



A412

A4 Valószínűségszámítás — XII. EA

dr. Keszthelyi Gabriella
Sztochasztika és Dinamikai rendszerek tanszék

2021. december 2.

dr. Keszthelyi Gabriella A4 Valószínűségszámítás

Momentumgeneráló függvény (ismétlés)

$$M_X(s) = E(e^{sX}) = \mathcal{L}\{f\}(-s) = \int_{-\infty}^{\infty} f(x)e^{sx} dx$$

A momentumgeneráló függvény

- egy várható érték s függvényében,
- Laplace transzformáltja a sűrűségfüggvény előjelcserélt változatának,
- és a sűrűségfüggvény/súlyfüggvény kölcsönösen meghatározzák egymást.

dr. Keszthelyi Gabriella A4 Valószínűségszámítás

Gamma/Erlang momentumgeneráló függvénye

Gamma sűrűségfüggvénye:

$$f(x) = \frac{\lambda(\lambda x)^{p-1}}{\Gamma(p)} e^{-\lambda x}$$

Erlang sűrűségfüggvénye ($p = n$):

$$f(x) = \frac{\lambda(\lambda x)^{n-1}}{(n-1)!} e^{-\lambda x}$$

Momentumgeneráló:

$$\begin{aligned} M_X(s) &= \frac{\lambda^n}{(n-1)!} \int_0^\infty e^{sx} e^{-\lambda x} x^{n-1} dx = \\ &= \left(\frac{\lambda}{\lambda-s} \right)^n \left[\frac{1}{(n-1)!} \int_0^\infty e^{-(\lambda-s)x} x^{n-1} (\lambda-s)^n dx \right] \\ &= \left(\frac{\lambda}{\lambda-s} \right)^n \end{aligned}$$

Gamma/Erlang momentumgeneráló függvénye

$$M'_X(s) = \frac{n\lambda^n}{(\lambda-s)^{n+1}}$$

$$M''_X(s) = \frac{n(n+1)\lambda^n}{(\lambda-s)^{n+2}}$$

Tehát

$$E(X) = M'_X(0) = \frac{n}{\lambda}$$

$$\begin{aligned} D^2(X) &= E(X^2) - (E(X))^2 = M''_X(0) - \left(\frac{n}{\lambda}\right)^2 = \\ &= \frac{n(n+1)}{(\lambda)^2} - \frac{n^2}{(\lambda)^2} = \frac{n}{(\lambda)^2} \end{aligned}$$

χ^2 -eloszlás

Legyenek Z_1, Z_2, \dots, Z_n független, standard normál eloszlású változók. Ekkor $X = Z_1^2 + Z_2^2 + \dots + Z_n^2$ -t χ^2 -eloszlásnak hívjuk n szabadsági fokkal.

Jelölés: $X \sim \chi_n^2$

Kiejtés: 'Kí-négyzet'

A χ^2 eloszlás tartja a konvolúciót, azaz $X_1 \sim \chi_{n_1}^2$ és $X_2 \sim \chi_{n_2}^2$, akkor $W = X_1 + X_2 \sim \chi_{n_1+n_2}^2$.


Példa

Tegyük fel, hogy egy tárgyat akarunk lokalizálni a 3D térben, és a 3 koordináta mérési hibái független normális változók 0 várható értékkel és 2 szórással. Mi a vszsége, hogy az objektum és az általunk becsült hely távolsága több, mint 3 méter?

Példa

Jelöljük W -vel a távolságot. Ekkor $W^2 = X_1^2 + X_2^2 + X_3^2$ ahol X_i az i . koordináta hibája. Legyen Z_i a standardizált változata, azaz $Z_i = X_i/2$.

$$P(W^2 > 9) = P(Z_1^2 + Z_2^2 + Z_3^2 > 9/4) = P(\chi_3^2 > 9/4) = \underline{0.52216}$$



χ_3^2 sűrűsége

χ^2 momentumgeneráló függvénye

$n = 1$ esetén

$$\begin{aligned} E(e^{sX}) &= E(e^{sZ^2}) = \int_{-\infty}^{\infty} e^{sX^2} f_Z(x) dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{sX^2} e^{-x^2/2} dx = \\ &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-x^2(1-2s)/2} dx \\ &= (1-2s)^{-1/2} \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-x^2/2\sigma^2} dx = \\ &= \boxed{(1-2s)^{-1/2}} \end{aligned}$$

STANDARD NORMALIS eloszlés értéke = 1

általános n -re

$$E(e^{sX}) = E(e^{s\sum_{i=1}^n Z_i^2}) = E\left(\prod_{i=1}^n e^{sZ_i^2}\right) = \underline{\underline{(1-2s)^{-n/2}}}$$

$$(1-2s)^{-n/2}$$

vs.

$$\left(\frac{\lambda}{\lambda-t}\right)^n$$

Ez a kettő megegyezik ha $\lambda = 1/2$ és $n = n/2$. Azaz a χ^2 n szabadságfokkal és a Gamma/Erlang $n/2$ és $1/2$ paraméterrel egybeesik.

Mire használjuk a χ^2 -eloszlást?

A χ^2 -et ritkán használjuk közvetlenül modellezésre, inkább hipotézis-vizsgálat kapcsán merül fel. A χ^2 -próba arra jó, hogy egy adatsorról eldöntsük, hogy egy általunk gyanított eloszlásra mennyire jól illeszkedik.

Student-féle T -eloszlás


Legyen Z standard normális és χ_n^2 független valószínűségi változók. Ekkor az n szabadságfokú T -eloszlás a következőképp van definiálva:

$$T_n = \frac{Z}{\sqrt{\chi_n^2/n}}$$

T -eloszlást akkor használunk, amikor gyanús, hogy normális eloszlású a minta (harang alakú a sűrűség), de kis mintával dolgozunk és a szórás ismeretlen.

A T -eloszlás szabadságfoka (n) nem más, mint a minta elemszáma mínusz 1. A szabadságfok növelésével a Student-eloszlás tart a Standard Normálhoz (30 fölött már egybeesnek).

Student-féle T -eloszlás



Student-féle T -eloszlás



William Sealy Gosset egy angol kémikus volt, aki a Guinness fő sörözőjé-ként szolgált, és a modern statisztika úttörője volt.

Ő publikálta **Student** álnéven a T -eloszlást.

$$E(T_n) = 0$$
$$D^2(T_n) = \frac{n}{n-2}$$

Paraméterbecslés

Legyen X valószínűségi változó, θ pedig a valószínűségi változó paramétere. Tegyük fel, hogy van egy n elemű mintánk (statisztikai minta)

$\mathbf{X}_n = (X_1, X_2, \dots, X_n)$. Ez n darab független kísérletet/megfigyelést jelent az X valószínűségi változóra nézve. A mintaelemek eloszlása megegyezik a valószínűségi változó eredeti eloszlásával.

Az X_n pontbecslése:

$$\hat{\theta}(\mathbf{X}_n) = g(X_1, X_2, \dots, X_n)$$

Ahol $X_1 = x_1, X_2 = x_2, \dots$ megfigyelések alapján meg tudjuk becsülni a θ paramétert.

Legegyszerűbb becslések

Legyen X várható értéke μ és szórása σ . $\hat{\theta}(X_n) = \bar{X}_n$ a mintaátlag.

$$E(\bar{X}_n) = \frac{1}{n} E\left(\sum_{j=1}^n X_j\right) = \mu$$

A \bar{X}_n szórása:

$$D^2(\bar{X}_n) = \frac{1}{n^2} D^2\left(\sum_{j=1}^n X_j\right) = \frac{\sigma^2}{n}$$

Egy becslést **torzítatlannak** nevezünk, ha

$$E(\hat{\theta}) = \theta$$

Ekkor tehát \bar{X}_n egy torzítatlan becslés μ -re.

A minta szórása

A tapasztalati szórásnégyzet

$$\hat{S}^2 = \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X}_n)^2$$

ahol \bar{X}_n még mindig a mintaátlag.

$$\begin{aligned}\hat{S}^2 &= \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X}_n)^2 = \frac{1}{n} \sum_{j=1}^n (X_j - \mu + \mu - \bar{X}_n)^2 \\ &= \frac{1}{n} \sum_{j=1}^n \{(X_j - \mu)^2 + 2(X_j - \mu)(\mu - \bar{X}_n) + (\mu - \bar{X}_n)^2\} \\ &= \frac{1}{n} \sum_{j=1}^n (X_j - \mu)^2 + \frac{2}{n}(\mu - \bar{X}_n) \sum_{j=1}^n (X_j - \mu) + \frac{1}{n} \sum_{j=1}^n (\mu - \bar{X}_n)^2 \\ &= \frac{1}{n} \sum_{j=1}^n (X_j - \mu)^2 + \frac{2}{n}(\mu - \bar{X}_n)(n\bar{X}_n - n\mu) + \frac{n(\mu - \bar{X}_n)^2}{n}\end{aligned}$$

$$\begin{aligned}
&= \frac{1}{n} \sum_{j=1}^n (X_j - \mu)^2 - \underbrace{2(\bar{X}_n - \mu)^2} + \underbrace{(\bar{X}_n - \mu)^2} \\
&= \frac{1}{n} \sum_{j=1}^n (X_j - \mu)^2 - (\bar{X}_n - \mu)^2.
\end{aligned}$$

$$\begin{aligned}
E[\hat{S}^2] &= E\left[\frac{1}{n} \sum_{j=1}^n (X_j - \mu)^2 - (\bar{X}_n - \mu)^2\right] \\
&= \frac{1}{n} \sum_{j=1}^n [E[(X_j - \mu)^2]] - E[(\bar{X}_n - \mu)^2] \\
&= \sigma^2 - \frac{\sigma^2}{n} = \frac{n-1}{n} \sigma^2 \neq \frac{\sigma^2}{n}
\end{aligned}$$

Tehát \hat{S}^2 torzított becslése a σ -nak.

Torzítatlan becslés szórásnégyzetre

A becslés torzítása

$$B(\hat{\theta}) = E(\hat{\theta}) - \theta$$

$$\frac{\sigma^2}{n} - \frac{n-1}{n} \sigma^2$$

Hogyan nyerhetünk ki egy torzítatlan becslést a szórásnégyzetre?

$$\hat{\sigma}^2 = \frac{1}{n-1} \sum_{j=1}^n (X_j - \bar{X}_n)^2$$

torzítatlan
becslés a szórásnégyzetre

Maximum Likelihood becslés (MAP)

Legyen $f(x_1, x_2, \dots, x_n | \theta)$ az együttes sűrűségfüggvénye X_1, X_2, \dots, X_n -nek. → ez egy likelihood

$f(x_1, x_2, \dots, x_n | \theta)$ egyfajta valószínűséget fejez ki, hogy az x_1, x_2, \dots, x_n értékek lesznek megfigyelve, amikor θ az igazi értéke a paraméternek.

$$\begin{cases} P(X_1, X_2, \dots, X_n | \theta), & \text{ha } X \text{ diszkrét,} \\ f(x_1, x_2, \dots, x_n | \theta), & \text{ha } X \text{ folytonos} \end{cases}$$

Mivel X_i -k függetlenek:

$$P(X_1, X_2, \dots, X_n | \theta) = P(X_1 | \theta) \cdot P(X_2 | \theta) \cdot \dots \cdot P(X_n | \theta) = \prod_{i=1}^n P(X_i | \theta)$$

$$f(x_1, x_2, \dots, x_n | \theta) = f(x_1 | \theta) \cdot f(x_2 | \theta) \cdot \dots \cdot f(x_n | \theta) = \prod_{i=1}^n f(x_i | \theta)$$

Log Likelihood

A Maximum Likelihood becslése $\hat{\theta}$ -nak, az a θ amely maximalizálja $f(x_1, x_2, \dots, x_n | \theta)$ -t.

$$l(x_1, x_2, \dots, x_n; \hat{\theta}) = \max_{\theta} l(x_1, x_2, \dots, x_n; \theta)$$

Néha érdekesebb a **log likelihood**dal dolgozni:

$$\begin{aligned} L(x_1, x_2, \dots, x_n; \theta) &= \log l(x_1, x_2, \dots, x_n; \theta) = \\ &= \begin{cases} \sum_{i=1}^n \log P(X_1, X_2, \dots, X_n | \theta), & \text{ha } X \text{ diszkrét,} \\ \sum_{i=1}^n \log f(x_1, x_2, \dots, x_n | \theta), & \text{ha } X \text{ folytonos} \end{cases} \end{aligned}$$

$$= \sum_{i=1}^n L(x_i; \theta)$$

Ahhoz, hogy maximalizáljuk $l(x_1, x_2, \dots, x_n; \theta)$ -t elég maximalizálni $L(x_1, x_2, \dots, x_n; \theta)$ -t:

$$\frac{\partial}{\partial \theta} L(x_1, x_2, \dots, x_n; \theta) = \frac{\partial}{\partial \theta} \log l(x_1, x_2, \dots, x_n; \theta) = 0$$

Példa

Legyenek X_i -k független $\text{Exp}(\lambda)$ valószínűségi változók, melyeknek nem ismerjük a várható értékét és így λ -t sem: ez lesz a paraméter amit becsülni szeretnénk.

$$f(x_1, x_2, \dots, x_n | \lambda) = \lambda e^{-x_1 \lambda} \lambda e^{-x_2 \lambda} \dots \lambda e^{-x_n \lambda} = \lambda^n e^{-\sum_{i=1}^n x_i \lambda}$$

$$\log(\lambda^n e^{-\sum_{i=1}^n x_i \lambda})$$

$$L(x_1, x_2, \dots, x_n; \lambda) = \sum_{i=1}^n (\log(\lambda) - x_i \lambda)$$

Loglikelihood

$$\frac{\partial}{\partial \lambda} L(x_1, x_2, \dots, x_n; \lambda) = \frac{n}{\lambda} - \sum_{i=1}^n x_i$$

$$\lambda = \frac{n}{\sum_{i=1}^n X_i} \quad \frac{1}{\bar{X}}$$

Azaz λ -ra kijött, hogy a mintaátlag reciproka.

Poisson becslése

Példa

A Géza által benyújtott dolgozatban a hibák száma Poisson eloszlású 1 hiba/oldal várható értékkel, míg Béla által írt dolgozatban átlagosan 5 hiba található oldalanként. A beküldött dolgozat egy oldalán 2 hiba található, mi a valószínűbb, melyikük írta?

$$\theta = \lambda$$

$$P(X = 2 | \lambda = 1) = \frac{1^2}{2!} e^{-1} = 0,1839$$

$$P(X = 2 | \lambda = 5) = \frac{5^2}{2!} e^{-5} = 0,0842$$

Poisson becslése 2.

$$P(X = k_j | \theta) = \frac{\theta^{k_j}}{k_j!} e^{-\theta}$$

A Loglikelihood függvény:

$$L(k_1, k_2, \dots, k_n; \theta) = \sum_{j=1}^n \ln P(X = k_j | \theta) = \sum_{j=1}^n (k_j \ln \theta - \theta - \ln k_j!) =$$

$$= \ln \theta \sum_{j=1}^n k_j - n\theta - \sum_{j=1}^n \ln k_j!$$

$$\log \left(\frac{\theta^{k_j}}{k_j!} e^{-\theta} \right)$$

$$\rightarrow \frac{1}{\theta} \sum_{j=1}^n k_j - n - 0$$

Megkeressük a maximumot:

$$0 = \frac{\partial}{\partial \theta} L(k_1, k_2, \dots, k_n; \theta) = \frac{1}{\theta} \sum_{j=1}^n k_j - n$$

$$\hat{\theta} = \theta = \frac{1}{n} \sum_{j=1}^n k_j = \bar{x}$$

Bernoulli becslése Likelihooddal

Tegyük fel, hogy van n Bernoulli változóm p paraméterrel.
Legyen (k_1, k_2, \dots, k_n) a kimenetek, ekkor

$$P(X = k_j | \theta = p) = p^{k_j} (1-p)^{1-k_j}$$

$$L(k_1, \dots, k_n; \theta) = \ln(p^{k_j} (1-p)^{1-k_j}) = \sum_{j=1}^n (k_j \ln p + (1-k_j) \ln(1-p))$$

Megkeressük a maximumot:

$$\begin{aligned} 0 &= \frac{\partial}{\partial p} L(k_1, k_2, \dots, k_n; p) = \frac{1}{p} \sum_{j=1}^n k_j - \frac{1}{1-p} \sum_{j=1}^n (1-k_j) = \\ &= -\frac{n}{1-p} + \left(\frac{1}{p} + \frac{1}{1-p} \right) \sum_{j=1}^n k_j = -\frac{n}{1-p} + \frac{1}{p(1-p)} \sum_{j=1}^n k_j \\ \theta = p &= \frac{1}{n} \sum_{j=1}^n k_j = \bar{x} \end{aligned}$$

dr. Keszthelyi Gabriella A4 Valószínűségszámítás

$k_j \rightarrow 0$
 $k_j \rightarrow 1$

$$\begin{aligned} P(X=1) &= p \\ P(X=0) &= 1-p \end{aligned}$$

$$\begin{aligned} 0 &= -\frac{n}{1-p} + \frac{1}{p(1-p)} \sum_{j=1}^n k_j \\ \frac{n}{1-p} &= \frac{1}{p(1-p)} \sum_{j=1}^n k_j \\ p &= \frac{1}{n} \sum_{j=1}^n k_j \end{aligned}$$

Konfidencia intervallum

Ahelyett, hogy pontosan meg akarnánk becsülni a keresett paramétert, gyakran elég, ha tudjuk, hogy milyen intervallumban van (bizonyos valószínűséggel). Például, ha a várható értéket akarjuk megbecsülni:

$$P(l(X) \leq \mu \leq u(X)) = 1 - \alpha$$

Azaz a μ a $[l(X), u(X)]$ intervallumban van $1 - \alpha$ valószínűséggel, akkor $[l(X), u(X)]$ a **konfidencia intervallum**, $1 - \alpha$ pedig a **konfidenciaszint**.

dr. Keszthelyi Gabriella A4 Valószínűségszámítás

Amikor csak a várható érték ismeretlen

Példa

Legyenek X_j -k független, azonos eloszlású normális változók, ismeretlen μ -vel és ismert σ -val. Ekkor \bar{X}_n is normális μ várható értékkel és σ/\sqrt{n} szórással. Mi lesz az $1 - \alpha$ szinthez tartozó konfidenciaintervallum?

$$\begin{aligned} 2\Phi(z) - 1 &= P\left(-z \leq \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \leq z\right) = \\ &= P\left(\bar{X}_n - \frac{z\sigma}{\sqrt{n}} \leq \mu \leq \bar{X}_n + \frac{z\sigma}{\sqrt{n}}\right) \end{aligned}$$

Legyen $z_{\alpha/2}$ amire $\alpha = 2 - 2\Phi(z_{\alpha/2})$, ekkor

$$\left(\bar{X}_n - \frac{z_{\alpha/2}\sigma}{\sqrt{n}}, \bar{X}_n + \frac{z_{\alpha/2}\sigma}{\sqrt{n}}\right)$$

lesz a megfelelő konfidenciaintervallum.

Példa

Az X feszültség egy konstansból és zajból tevődik össze:

$$X = v + N$$

ahol $N \sim N(0, 1)$. Találj 95%-os konfidenciaintervallumot v -re ha 100-szor volt megmérve a feszültség és a mintaátlag $5.25\mu\text{V}$!

$\alpha = 0,05$, $z_{\alpha/2} = 1.96$ Ekkor a keresett intervallum:

$$\left(5,25 - \frac{1,96 \cdot 1}{10}, 5,25 + \frac{1,96 \cdot 1}{10}\right)$$

$(5,06 ; 5,44)$

$1 - \alpha = 0,95$
 $\alpha = 0,05 = 2 - 2\Phi(z_{\alpha/2})$
 $\Phi^{-1}(0,975) = 1,96$

Várható érték és szórás is ismeretlen

Legyenek X_j -k független, azonos eloszlású normális változók, ismeretlen μ -vel és ismeretlen σ -val. Mi lesz μ -nek az $1 - \alpha$ szinthez tartozó konfidenciaintervalluma?

A szórást lecseréljük a tapasztalati szórásra:

$$\left(\bar{X}_n - \frac{t\hat{\sigma}}{\sqrt{n}}, \bar{X}_n + \frac{t\hat{\sigma}}{\sqrt{n}} \right)$$
$$P\left(\bar{X}_n - \frac{t\hat{\sigma}}{\sqrt{n}} \leq \mu \leq \bar{X}_n + \frac{t\hat{\sigma}}{\sqrt{n}} \right) = P\left(-t \leq \frac{\bar{X}_n - \mu}{\hat{\sigma}/\sqrt{n}} \leq t \right) =$$
$$= 2T_{n-1}(t) - 1$$

alhotha van

normális változó

T-eloszlás változó

Irodalomjegyzék

- Vetier András—Valószínűségszámítás
- Alberto Leon-Garcia—Probability, Statistics, and Random Processes for Electrical Engineering
- Sheldon M. Ross —Introduction To Probability and Statistics for Engineers and Scientists
- Dimitri P. Bertsekas and John N. Tsitsiklis —Introduction to Probability
- E. T. Jaynes —Probability Theory - The Logic of Science

Köszönöm a figyelmet!