

بنام زندگی

تخمین $MVUE$

همان صورت که دیدیم، روند به سمت آدران تخمین $MVUE$ بر این

باید استوار است که مجموعه خانواده توزیع احتمال $\{P_\theta, \theta \in \Lambda\}$

یک مجموعه کامل باشد. در ادامه مطرح می‌کنیم که کرده زیادی از سراجب احتمال

که در عمل با آنها سر و کار داریم، کامل هستند. برای این منظور تا زارده توزیع ^{صک}
نمایی را معرفی می کنیم.

* خانواده توزیع های نمایی Exponential family of densities

اگر توابع $c(\cdot)$, $h(\cdot)$, $Q_1(\cdot)$, \dots , $Q_m(\cdot)$, $T_1(\cdot)$, \dots , $T_m(\cdot)$

توابعی صمیم باشند، دانسته باشیم.

$$P_{\underline{\theta}}(\underline{y}) = P(\underline{y} | \underline{\theta}) = h(\underline{y}) \exp\left(\sum_{i=1}^m T_i(\underline{y}) Q_i(\underline{\theta})\right) C(\underline{\theta})$$

$$\forall \underline{\theta} \in \Lambda, \forall \underline{y} \in \Gamma$$

آنگاه $\{P_{\underline{\theta}}(\underline{y}), \underline{\theta} \in \Lambda\}$ یک خانواده توزیع‌های نمایی که داریم.

همان‌طور که دیده می‌شود، اگرچه زیاده‌ای از شرایط اعمالی که با آنها سر و کار داریم، از خانواده توزیع‌های نمایی هستند.

در عنوان مثال توزیع های گوسی، رابلی، نمایی، لاپلاس، پواسن، براسن
در حالت تک بعدی و برداری از خانواده توزیع های نمایی هستند.

نقشه: خانواده توزیع های نمایی، کامل هستند (اثبات به عنوان تمرین با مطالعه)

اگر $c(\cdot)$ ، $h(\cdot)$ و $T_1(\cdot)$ ، \dots ، $T_m(\cdot)$ توابع صحتی باشند،

$$\underline{\theta} \in \Lambda, \quad \underline{y} \in \Gamma, \quad \Lambda \subseteq \mathbb{R}^m, \quad \Gamma \subseteq \mathbb{R}^n$$

$$\underline{\theta} = [\theta_1, \dots, \theta_m]^T, \quad \underline{y} = [y_1, \dots, y_n]^T$$

در ادامه داریم

$$P_{\theta}(y) = c(\theta) \exp\left(\sum_{i=1}^m \theta_i T_i(y)\right) h(y)$$

که نگاه کنیم به $T(y) = [T_1(y), T_2(y), \dots, T_m(y)]$ یک آمارگان کافی کامل

است. (یعنی $\{P_{\theta}(y), \theta \in \Omega\}$ یک خانواده توزیع کامل است) $T(y)$

یک آمارگان کافی ردی این خانواده توزیع است)

* نشان داره ی شود که آمارگان کافی کامل ، می نیال نیز هست .

* اگر چند آمارگان کافی حاصل پذیرالسم همگی بعضی مدیه بین آنها در دارند .

در ادامه می فرماییم باب مثال ، درند به دست آوردن تخمین $MVUE$!

بنیم .

مثال: تخمین رامنبری بر سیگنال از روی مشاهدات نرنبری آن

$$Y_k = \mu S_k + N_k \quad k = 1, 2, \dots, n$$

نرنبری \rightarrow N_k
 سیگنال اربال معلوم \rightarrow S_k
 رامنبری \rightarrow μ
 که می فرایند تخمین بزینم

نمونه های نرنبری N_1, \dots, N_n همزنه های

نرنبری $i.i.d$ کوسی با توزیع $N(0, \sigma^2)$ ، $S = [S_1, S_2, \dots, S_n]^T$ سیگنال معلوم μ پارامترنا معلوم است که می فرایند آن را تخمین بزینم ، همان رامنبری سیگنال

ارسالی است. هدف تخمین $MVUE$ است. $\mu \in \mathbb{R}$

۱- بدست آوردن بد آمارگان کافی کامل برداری خانواده توزیع های $\{P_\theta, \theta \in \mathbb{R}\}$

$$P_\theta(\underline{y}) = ?$$

$$N_i \sim N(0, \sigma^2)$$

$$P(\underline{y} | \mu) = ?$$

$$N_1 \perp N_2 \dots \perp N_n$$

$$Y_k = \mu S_k + N_k, \quad k=1, 2, \dots, n$$

به شرط معلوم بودن μ

$$y_k \sim N(\mu s_k, \sigma^2)$$

$$, y_1 \perp\!\!\!\perp y_2 \perp\!\!\!\perp \dots \perp\!\!\!\perp y_n, P(y_k | \mu) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y_k - \mu s_k)^2}{2\sigma^2}\right)$$

$$\Rightarrow P(\underline{y} | \mu) = \prod_{i=1}^n P(y_i | \mu)$$

$$= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y_i - \mu s_i)^2}{2\sigma^2}\right)$$

$$\Rightarrow P(\underline{y} | \mu) = \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mu s_i)^2\right)$$

برای به دست آوردن $T(y)$ از قضیه فاکتورسازی و عامل بدون اندازه نریجی
 مناسب استفاده می کنیم.

$$P(\underline{y} | \mu) = \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i^2 + \mu^2 s_i^2 - 2\mu s_i y_i)\right)$$

$$\Rightarrow P(\underline{y} | M) = \underbrace{\left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp\left(-\frac{\sum_{i=1}^n y_i^2}{2\sigma^2}\right)}_{h(\underline{y})} \underbrace{\exp\left(-\frac{N^2}{2\sigma^2} \sum_{i=1}^n s_i^2\right)}_{c(\theta)}$$

$$\exp\left(\underbrace{\frac{\mu}{\sigma^2}}_{\theta_1} \underbrace{\sum_{i=1}^n s_i y_i}_{T(\underline{y})}\right)$$

$$\theta_1 = \frac{\mu}{\sigma^2} \equiv \theta, \quad T(\underline{y}) = T_1(\underline{y}) = \sum_{i=1}^n s_i y_i$$

۲- به دست آوردن بیشترین بدون بایس از $g(\theta)$ به نام $\hat{g}(y)$

$$\theta = \frac{\mu}{\sigma^2} \quad \Rightarrow \quad \mu \equiv g(\theta) = \theta \sigma^2$$

با نگاهی به مشاهدات $y_k = \mu s_k + N_k$ مستخرجی داریم که امیدواریم

نرخ تمام مشاهدات به شرطی معلوم بودن μ برابر است با

$$E_{\mu} \{ y_k \} = \mu s_k$$

بنابراین $\hat{g}(y)$ می تواند مرتاب خطی از مشاهدات باشد که باید ثابت
معیار شده باشد. بنابراین ساده ترین حالت برای $\hat{g}(y)$ به صورت زیر
در نظر گرفته می شود.

$$\hat{g}(y) = \frac{y}{s_1}$$

$$E_{\mu} \{ \hat{g}(y) \} = \frac{\mu s_1}{s_1} = \mu = g(\theta)$$

۳- به دست آوردن تخمین $MVUE$ با استفاده از رابنوی زیر

$$g^*(T(\underline{y})) = E_{\mu} \left\{ \hat{g}(\underline{y}) \mid T(\underline{y}) = T(\underline{y}) \right\}$$

$$g^*(T(\underline{y})) = E_{\mu} \left\{ \frac{\overset{z_1}{y_1}}{s_1} \mid \overset{z_2}{T(\underline{y})} = \overset{z_2}{T(\underline{y})} \right\}$$

$$T(\underline{y}) = \sum_{i=1}^n s_i y_i, \quad T(\underline{y}) = \sum_{i=1}^n s_i y_i$$

$$\hat{g}(\underline{y}) = \frac{y_1}{s_1}, \quad ,$$

$$\hat{g}(\underline{y}) = \frac{y_1}{s_1}$$

z_1 ، z_2 در مشتمل تصادفی توأماً گاوسی هستند. زیرا هر ترکیب خطی از اجزای
از z_1 ، z_2 ، در واقع یک ترکیب خطی از y_1, \dots, y_n است و می دانیم
 $\{y_i\}_{i=1}^n$ متغیرهای تصادفی گاوسی مستقل از هم هستند، بنابراین ترکیب خطی مشتمل
تصادفی گاوسی می کند. (به شرطی که بردار μ)

$$g^a(T(\underline{y})) = E_{\mu} \{z_1 | z_2\} = m_{z_1} + c_{z_1 z_2} \text{Var}_{z_2}^{-1} (z_2 - m_{z_2})$$

$$z_1 = \frac{y_1}{s_1}, \quad z_2 = T(\underline{y}) = \sum_{i=1}^n s_i y_i$$

$$m_{z_1} = E_{\mu} \left\{ \frac{y_1}{s_1} \right\} = \mu$$

$$m_{z_2} = E_{\mu} \left\{ \sum_{i=1}^n s_i \cdot y_i \right\} = \sum_{i=1}^n s_i \overbrace{E_{\mu} \{ y_i \}}^{\mu s_i} = \mu \sum_{i=1}^n s_i^2$$

$$m_{z_2} = \mu n \overline{s^2}$$

$$\overline{s^2} = \frac{\sum_{i=1}^n s_i^2}{n} \equiv \text{میان میانگین مربعات}$$

$$C_{z_1, z_2} = E_{\mu} \left\{ (z_1 - m_{z_1}) (z_2 - m_{z_2}) \right\} = E_{\mu} \left\{ \left(\frac{y_1}{s_1} - \mu \right) \left(\sum_{i=1}^n s_i y_i - \mu n \overline{s^2} \right) \right\}$$

$$C_{z_1 z_2} = E_{\mu} \left\{ \frac{y}{s} \sum_{i=1}^n s_i y_i - \dots \right\} = \sigma^2$$

$$E_{\mu} \{ y_i y_j \} = \begin{cases} E y_i^2 = \mu^2 s_i^2 + \sigma^2 & i=j \\ E y_i E y_j = \mu^2 s_i s_j & i \neq j \end{cases}$$

$$y_i = \mu s_i + N_i, \quad y_j = \mu s_j + N_j$$

$$\text{Var}_{z_2} = \text{Var} \left(\sum_{i=1}^n s_i y_i \right) = E \left(z_2 - m_{z_2} \right)^2$$

$$\begin{aligned}
 \text{Var}_{Z_2} &= E \left(\sum_{i=1}^n s_i y_i - \mu_n \bar{s}^2 \right)^2 \\
 &= E \left(\left(\sum_{i=1}^n s_i y_i \right) \left(\sum_{j=1}^n s_j y_j \right) + \mu^2 n^2 (\bar{s}^2)^2 \right. \\
 &\quad \left. - 2 \mu_n \bar{s}^2 \sum_{i=1}^n s_i y_i \right)
 \end{aligned}$$

$$\Rightarrow \text{Var}(Z_2) = n \sigma^2 \bar{s}^2$$

$$\Rightarrow g^*(T(\underline{y})) = \frac{1}{n\bar{s}^2} \sum_{i=1}^n s_i y_i = \frac{T(\underline{y})}{n\bar{s}^2}$$

(تابعی 'نکاو' است)

$$\text{Var}(g^*(T(\underline{y}))) = \frac{1}{(n\bar{s}^2)^2} \underbrace{\text{Var}(T(\underline{y}))}_{\text{Var}_{Z_2}} = \frac{\sigma^2}{n\bar{s}^2}$$

= Min Var

حسان خود که داریم در روش $MVUE$ بر روی گروه سزایع احتمال
کامل $P(\theta)$ کاری کنیم. علامت منده هستیم که روشهای تخمین دیگری
نیز معرفی کنیم که برای تمام خانواده‌های توزیع‌ها، مثال استاده باشند.
بنابراین در ادامه روش تخمین ML را برای تخمین پارامترهای نامعلوم،
معرفی خواهیم کرد.