

Proposition 1 (Jensen-egyenlőtlenség) Ha $f : \mathbb{R} \rightarrow \mathbb{R}$ konvex, akkor tetszőleges ξ változóra

$$f(\mathbf{M}(\xi)) \leq \mathbf{M}(f(\xi))$$

feltéve, hogy az egyenlőtlenségben szereplő véges vagy végtelen várható értékek léteznek.

Bizonyítás: Megjegyezzük, hogy konvex függvényekre mindig létezik a $\pm\infty$ -ben vett, esetlegesen végtelen értékű, határérték, így ha az $\mathbf{M}(\xi)$ létezik, akkor a bal oldali kifejezés értelmes.

1. Tegyük fel először, hogy az $\mathbf{M}(\xi)$ és az $f(\mathbf{M}(\xi))$ véges. Tekintsünk egy az

$$(\mathbf{M}(\xi), f(\mathbf{M}(\xi)))$$

ponton átmenő olyan $ax + b$ alakú egyenest, hogy minden x számra

$$f(x) \geq a \cdot x + b.$$

Az f függvény konvexitása miatt ilyen egyenes biztosan van¹. De ekkor az alapul vett Ω valószínűségi mező minden $\omega \in \Omega$ kimenetelére

$$f(\xi(\omega)) \geq a \cdot \xi(\omega) + b.$$

Mindkét oldalt integrálva, az $ax + b$ egyenes választása alapján

$$\mathbf{M}(f(\xi)) \geq a \cdot \mathbf{M}(\xi) + b \cdot \mathbf{M}(1) = f(\mathbf{M}(\xi)).$$

2. Ha $\mathbf{M}(f(\xi)) = \infty$, az állítás evidens.

3. Tegyük fel, hogy $\mathbf{M}(\xi) = \infty$. Ha létezik t , hogy $f'_-(t) > 0$, akkor a konvexitásból következő

$$f(\xi) \geq f(t) + f'_-(t) \cdot (\xi - t)$$

egyenlőtlenséget integrálva és kihasználva, hogy az integrálok léteznek

$$\mathbf{M}(f(\xi)) \geq f(t) + f'_-(t) \cdot (\mathbf{M}(\xi) - t) = \infty,$$

tehát az egyenlőtlenség teljesül. Ha minden t -re $f'_-(t) \leq 0$, akkor az f monoton csökken, vagyis $f(\infty) \leq f(\xi)$ és ezért

$$\mathbf{M}(f(\xi)) \geq f(\infty) = f(\mathbf{M}(\xi)).$$

4. Az $\mathbf{M}(\xi) = -\infty$, analóg, csak az $f'_-(t) < 0$ esetből kell kiindulni.

5. Végezetül ha $\mathbf{M}(f(\xi)) = -\infty$, és van olyan t , amelyre $f'_-(t) > 0$, akkor az imént említett módon $\mathbf{M}(\xi) = -\infty$, és az egyenlőtlenség a már bemutatott indokolható. Ha $f'_- \leq 0$, és van olyan t , hogy $f'_-(t) < 0$, akkor egyrészt az

¹Ha f deriválható, akkor a deriváltja éppen ilyen, ha nem akkor a konvexitás miatt létező f'_+ jobb, illetve f'_- bal oldali deriváltak, illetve a köztük haladó bármely másik egyenes megfelelő.

f csökken, másrészt a már korábban elmondottak miatt $\mathbf{M}(\xi) = \infty$, vagyis $f(\mathbf{M}(\xi)) \leq f(\xi)$. Ha $f'_- = 0$, akkor az f véges konstans, és az $\mathbf{M}(f(\xi)) = -\infty$ nem teljesülhet. □

Az egyenlőtlenségben explicite feltettük, hogy az $\mathbf{M}(\xi)$ és az $\mathbf{M}(f(\xi))$ várható értékek léteznek. Éppen ezért nem érdektelen a következő észrevétel:

Proposition 2 *Ha $f : \mathbb{R} \rightarrow \mathbb{R}$ konvex és az $\mathbf{M}(\xi)$ várható érték véges, akkor*

$$\mathbf{M}(f^-(\xi)) < \infty,$$

következésképpen az $\mathbf{M}(f(\xi))$ véges vagy végtelen várható érték létezik.

Bizonyítás: A konvexitás miatt ismételten

$$f(t) \geq f(0) + f'_-(0) \cdot t,$$

amiből

$$-f(t) \leq -f(0) - f'_-(0) \cdot t,$$

következésképpen

$$f^-(t) \stackrel{\circ}{=} \max(-f(t), 0) \leq |f(0)| + |f'_-(0)| \cdot |t|,$$

vagyis

$$\mathbf{M}(f^-(\xi)) \leq |f(0)| + |f'_-(0)| \cdot \mathbf{M}(|\xi|) < \infty. \quad \square$$

Example 3 *A maximum likelihood elv indoklása.*

Legyen μ tetszőleges mérték és legyenek p és q a μ mérték szerinti sűrűségfüggvények². A logaritmus függvény konkáv, így a Jensen-egyenlőtlenség szerint

$$\begin{aligned} \int_{\Omega} p \cdot (\ln q - \ln p) d\mu &= \int_{\Omega} p \cdot \ln \frac{q}{p} d\mu = \mathbf{M} \left(\ln \frac{q}{p} \right) \leq \ln \left(\mathbf{M} \left(\frac{q}{p} \right) \right) = \\ &= \ln \left(\int_{\Omega} p \cdot \frac{q}{p} d\mu \right) = \ln \left(\int_{\Omega} q d\mu \right) = \ln 1 = 0. \end{aligned}$$

Ebből következően

$$\int_{\Omega} p \cdot \ln q d\mu \leq \int_{\Omega} p \cdot \ln p d\mu, \quad (1)$$

feltéve, hogy mind a két oldal véges. Az egyenlőtlenség alkalmazásaként tegyük fel, hogy a $\xi_1, \xi_2, \dots, \xi_n$ változók azonos eloszlásúak, és a közös sűrűségfüggvényük

²A μ lehet például a számláló mérték. Ilyenkor a diszkrét eloszlásokat kezeljük és az integrálok egyszerű összegek.

legyen $f(x, \theta)$, ahol θ egy ismeretlen paraméter amely értékét a $(\xi_k)_{k=1}^n$ változók megfigyelése alapján próbáljuk megbecsülni. Képezzük az

$$L(\xi_1, \dots, \xi_n, \theta) \doteq \prod_{k=1}^n f(\xi_k, \theta)$$

likelihood függvényt. Ha a ξ_k változók függetlenek, akkor a nagy számok törvénye alapján

$$\frac{\ln L(\xi_1, \dots, \xi_n, \theta)}{n} = \frac{\sum_{k=1}^n \ln f(\xi_k, \theta)}{n} \rightarrow \mathbf{M}(\ln f(\xi, \theta)),$$

ahol ξ tetszőleges olyan változó, amely eloszlása megegyezik a ξ_k változók közös eloszlásával³. Ha θ_0 a θ paraméter valódi értéke, akkor a transzformált valószínűségi változók várható értékére vonatkozó formula alapján

$$\mathbf{M}(\ln f(\xi, \theta)) \doteq \int_{\Omega} \ln f(\xi, \theta) d\mathbf{P} = \int_{\Omega} \ln f(x, \theta) f(x, \theta_0) d\mu(x).$$

Az (1) alapján

$$\begin{aligned} \mathbf{M}(\ln f(x, \theta)) &= \int_{\Omega} \ln f(x, \theta) f(x, \theta_0) d\mu(x) \leq \\ &\leq \int_{\Omega} \ln f(x, \theta_0) f(x, \theta_0) d\mu(x) \leq \mathbf{M}(\ln f(x, \theta_0)). \end{aligned}$$

Ebből következően a θ_0 ismeretlen paraméter $\hat{\theta}$ becslését úgy célszerű meghatározni, hogy maximalizáljuk a várható értéket közelítő

$$\frac{\ln L(\xi_1, \dots, \xi_n, \theta)}{n}$$

átlag értékét a θ paraméter szerint. Ez ekvivalens avval, hogy adott n esetén a θ paraméter szerint maximalizáljuk az L likelihood függvényt. \square

Mekkora a becslés hibája, vagyis mekkora a $\hat{\theta} - \theta_0$ eltérés? Tekintsük az $\ln L$ függvény Taylor-kifejtését a θ_0 helyes érték körül:

$$\ln L(\theta) = \ln L(\theta_0) + \frac{d \ln L}{d\theta}(\theta_0)(\theta - \theta_0) + \frac{1}{2} \frac{d^2 \ln L}{d\theta^2}(\theta_0)(\theta - \theta_0)^2 + R_3(\theta - \theta_0)^3.$$

A kifejtést mint polinomot θ szerint deriválva, felhasználva, hogy az első tag konstans

$$\frac{d}{d\theta} \ln L(\theta) = \frac{d \ln L}{d\theta}(\theta_0) + \frac{d^2 \ln L}{d\theta^2}(\theta_0)(\theta - \theta_0) + 3R_3(\theta - \theta_0)^2.$$

³Feltéve persze, hogy a várható érték létezik.

A θ helyébe a $\hat{\theta}$ becslést behelyettesítve és a T_3 új jelölést bevezetve

$$\frac{d}{d\theta} \ln L(\hat{\theta}) = \frac{d \ln L}{d\theta}(\theta_0) + \frac{d^2 \ln L}{d\theta^2}(\theta_0) (\hat{\theta} - \theta_0) + T_3 (\hat{\theta} - \theta_0)^2.$$

A $\hat{\theta}$ értékét a maximálással becsültük, a maximumban a derivált nulla, így a jobb oldalon $\frac{d}{d\theta} \ln L(\hat{\theta}) = 0$, vagyis

$$0 = \frac{d \ln L}{d\theta}(\theta_0) + \frac{d^2 \ln L}{d\theta^2}(\theta_0) (\hat{\theta} - \theta_0) + T_3 (\hat{\theta} - \theta_0)^2.$$

Ebből elemi átrendezéssel

$$(\hat{\theta} - \theta_0) = - \left(\frac{d \ln L}{d\theta}(\theta_0) + T_3 (\hat{\theta} - \theta_0)^2 \right) \left(\frac{d^2 \ln L}{d\theta^2}(\theta_0) \right)^{-1}.$$

A két oldalt \sqrt{n} -bel beszorozva

$$\begin{aligned} \sqrt{n} (\hat{\theta} - \theta_0) &= - \frac{n}{\sqrt{n}} \left(\frac{d \ln L}{d\theta}(\theta_0) + T_3 (\hat{\theta} - \theta_0)^2 \right) \left(\frac{d^2 \ln L}{d\theta^2}(\theta_0) \right)^{-1} = \\ &= - \left(\frac{\frac{d \ln L}{d\theta}(\theta_0) + T_3 (\hat{\theta} - \theta_0)^2}{\sqrt{n}} \right) \left(\frac{\frac{d^2 \ln L}{d\theta^2}(\theta_0)}{n} \right)^{-1}. \end{aligned}$$

Vizsgáljuk meg az egyes kifejezések határértékét!

1.

$$\frac{\frac{d \ln L}{d\theta}(\theta_0)}{\sqrt{n}} = \frac{\sum_{k=1}^n \frac{d}{d\theta} \ln f(\xi_k, \theta_0)}{\sqrt{n}}.$$

A centrális határeloszlás tételét akarjuk használni, de ehhez szükségünk van az összeadandók várható értékre és szórására. Számoljuk ki az

$$\eta_k \doteq \frac{d}{d\theta} \ln f(\xi_k, \theta_0)$$

változók közös várható értékét.

$$\begin{aligned} \mathbf{M} \left(\frac{d}{d\theta} \ln f(\xi_k, \theta_0) \right) &= \mathbf{M} \left(\frac{1}{f(\xi_k, \theta_0)} \frac{d}{d\theta} f(\xi_k, \theta_0) \right) = \\ &= \int_{\mathbb{R}} \frac{1}{f(x, \theta_0)} \frac{d}{d\theta} f(x, \theta_0) f(x, \theta_0) d\mu = \\ &= \int_{\mathbb{R}} \frac{d}{d\theta} f(x, \theta_0) d\mu = \\ &= \frac{d}{d\theta} \int_{\mathbb{R}} f(x, \theta) d\mu = \\ &= \frac{d}{d\theta} 1 = 0. \end{aligned}$$

Vegyük észre, hogy a számolás során kihasználtuk, hogy θ_0 a paraméter helyes értéke, így az \mathbf{M} várható érték az $f(x, \theta_0)$ szerinti integrálással számolható. Ugyancsak felhasználtuk, hogy a deriválás és az integrálás felcserélhető, amely nyilván általában nem teljesül. Ez megszorítást jelent a számba jöhető $f(x, \theta)$ párokra és nyilván a konkrét alkalmazásokban ellenőrizni kell ezt a regularitási tulajdonságot. Számoljuk ki az η_k változók közös szórását. Mivel a várható érték nulla elég kiszámolni a második momentumot. Egyrészt a már felhasznált regularitási szabály alapján

$$\begin{aligned} \frac{d}{d\theta} \int_{\mathbb{R}} \frac{d}{d\theta} \ln f(x, \theta) f(x, \theta) d\mu &= \frac{d}{d\theta} \int_{\mathbb{R}} \left(\frac{1}{f(x, \theta)} \frac{d}{d\theta} f(x, \theta) \right) f(x, \theta) d\mu = \\ &= \frac{d}{d\theta} \int_{\mathbb{R}} \frac{d}{d\theta} f(x, \theta) \frac{1}{f(x, \theta)} f(x, \theta) d\mu = \\ &= \frac{d}{d\theta} \int_{\mathbb{R}} \frac{d}{d\theta} f(x, \theta) d\mu = \\ &= \frac{d^2}{d\theta^2} \int_{\mathbb{R}} f(x, \theta) d\mu = \frac{d^2}{d\theta^2} 1 = 0. \end{aligned}$$

Az integrálba bederiválva a szorzat deriválási szabálya szerint ugyanez

$$\begin{aligned} 0 &= \frac{d}{d\theta} \int_{\mathbb{R}} \frac{d}{d\theta} \ln f(x, \theta) f(x, \theta) d\mu = \\ &= \int_{\mathbb{R}} \frac{d}{d\theta} \left(\frac{d}{d\theta} \ln f(x, \theta) f(x, \theta) \right) d\mu = \\ &= \int_{\mathbb{R}} \frac{d^2}{d\theta^2} \ln f(x, \theta) f(x, \theta) d\mu + \\ &\quad + \int_{\mathbb{R}} \frac{d}{d\theta} \ln f(x, \theta) \frac{d}{d\theta} f(x, \theta) d\mu. \end{aligned}$$

Ahol ismételten többször kihasználtuk, hogy az $f(x, \theta)$ kifejezés elég jó ahhoz, hogy a deriválás és az integrálás felcserélhető. Ebből a már többször használt

$$\frac{d}{d\theta} f(x, \theta) = \frac{d}{d\theta} \ln f(x, \theta) f(x, \theta)$$

azonosság szerint⁴

$$\begin{aligned} \int_{\mathbb{R}} \frac{d^2}{d\theta^2} \ln f(x, \theta) f(x, \theta) d\mu &= - \int_{\mathbb{R}} \frac{d}{d\theta} \ln f(x, \theta) \frac{d}{d\theta} f(x, \theta) d\mu = \\ &= - \int_{\mathbb{R}} \frac{d}{d\theta} \ln f(x, \theta) \frac{d}{d\theta} \ln f(x, \theta) f(x, \theta) d\mu = \\ &= - \int_{\mathbb{R}} \left(\frac{d}{d\theta} \ln f(x, \theta) \right)^2 f(x, \theta) d\mu. \end{aligned}$$

⁴Ugyanis az összeg nulla.

Ha most $\theta \doteq \theta_0$, akkor az $f(x, \theta_0)$ a valódi sűrűségfüggvény, így az integrálok a transzformált változók várható értékét adják:

$$\mathbf{M} \left(\left(\frac{d}{d\theta} \ln f(x, \theta_0) \right)^2 \right) = -\mathbf{M} \left(\frac{d^2}{d\theta^2} \ln f(x, \theta_0) \right),$$

vagyis

$$\begin{aligned} \mathbf{D}^2 \left(\frac{d}{d\theta} \ln f(\xi_k, \theta_0) \right) &\doteq \mathbf{D}^2(\eta_k) = \mathbf{M}(\eta^2) = \\ &= \mathbf{M} \left(\left(\frac{d}{d\theta} \ln f(x, \theta_0) \right)^2 \right) = \\ &= -\mathbf{M} \left(\frac{d^2}{d\theta^2} \ln f(\xi_k, \theta_0) \right) \doteq \varphi. \end{aligned}$$

Ebből a centrális határeloszlás tétele szerint

$$\begin{aligned} \lim_{n \rightarrow \infty} \frac{\frac{d \ln L}{d\theta}(\theta_0)}{\sqrt{n}} &= \lim_{n \rightarrow \infty} \frac{\sum_{k=1}^n \frac{d}{d\theta} \ln f(\xi_k, \theta_0)}{\sqrt{n}} = \\ &= \lim_{n \rightarrow \infty} \frac{\sum_{k=1}^n (\eta_k - \mathbf{M}(\eta_k))}{\sqrt{n}} = N(0, \mathbf{D}(\eta)) = \\ &= N(0, \sqrt{\varphi}). \end{aligned}$$

2. Ugyanakkor a nagy számok törvénye szerint

$$\begin{aligned} \lim_{n \rightarrow \infty} \frac{\frac{d^2 \ln L}{d\theta^2}(\theta_0)}{n} &= \lim_{n \rightarrow \infty} \frac{\sum_{k=1}^n \frac{d^2 \ln f(\xi_k, \theta)}{d\theta^2}(\theta_0)}{n} = \\ &= \mathbf{M} \left(\frac{d^2}{d\theta^2} \ln f(\xi, \theta_0) \right) = -\varphi. \end{aligned}$$

3. Tegyük fel, hogy a becslés "elég aszimptotikusan konzisztens", vagyis a Taylor-közelítés maradékjára

$$\lim_{n \rightarrow \infty} \frac{T_3(\hat{\theta}_n - \theta_0)^2}{\sqrt{n}}.$$

Ez teljesül például akkor, ha a harmadik derivált a becslés környezetében korlátos és a paraméterter, vagyis a θ lehetséges értékei halmaza például szintén korlátos. De számos más egyéb a konkrét helyzetben ellenőrizendő feltétel esetén teljesül.

Ilyenkor eloszlásban

$$\lim_{n \rightarrow \infty} \sqrt{n}(\hat{\theta} - \theta_0) = -N(0, \sqrt{\varphi})(-\varphi^{-1}) = N(0, \sqrt{\varphi^{-1}}).$$

Emlékeztetünk, hogy

$$\varphi \doteq -\mathbf{M} \left(\frac{d^2}{d\theta^2} \ln f(\xi_k, \theta_0) \right)$$

A nagy számok törvénye szerint

$$\begin{aligned} \mathbf{M} \left(\frac{d^2}{d\theta^2} \ln f(\xi_k, \theta_0) \right) &\approx \frac{\sum_{k=1}^n \frac{d^2}{d\theta^2} \ln f(\xi_k, \theta_0)}{n} \approx \\ &\approx \frac{\sum_{k=1}^n \frac{d^2}{d\theta^2} \ln f(\xi_k, \hat{\theta})}{n}. \end{aligned}$$