

به نام زندگی

شرط لازم دهانی برای تسادی در نامساری اقلدعات

- شرط دهانی : در خاداده توزیع نمایی  $h(y) = c(10)^e$  با شرط گفته شده،

اگر  $\hat{\theta}(y) = \tau$  در نظر بگیریم به گران نامساری اقلدعات اکثرین مقدار  
دارایین تخمین می رسیم .

در ادامه می فداحصیم شرط لازم برای رسیدن به گران نامساری اقلدعات را نیز به دست  
بیاد مییم .

بنابر این فرض می‌کنیم که کران ناسازی اطمینان دیتای برقرار است، نتایج حاصل از بررسی می‌کنیم.

به یاد داریم که ناسازی اطمینان به صورت زیر است:

$$\text{Var}_\theta (\hat{\theta}(y)) \geq \frac{\left[ \frac{\partial}{\partial \theta} E_\theta \{ \hat{\theta}(y) \} \right]^2}{I_\theta}$$

$$\Rightarrow \left[ \frac{\partial}{\partial \theta} E_\theta \{ \hat{\theta}(y) \} \right]^2 \leq \text{Var}_\theta (\hat{\theta}(y)) I_\theta$$

$$\Rightarrow \left[ \frac{\partial}{\partial \theta} E_\theta \{ \hat{\theta}(y) \} \right]^2 \leq E_\theta \left\{ \underbrace{(\hat{\theta}(y) - E_\theta \{ \hat{\theta}(y) \})^2}_{f(x)} \right\} E_\theta \left\{ \underbrace{\left( \frac{\partial}{\partial \theta} \log p_\theta(y) \right)^2}_{g(x)} \right\}$$

سادی در نامسادی شود اگر



$$g(n) = k f(n)$$

$$\frac{\partial}{\partial \theta} \log P_{\theta}(y) = k(\theta) (\hat{Q}(y) - E_{\theta} \{ \hat{Q}(y) \}) \quad (4)$$

سادی در گران نامسادی

اطلاعات

برای بدست آوردن شرط لازم برای سادی، باید رابطه‌ی (۱۰) را بررسی کنیم و بینیم

که نرم  $P_{\theta}(y)$  تحت این شرط به چه شکلی فرامحدود می‌شود. همچنین  $\hat{Q}(y)$  به چه شکلی

فرامحدود بنا بر این رابطه (۱۰) را به صورت زیر ساده می‌کنیم.

$$\frac{\partial}{\partial \theta} \log P_{\theta}(y) = \kappa(\theta) (\hat{\theta}(y) - \underbrace{E_{\theta} \{ \hat{\theta}(y) \}}_{f(\theta)}) \quad (*)$$

برای انتخاب عملیات فرض می‌کنیم  $\Lambda = (a, b)$

حسین برای سادگی در نوشتار، تراپی در حد

$$E_{\theta} \{ \hat{\theta}(y) \} = f(\theta)$$

از طرفین اضرب (\*) آنقدری می‌کنیم.

$$\int_a^{\theta} (*) d\theta$$

$$\int_a^{\theta} \frac{\partial}{\partial \theta_1} \log P_{\theta_1}(y) d\theta_1 = \int_a^{\theta} \kappa(\theta_1) (\hat{\theta}(y) - f(\theta_1)) d\theta_1$$

$$\Rightarrow \log P_{\theta_1}(y) \Big|_{\theta_1=a}^{\theta_1=\theta} = \int_a^{\theta} \kappa(\theta_1) (\hat{\theta}(y) - f(\theta_1)) d\theta_1$$

$$\Rightarrow \log P_{\theta}(y) - \log P_a(y) = \int_a^{\theta} \kappa(\theta_1) (\hat{\theta}(y) - f(\theta_1)) d\theta_1$$

$$\Rightarrow \log P_{\theta}(y) = \log P_a(y) + \int_a^{\theta} \kappa(\theta_1) (\hat{\theta}(y) - f(\theta_1)) d\theta_1 \quad (aa)$$

طرفین عبارت  
 $e$

$\xrightarrow{\log P_\theta(y)}$   
 $e^{P_\theta(y)} = P_\theta(y)$

$P_\theta(y) = e^{g(y; P_\theta)} \exp\left(\int_a^\theta k(\theta_1) (\hat{\theta}(y) - f(\theta_1)) d\theta_1\right)$

تابعیت متغیر از  $y$

$h(y)$

تابعیت فقط از  $\theta$

$\hat{\theta}(y) \int_a^\theta k(\theta_1) d\theta_1$

$\Rightarrow P_\theta(y) = h(y) \exp\left(\int_a^\theta k(\theta_1) \hat{\theta}(y) d\theta_1 - \int_a^\theta k(\theta_1) f(\theta_1) d\theta_1\right)$

تابعی از  $y$

تابعی از  $\theta$  × تابعی از  $y$

تابعیت متغیر از  $\theta$

تابعی از  $\theta$

بنابراین  $P_\theta(y)$  را می‌توان به فرم  $h(y) e^{g(\theta) T(y)}$  نوشت.

$$h(y) = e^{g(y) P_0(y)}$$

$$C(\theta) = \exp\left(-\int_a^\theta \kappa(\theta_1) f(\theta_1) d\theta_1\right)$$

$$g(\theta) = \int_a^\theta \kappa(\theta_1) d\theta_1$$

$$T(y) = \hat{\theta}(y)$$

که در آن

$\Rightarrow$  معنی  $P_0(y)$  نرم نایی  
داشته باشد  $T(y) = \hat{\theta}(y)$

$\Leftarrow$  شرط لازم برای برآوردی ستادی در کران نامساوی اقلهعات (رسیدن به تخمین کران بدین  
طریقی) این است که روی  $\{P_0(y), \theta \in \mathcal{M}\}$  با شرط گفته شده، داشته باشیم  $h(y) = C(\theta) e^{g(\theta) T(y)}$

و  $T(y) = \hat{h}(y)$  در شرط گرفته شود.

منابر این شرط لازم دامن برای رسیدن به گران نامساوی اقلدعات (تخمین کر با همزین  
و این) دردی خانواده توزیع های  $\{P_\theta(y), \theta \in \Lambda\}$  باشد که گفته شده، این است  
که داشته باشیم  $h(y) = c(\theta) e^{g(\theta)T(y)}$  (یعنی  $P_\theta(y)$  نرم نامی داشته باشد و

در نظر بگیریم  $\hat{h}(y) = T(y)$

در ادامه می خواهیم شرط برتری ساری در نامساوی اقلدعات را بررسی کنیم و به نتایج  
در مورد  $k(\theta)$  برسیم.



دیدیم که شرط‌سازی به صورت زیر است

$$\frac{\partial}{\partial \theta} \log P_{\theta}(y) = k(\theta) (\hat{\theta}(y) - f(\theta)) \quad (*)$$

$$E_{\theta} \{ \hat{\theta}(y) \} = f(\theta)$$

می‌خواهیم بدانیم که در حالت‌سازی  $k(\theta)$  چه رابطه‌ای با پارامترهای نامساوی اطلاعات دارد.


طرفین رابطه (۵) را

$$\implies \left( \frac{\partial}{\partial \theta} \log P_{\theta}(y) \right)^2 = k^2(\theta) (\hat{\theta}(y) - f(\theta))^2 \quad (1)$$

به توان درمی‌رانیم

با توجه به نامساوی اطلاعات

از طرفین رابطه ①



(با  $E_{\theta}$  می‌گیریم)

$$\underbrace{E_{\theta} \left\{ \left( \frac{\partial}{\partial \theta} \log P_{\theta}(y) \right)^2 \right\}}_{I_{\theta}} = k^2(\theta) \underbrace{E_{\theta} \left\{ (\hat{\theta}(y) - f(\theta))^2 \right\}}_{\text{Var}_{\theta}(\hat{\theta}(y))}$$

$$\Rightarrow I_{\theta} = k^2(\theta) \text{Var}_{\theta}(\hat{\theta}(y)) \quad \textcircled{2}$$

از طرف دیگر می‌دانیم که با مسایلی که در حالت‌های نزدیک به حالت‌های پایداری برقرار است یعنی

$$\text{Var}_{\theta}(\hat{\theta}(y)) = \frac{[f'(\theta)]^2}{I_{\theta}} \quad \textcircled{3}$$

③, ②  
→

$$k(\theta) = \frac{I_{\theta}}{f'(\theta)}$$

با حذف کردن  $\text{Var}_{\theta}(\hat{\theta})$

این رابطه برای به دست آوردن قسم  $P_{\theta}$  در حالت ساده، کمک کننده است.

Maximum Likelihood (ML)

\* تخمین بهترین شباهت

حماں مگر که در وقت MVE بیان کردیم، برای به دست آوردن تخمین MVE نیاز به محاسبه یک آمارگان کافی کامل داریم که لازم می‌آید در مجموعه  $\{\theta \in \mathcal{A}; P_{\theta}\}$  یک مجموعه خانواده توزیع‌های کامل باشد. یک آمارگان کافی روی آن به دست آوریم.

در بسیاری از مسائل شرط بالا برقرار نیست و ما به دنبال راه‌حلی برای تخمین هستیم که  
 بتوانیم در حالت کلی برای همه مجموعه‌های  $\{P_\theta; \theta \in \mathcal{L}\}$  و بدون داشتن  
 اطلاعات اولیه در مورد پارامتر  $\theta$  (یعنی  $w(\theta)$  را اختیار نداریم) پارامتر  $\theta$   
 را تخمین بزنیم. بنابراین به دنبال راه‌حلی هستیم که بدون هیچ شرطی روی  
 $\{P_\theta; \theta \in \mathcal{L}\}$  بتوانیم تخمین  $\theta$  را به دست بیاوریم. همی از راه‌حلهای متداول برای  
 این منظور، روش تخمین  $M_L$  است.

از دست تحمین MAP سی دانسیه که

$$\begin{aligned}\hat{\theta}_{MAP}(y) &= \text{Arg Max}_{\theta} (w(\theta|y)) \\ &= \text{Arg Max}_{\theta} \left( \frac{P(y|\theta)P(\theta)}{P(y)} \right) \\ &= \text{Arg Max}_{\theta} \left( \underbrace{P_{\theta}(y)}_{P(y|\theta)} \underbrace{w(\theta)}_{P(\theta)} \right) \\ &= \text{Arg Max}_{\theta} \left\{ P_{\theta}(y) \underline{w(\theta)} \right\}\end{aligned}$$

درصورتی که می‌فرضیم تخمین  $\theta$  را بدون داشتن اطلاعات اولیه از  $\theta$  به دست می‌آوریم یا به عبارت دیگر اطلاعات کافی در مورد  $\theta$  در اختیار نداریم که بتوانیم  $w(\theta)$  را تعیین کنیم. طرفی می‌کنیم که توزیع  $\theta$  روی مجموعه  $\Omega$  به صورت یکنواخت است. یعنی  $w(\theta) = \frac{1}{|\Omega|}$  (از نظر تئوری اطلاعات در حالت گسسته، توزیع یکنواخت ماکزیم آنترپی را دارد و در این حالت داریم برای بهترین حالت ممکن، تخمین را به دست می‌آوریم) در این حالت تخمین MAP به صورت زیر خواهد بود.

$$\hat{\theta}_{MAP}(y) = \underset{\theta}{\text{Arg Max}} \{ P_{\theta}(y) \} \equiv \hat{\theta}_{ML}(y)$$

تابع  $P(\theta | \mathcal{A}) = P_0(\theta)$ ، هر تابع یکنوا (mono-tone) از آن را یک تابع

شبهاحتمال (likelihood function) می‌گوییم. بنابراین این تخمین‌گر، تخمین‌گری است که تابع شبهاحتمال را ماکزیمم می‌کند و به آن تخمین‌گر بیشترین شبهاحتمال می‌گوییم.

\* توجه: این نکته لازم است که نشان اولی (در اکتشافی نشان  $w(\theta)$ ) معادل با یک افزایش بودن توزیع  $\theta$  نیست. علاوه بر این اگر  $\mathcal{A}$  یک مجموعه نامتناهی

باشد، فرض یک افزایش بودن توزیع  $\theta$ ، فرض درستی نیست. اما این دیدگاه برای رسیدن به جواب تخمین  $\theta_L$  یک دیدگاه ساده است که ما را با تخصیص‌های رایجی مرتبط

۴. تخمین ML دیگر معنی‌کننده (ردا و تقصیه‌های ریاضی برای رسیدن به تخمین ML بدون فرض کلیت افت بودن توزیع  $\theta$ ، در حراج و مورد دارد)

در هر صورت، چنان‌که دیدیم

$$\hat{\theta}_{ML}(y) = \text{Arg Max}_{\theta} \{ P_{\theta}(y) \}$$

به دست آوردن تخمین ML باید روش سرراست را ساده امکان‌پذیر است و همچنین تخمین ML ویژگی‌های خاصی دارد که در ادامه به آن‌ها می‌پردازیم اما پیاده‌سازی عملی تخمین ML پیچیده است (پسیدگی از مرتبه‌بندی نسبت به اجزای مسئله است)



برای برداشتن آرمان تخمین ML می توانیم به صورت زیر عمل کنیم.

$$\hat{\theta}_{ML}(y) = \text{Arg Max}_{\theta} \{ P_{\theta}(y) \}$$
$$= \text{Arg Max}_{\theta} \{ \log P_{\theta}(y) \}$$

و ما به تابع لگاریتم هم عددی است

با فرض یکنواختی  
 $\rightarrow$   
 $P_{\theta}(y)$

$$\frac{\partial}{\partial \theta} \log P_{\theta}(y) \Big|_{\theta = \hat{\theta}_{ML}} = 0$$

معادله شایستگی

Likelihood equation

در ادامه می‌فرض کنیم رگرسیون خطی این محاله را بررسی کنیم. به طرف خاص به دنبال رابطه‌ای  
بین تخمین ML و MVUE هستیم.

ترستی کنیم  $\hat{\theta}(y)$  یک تخمین بدون بایس از  $\theta$  است که بدان کرامت-رانوری بگویم.

$$\text{Var}_{\theta}(\hat{\theta}(y)) = \frac{1}{I_{\theta}}$$

به عبارت دیگر  $\hat{\theta}(y)$  یک MVUE است.

از طرف دیگر دیدیم که برای برقراری ستاری در کرامت ناسازی لغو حالت شرطی را باید  
برقرار باشد.

$$\log P_0(y) = \log h(y) + \int_a^{\theta} \kappa(\theta_1) (\hat{\theta}(y) - f(\theta_1)) d\theta_1 \quad (I)$$

(ابطوح به رابطه (۱۵۵))

$$\kappa(\theta) = \frac{I_{\theta}}{f'(\theta)}$$

همین سی دانش که در حالت ستادی داریم

مبتدعه به اینکه  $\hat{\theta}(y)$  بدون ابایس است، داریم.

$$f(\theta) = E_{\theta} \{ \hat{\theta}(y) \} = \theta \quad \Rightarrow \quad f'(\theta) = 1 \quad \Rightarrow \quad \kappa(\theta) = I(\theta)$$

$$\stackrel{(I)}{\Rightarrow} \log P_0(y) = \log h(y) + \int_a^{\theta} I_{\theta_1} (\hat{\theta}(y) - \theta_1) d\theta_1$$

از طرف دیگر، معادله شایسته به صورت زیر درآید

$$\frac{\partial}{\partial \theta} \log P_{\theta}(y) \Big|_{\theta = \hat{\theta}_{ML}} = 0$$

$$\frac{\partial}{\partial \theta} \log P_{\theta}(y) \Big|_{\theta = \hat{\theta}_{ML}} = z_{\theta} (\hat{\theta}(y) - \theta) \Big|_{\theta = \hat{\theta}_{ML}} = 0$$

$$\Rightarrow \hat{\theta}(y) = \hat{\theta}_{ML}$$

یعنی  $\hat{\theta}(y)$ ! فرض های گفته شده،  
حما و تخمین ML است.

به عبارت دیگر هر تخمین بدون بایاس  $\hat{\theta}(y)$  که به کران کرامر-رائز می رسد یک یعنی  $\hat{\theta}(y)$  بی  $MVUE$  است

تخمین کرامر  $ML$  (بشیرین شایسته) است.

تخمین کرامر که معادله شایسته را برقرار می کند

$\hat{\theta}$  بی تخمین  $ML$  است  $\implies$  اگر  $\hat{\theta}$  بی  $MVUE$  باشد  $\longleftarrow$

ولی عکس پس مطلب لزوماً درست نیست یعنی هر جواب معادله شایسته (که تخمین کرامر  $ML$  است) لزوماً  $MVUE$  نیست

مثال: تخمین ML برای پارامتر یک توزیع نمایی

فرض کنیم مشاهدات  $y_1, y_2, \dots, y_n$  را در اختیار داریم و می‌دانیم این مشاهدات

متغیرهای تصادفی iid با توزیع نمایی با پارامتر  $\theta$  هستند.  $\Lambda = (0, \infty)$

$$\Gamma = \mathbb{R}^n$$

$$P_{\theta}(y_k) = \begin{cases} \theta e^{-\theta y_k} & y_k \geq 0 \\ 0 & \text{oth.} \end{cases}$$

( $y_k$  ها توزیع نمایی  
با پارامتر  $\theta$  دارند)

تخمین ML از

ی فضا هم  $\theta^x$  را از روی مشاهدات  $y_1, y_2, \dots, y_n$  بیابیم  $\hat{\theta}_{ML}(\underline{y})$

$$\hat{\theta}_{ML}(\underline{y}) = \text{Arg Max}_{\theta} \{ P_{\theta}(\underline{y}) \}$$

می دانیم که

بنابر این در اولین مرحله  $P_{\theta}(\underline{y})$  را به دست می آوریم.

$$P_{\theta}(\underline{y}) = \prod_{k=1}^n P_{\theta}(y_k) = \prod_{k=1}^n \theta e^{-\theta y_k} \quad \{y_k\}_{k=1}^n \geq 0$$

iid متغیرهای  $\{y_k\}_{k=1}^n$

$$\bar{y} = \frac{\sum_{k=1}^n y_k}{n}$$

$$\Rightarrow P_{\theta}(\underline{y}) = \theta^n e^{-\theta \sum_{k=1}^n y_k} = \theta^n e^{-n\theta \bar{y}}$$

$\{y_k\}_{k=1}^n \geq 0$

$$\begin{aligned}
 \hat{\theta}_{ML}(\underline{y}) &= \text{Arg Max}_{\theta} \{ P_{\theta}(\underline{y}) \} \\
 &= \text{Arg Max}_{\theta} \{ \theta^n e^{-n\theta \bar{y}} \} \\
 &= \text{Arg Max}_{\theta} \{ \underbrace{n \log \theta - n\theta \bar{y}}_{\log P_{\theta}(\underline{y})} \} \\
 &\quad \uparrow \\
 &\quad \log(1.)
 \end{aligned}$$

$$\frac{\partial}{\partial \theta} \{ \underbrace{n \log \theta - n\theta \bar{y}}_{\log P_{\theta}(\underline{y})} \} \Big|_{\theta = \hat{\theta}_{ML}} = 0$$

معادله مشتاقیت



حل معادله انتگرالی  
=>

$$\frac{\partial}{\partial \theta} (n \log \theta - n \theta \bar{y}) \Big|_{\theta = \hat{\theta}_{ML}} = 0$$

$$\frac{n}{\theta} - n \bar{y} \Big|_{\theta = \hat{\theta}_{ML}} = 0$$

$$\Rightarrow \hat{\theta}_{ML}(\underline{y}) = \frac{1}{\bar{y}} = \frac{n}{\sum_{k=1}^n y_k}, \quad \bar{y} = \frac{1}{n} \sum_{k=1}^n y_k$$

بابت صواب باشد مشتق دوم  $\frac{\partial^2}{\partial \theta^2} \log P_{\theta}(y) = -\frac{n}{\theta^2}$  به ازای  $\hat{\theta}_{ML}(y)$  که در بالا

به دست آمده است، معنی است در نتیجه جواب به دست آمده عبارت  $P_0(y)$  را ماکزیم می کند.

$$\hat{\theta}_{ML}(y) = \frac{1}{\bar{y}}, \quad \bar{y} = \frac{\sum_{k=1}^n y_k}{n}$$

**نکته اول:** در مورد شریفتراض ناپی  $y_k$  با برابری  $\theta$  می دانیم که

$$E\{y_k\} = \frac{1}{\theta}, \quad k=1, 2, \dots, n$$

از طرف دیگر به دست آوردیم

$$\hat{\theta}_n(y) = \frac{1}{y}$$

( $\bar{y}$  میانگین عددی مقادیر مشغله‌های تصادفی  $y_1, \dots, y_n$  است)

از قانون اعداد بزرگ، می‌دانیم که اگر  $n$  به اندازه‌ی کافی بزرگ باشد، میانگین‌ها به سمت میانگین‌های آماری (یعنی امید ریاضی) همگرا می‌شوند. یعنی

$$\{\bar{y}\} \xrightarrow[n \rightarrow \infty]{P} E y = \frac{1}{\theta}$$

(همگرا می‌در آید)

$$\left\{ \frac{1}{\bar{y}} \right\} \xrightarrow[n \rightarrow \infty]{P} \theta$$

(همگرا می‌در آید)

با به عبارتی دیگر

نابرابری می توان گفت که تخمین که  $ML$ ،  $\hat{\theta}_{ML}(y)$  برای  $n$  های به اندازه کافی بزرگ، با مفهوم احتمال به سمت مقدار واقعی پارامتر  $\theta$  همگرا می شود.

این خاصیت برای تمامی تخمین کرهای  $ML$  برقرار است و به آن خاصیت سازگاری  $Consistency$  گفته می شود.

تخمین  $ML$  در حد وقتی  $n \rightarrow \infty$ ، به سمت مقدار واقعی پارامتر مورد تخمین همگرا می شود.

$Consistency$  of  $ML$  Estimation.