \xi_n) \quad \text{illetve az} \quad f(\lambda_1, \dots, \lambda_k, \xi_1, \dots, \xi_n)$$

valószínűségi változót. Azt mondjuk, hogy a $\hat{\lambda}(\xi_1, \dots, \xi_n)$ (véletlen) szám maximum likelihood becslése a λ paraméternek, a $\hat{\lambda}_j(\xi_1, \dots, \xi_n)$, $1 \leq j \leq k$, (véletlen) k dimenziós vektor maximum likelihood becslése a $(\lambda_1, \dots, \lambda_k)$ vektornak, ha ez a szám illetve vektor (lokális) maximuma az $f(\lambda, \xi_1, \dots, \xi_n)$ illetve az $f(\lambda_1, \dots, \lambda_k, \xi_1, \dots, \xi_n)$ függvénynek rögzített ξ_1, \dots, ξ_n számra.

Megjegyzés: A maximum likelihood becslésben lehet a sűrűségfüggvény maximuma helyett annak logaritmusát vizsgálni, azaz a $\log f(\lambda, \xi_1, \dots, \xi_n) = \sum_{j=1}^n \log f(\lambda, \xi_j)$, illetve

a $\log f(\lambda_1, \dots, \lambda_k, \xi_1, \dots, \xi_n) = \sum_{j=1}^n \log f(\lambda_1, \dots, \lambda_k, \xi_j)$ függvény maximumát keresni.

Ez a

$$\sum_{j=1}^n \frac{d \log f(\lambda, \xi_j)}{d\lambda} = 0$$

egyenlethez, illetve az

$$\sum_{j=1}^n \frac{\log f(\lambda_1, \dots, \lambda_k, \xi_j)}{\partial \lambda_j} = 0, \quad 1 \leq j \leq k,$$

egyenletrendszerhez vezet.

2. Megjegyzés: A maximum likelihood becslés módszer természetes módon megfogalmazható abban az esetben is, amikor a vizsgált eloszlásfüggvénycsalád eloszlásfüggvényeinek nincs sűrűségfüggvényük, hanem például rácsos eloszlásúak. Ebben az esetben, ha az eloszlások bizonyos m értékeket vehetnek fel $p_\lambda(m) = p(\lambda, m)$ vagy $p_{\lambda_1, \dots, \lambda_k}(m) = p(\lambda_1, \dots, \lambda_k, m)$ valószínűséggel, ($\sum_m p(\lambda, m) = 1$, illetve $\sum_m p(\lambda_1, \dots, \lambda_k, m) = 1$.) Megfigyelünk egymástól független $\xi_j = m_j$, $1 \leq j \leq n$, értékeket, és a maximum likelihood elv alapján a $\prod_{j=1}^n p(\lambda, m_j)$, illetve $\prod_{j=1}^n p(\lambda_1, \dots, \lambda_k, m_j)$ kifejezés maximumát adó $\hat{\lambda}$ illetve $\hat{\lambda}_j$, $1 \leq j \leq k$, értékek adják meg a maximum likelihood becslést.

Számítsuk ki, hogy milyen becslést sugall a maximum likelihood módszer a most vizsgált probléma esetében.

Jelen esetben a (ξ_1, \dots, ξ_n) vektor sűrűségfüggvénye a

$$\prod_{j=1}^n \lambda e^{-\lambda x_j} = \lambda^n \exp \left\{ -\lambda \sum_{k=1}^n x_j \right\}$$

függvény. Ennek logaritmus az $n \log \lambda - \lambda \sum_{k=1}^n x_j$ függvény. Ezért a maximum likelihood

módszer az $\frac{n}{\hat{\lambda}_n} = \sum_{j=1}^n \xi_j$ egyenlethez és a $\hat{\lambda}_n = \frac{n}{\sum_{j=1}^n \xi_j}$ becsléshez vezet. Jegyezzük meg,

hogy egy λ paraméterű exponenciális eloszlású valószínűségi változó várható értéke $\frac{1}{\lambda}$. Ezért a nagy számok törvénye azt adja, hogy $\hat{\lambda}_n \Rightarrow \lambda$.

Nézzük meg milyen becslést sugall a maximum likelihood módszer a korábban tárgyalt problémákban. Az első feladatban, amikor egy pénzdarab fej oldalára való eséseének a valószínűségét kell becsülnünk, jelöljük k -val a fejdobások (véletlen) számát n dobás esetén. Ekkor p paraméter esetén annak a valószínűsége, hogy pontosan k fejdobás következett be $P_p(k) = \binom{n}{k} p^k (1-p)^{n-k}$, ennek logaritmus pedig $\log P_p(k) = \text{const.} (k \log p + (n-k) \log(1-p))$, ahol a const. függhet a k számtól, de nem függ az ismeretlen p paramétertől. Ezért a maximum likelihood módszer által sugallt a p paraméter szerinti deriválás a $\frac{k}{\hat{p}_n} - \frac{n-k}{1-\hat{p}_n} = 0$ egyenlethez, és a $\hat{p}_n = \frac{k}{n}$ becsléshez vezet. Ez az eredetileg megadott becslés.

A második feladatban hasonló a helyzet. Annak a valószínűsége, hogy k_j j -es dobás következik be n kísérletben, $1 \leq j \leq 6$, $k_1 + \dots + k_6 = n$, p_j , $1 \leq j \leq 6$ esetében

$$P_{p_1, \dots, p_6} = \frac{n!}{k_1! \dots k_6!} p_1^{k_1} \dots p_6^{k_6} = \frac{n!}{k_1! \dots k_6!} p_1^{k_1} \dots p_5^{k_5} (1 - p_1 - \dots - p_5)^{k_6}.$$

E kifejezésben logaritmust véve, majd az így kapott kifejezésnek véve a parciális deriváltját a p_1, \dots, p_5 változók szerint kapjuk a

$$\frac{k_j}{\hat{p}_{j,n}} = \frac{k_6}{1 - \hat{p}_{1,n} - \dots - \hat{p}_{5,n}}, \quad 1 \leq j \leq 5,$$

egyenleteket. Ezeket az egyenleteket összehasonlítva (és felhasználva, hogy az egyenletek jobb oldala nem függ a j indextől) kapjuk, hogy $\frac{\hat{p}_{j,n}}{\hat{p}_{s,n}} = \frac{k_j}{k_s}$ minden $1 \leq j, s \leq 6$ számra, azaz $C\hat{p}_{j,n} = k_j$, $1 \leq j \leq 5$, valamilyen ismeretlen C konstanssal. Ezt beírva az egyenletekbe kapjuk, hogy $k_6 = C - (k_1 + \dots + k_5)$, ahonnan mivel $\sum_{j=1}^6 k_j = n$, $C = n$, és $\hat{p}_{j,n} = \frac{k_j}{n}$. Azaz a maximum likelihood módszer ebben az esetben is az eredetileg javasolt becslést adja. Megjegyezzük, hogy a fenti szélsőérték feladatot egyszerűbben kiszámíthattuk volna a feltételes szélsőérték kiszámítására kidolgozott Lagrange féle multiplikátor módszerrel.

A harmadik feladatban a (ξ_1, \dots, ξ_n) véletlen vektor sűrűségfüggvénye 1, ha mindegyik (ξ_1, \dots, ξ_n) pont a $[\vartheta, \vartheta + 1]$ intervallum belsejében van, azaz $\vartheta \leq \xi_1^* < \xi_n^* \leq \vartheta + 1$, egyébként pedig zéró. Ezért a vizsgálandó függvénynek nincs szigorú maximuma. Viszont szimmetriaokokból természetes azt a becslést tekinteni, melyre a $[\hat{\vartheta}_n, \hat{\vartheta}_n + 1]$ intervallum a $[\xi_1^*, \xi_n^*]$ intervallumot középen tartalmazza, és ez a tekintett $\hat{\vartheta}_n = \frac{\xi_1^* + \xi_n^*}{2} - \frac{1}{2}$ becslés.

5. Tekintsük a következő feladatot. Megfigyelünk ξ_1, \dots, ξ_n független, azonos eloszlású valószínűségi változókat ismeretlen $F(x)$ eloszlásfüggvénnyel. Becsüljük meg:

- a. Az ismeretlen $F(x)$ eloszlásfüggvényt,
- b. A ξ_j valószínűségi változók várható értékét,
- c. A ξ_j valószínűségi szórásnégyzetét.

Ezek a feladatok tipikus példái az úgynevezett nem parametrikus becslélméletnek. Ugyanis nem lehet az összes lehetséges eloszlásfüggvényt természetes módon véges sok paraméterrel paraméterezni.

a. Az a.) esetben, az $F(x)$ eloszlásfüggvény becslése esetén természetes becslés az úgynevezett empirikus eloszlásfüggvény, azaz

$$F_n(x) = F_n(x, \xi_1, \dots, \xi_n) = \frac{\text{Azon } 1 \leq k \leq n \text{ indexek száma, melyekre } \xi_k < x}{n},$$

$$-\infty < x < \infty.$$

Be lehet látni, hogy $\sup_{-\infty < x < \infty} |F_n(x) - F(x)| \Rightarrow 0$, ha $n \rightarrow \infty$ minden F eloszlásfüggvény esetén. Ez az órán is tárgyalt eredmény azt a tényt fejezi ki, hogy az empirikus eloszlásfüggvény valóban jó becslése az eloszlásfüggvénynek.

- b. A várható érték természetes becslése $M_n = M_n(\xi_1, \dots, \xi_n) = \frac{1}{n} \sum_{k=1}^n \xi_k$. Nem nehéz belátni, hogy $EM_n(\xi_1, \dots, \xi_n) = E\xi_1$. Továbbá, a nagy számok törvénye alapján $M_n(\xi_1, \dots, \xi_n) \Rightarrow E\xi_1$, ahol \Rightarrow sztochasztikus konvergenciát jelöl.
- c. A Szórásnégyzet szokásos becslése a következő becslés: $D_n^2 = D_n^2(\xi_1, \dots, \xi_n) = \frac{1}{n-1} \sum_{k=1}^n (\xi_k - M_n)^2$, ahol az $M_n = M_n(\xi_1, \dots, \xi_n)$ számot az előzőekben definiáltuk. Talán meglepő, hogy ebben a képletben $n-1$ -gyel osztottunk és nem n -nel. Ennek egyébként nagy n mintaelemszám esetén kicsi a jelentősége. Ennek oka az, hogy mint azt némi (nem nehéz) számolás mutatja, ezzel a választással $ED_n^2(\xi_1, \dots, \xi_n) = \text{Var} \xi_1$. Némi további számolás azt is mutatja, hogy $\lim_{n \rightarrow \infty} \text{Var} D_n^2(\xi_1, \dots, \xi_n) = 0$. Ezekből az eredményekből, illetve a Csebisev egyenlőtlenségből kapjuk, hogy $D_n^2(\xi_1, \dots, \xi_n) \Rightarrow \text{Var} \xi_1$, ahol \Rightarrow sztochasztikus konvergenciát jelöl.

Végül megfogalmazzunk néhány fontos fogalmat, elvet, melyek fontosak a becslélelemben.

Legyen adva $F_\lambda(x)$, valószínűségi eloszlások egy családja, és adott n -re ξ_1, \dots, ξ_n független, egyforma eloszlású valószínűségi változók sorozata, F_λ eloszlással, ahol λ ismeretlen paraméter. Azt mondjuk, hogy egy n -változós $T(x_1, \dots, x_n) = T_n(x_1, \dots, x_n)$ függvény becslést ad az ismeretlen λ paraméterre, ha az ismeretlen λ paramétert a $\hat{\lambda}_n = \hat{\lambda}_n(\xi_1, \dots, \xi_n) = T_n(\xi_1, \dots, \xi_n)$ valószínűségi változó segítségével becsljük meg. A $\hat{\lambda}_n$, illetve e valószínűségi változó függvényeinek eloszlása függ az F_λ eloszlástól, ezért a λ paramétertől. Ezt jelölendő, a továbbiakban P_λ -val fogjuk jelölni azokat a valószínűségeket, melyek az $F_\lambda(\cdot)$ eloszlású ξ_1, \dots, ξ_n valószínűségi változóktól függ.

Becslések konzisztenciája. Az előbb bevezetett jelöléseket használva azt mondjuk, hogy a $T_n(x_1, \dots, x_n)$, $n = 1, 2, \dots$, becselőfüggvények konzisztens becslést adnak, ha

$$\hat{\lambda}_n = T_n(\xi_1, \dots, \xi_n) \Rightarrow \lambda \quad \text{minden } \lambda \text{ paraméterre,}$$

ahol \Rightarrow sztochasztikus konvergenciát jelöl, azaz $\lim_{n \rightarrow \infty} P_\lambda \left(|\hat{\lambda}_n - \lambda| > \varepsilon \right) = 0$ minden lehetséges λ paraméterre és $\varepsilon > 0$ számra.

Becslés torzítatlanságának definíciója. Az előbb bevezetett jelöléseket használva azt mondjuk, hogy a $\hat{\lambda}_n = \hat{\lambda}_n(\xi_1, \dots, \xi_n) = T_n(x_1, \dots, x_n)$ becslés torzítatlan, ha

$$E_\lambda \hat{\lambda}_n(\xi_1, \dots, \xi_n) = \lambda \quad \text{minden } \lambda \text{ paraméterre.}$$

A $\hat{\lambda}_n = \hat{\lambda}_n(\xi_1, \dots, \xi_n) = T_n(x_1, \dots, x_n)$ becsléssorozat, $n = 1, 2, \dots$, aszimptotikusan torzítatlan, ha

$$\lim_{n \rightarrow \infty} E_\lambda \hat{\lambda}_n(\xi_1, \dots, \xi_n) = \lambda \quad \text{minden } \lambda \text{ paraméterre.}$$

A becslélméletben gyakran keresnek olyan torzítatlan $\hat{\lambda}_n = \hat{\lambda}_n(\xi_1, \dots, \xi_n)$ becslést, melyre a $D_n(\lambda) = \text{Var}_\lambda \hat{\lambda}_n(\xi_1, \dots, \xi_n)$ szórásnégyzet minél kisebb. Azt mondjuk, hogy egy torzítatlan $\hat{\lambda}_n$ becslés optimális, ha $\text{Var}_\lambda \hat{\lambda}_n(\xi_1, \dots, \xi_n) \leq \text{Var}_\lambda \tilde{\lambda}_n(\xi_1, \dots, \xi_n)$ minden torzítatlan $\tilde{\lambda}_n(\xi_1, \dots, \xi_n)$ becslésre és λ paraméterre. Sok érdekes esetben van torzítatlan optimális becslés. Jegyezzük meg, hogy a Csebisev egyenlőtlenség alapján, ha egy $\hat{\lambda}_n = \hat{\lambda}_n(\xi_1, \dots, \xi_n)$, $n = 1, 2, \dots$, becsléssorozat aszimptotikusan torzítatlan, és $\lim_{n \rightarrow \infty} \text{Var}_\lambda \hat{\lambda}_n(\xi_1, \dots, \xi_n) = 0$ minden λ paraméterre, akkor ez a becslés konzisztens. (Miért?) A maximum likelihood becslés nagyon általános feltételek mellett teljesíti ezeket a tulajdonságokat.