

Estimador de Máxima Verossimilhança

5.2

Introdução

- ✔ Assuma que deseja-se conhecer um parâmetro de interesse θ de certa característica dos elementos de uma população que possa ser representada por uma variável aleatória X com função densidade $f(x;\theta)$, em que θ é desconhecido.
- ✔ Assuma também que os valores x_1, x_2, \dots, x_n da amostra aleatória X_1, X_2, \dots, X_n de $f(x;\theta)$ foram observados.
- ✔ Baseado nos valores observados da amostra aleatória, queremos estimar o valor do parâmetro desconhecido θ .
- ✔ Na **estimação pontual**, o valor de alguma estatística $t(X_1, X_2, \dots, X_n)$ representa, ou **estima**, o parâmetro desconhecido θ .

Exemplo

- Suponha que uma urna contém bolas pretas e brancas e que a razão entre elas é de 3/1, mas não sabemos se há mais bolas pretas ou brancas. Assim, a probabilidade de retirar uma bola preta é 1/4 ou 3/4 .
- Se n bolas são retiradas da urna com reposição, a distribuição de $X =$ número de bolas pretas é dada pela distribuição binomial

$$P(x; p) = \binom{n}{x} p^x (1 - p)^{n-x}, \quad x = 0, 1, 2, \dots, n$$

em que $p = 1/4$ ou $p = 3/4$.

- Iremos retirar uma amostra de três bolas ($n = 3$) com reposição e tentar estimar o parâmetro desconhecido p da distribuição.

Resultados de x	0	1	2	3
$P(X = x; \frac{3}{4})$	$\frac{1}{64}$	$\frac{9}{64}$	$\frac{27}{64}$	$\frac{27}{64}$
$P(X = x; \frac{1}{4})$	$\frac{27}{64}$	$\frac{27}{64}$	$\frac{9}{64}$	$\frac{1}{64}$

- Se encontrarmos $x = 0$ em uma amostra de 3, a estimativa 0,25 para p deve ser preferida sobre 0,75 porque a probabilidade $27/64$ é maior que $1/64$, isto é, porque uma amostra com $x = 0$ é mais verossímil (no sentido de ter maior probabilidade) ter surgido de uma população com $p = 1/4$ do que de uma com $p = 3/4$.

- O estimador pode ser definido como

$$\hat{p} = \hat{p}(x) = \begin{cases} 0,25, & \text{para } x = 0, 1 \\ 0,75, & \text{para } x = 2, 3. \end{cases}$$

- O estimador então seleciona para cada possível x o valor de p , dito \hat{p} , de tal forma que

$$P(x; \hat{p}) > P(x; p'),$$

em que p' é o valor alternativa de p .

Função de Verossimilhança

Definição: A **função de verossimilhança** de n variáveis aleatórias X_1, X_2, \dots, X_n é definida como a densidade conjunta das n variáveis aleatórias, isto é, $L(\theta; x_1, x_2, \dots, x_n) = f(x_1, x_2, \dots, x_n; \theta)$, que é considerada ser uma função de θ , com $\theta \in \Theta$, em que Θ é o espaço paramétrico.

Em particular, se X_1, X_2, \dots, X_n é uma amostra aleatória da densidade $f(x; \theta)$, então a função de verossimilhança é $L(\theta; x_1, x_2, \dots, x_n) = \prod_{i=1}^n f(x_i; \theta)$.

Interpretação: A função de verossimilhança $L(\theta; x_1, x_2, \dots, x_n)$ nos dá a verossimilhança relativa à um particular valor x_1, x_2, \dots, x_n que a variável aleatória assume. Supondo θ conhecido, então um particular valor da variável aleatória é mais “provável que ocorra”, ou mais “verossímil”, quando o valor da função for o máximo.

O **Princípio da Verossimilhança** postula que para fazer inferência sobre uma quantidade de interesse θ só importa aquilo que foi realmente observado e não aquilo que “poderia” ter ocorrido mas efetivamente não ocorreu.

Estimador de Máxima Verossimilhança

Definição: Seja $L(\theta) = L(\theta; x_1, x_2, \dots, x_n)$ a função de verossimilhança das variáveis aleatórias X_1, X_2, \dots, X_n . Se $\hat{\theta}$ (em que $\hat{\theta}$ é função das observações x_1, x_2, \dots, x_n) é o valor de $\theta \in \Theta$ que maximiza $L(\theta)$, então $\hat{\theta}$ o **estimador de máxima verossimilhança (EMV)** de θ , ou seja,

$$\hat{\theta} = \arg \max_{\theta \in \Theta} L(\theta; x_1, x_2, \dots, x_n).$$

Se a função de verossimilhança conter k parâmetros, ou seja,

$$L(\theta_1, \theta_2, \dots, \theta_k) = \prod_{i=1}^n f(x_i; \theta_1, \theta_2, \dots, \theta_k)$$

então os estimadores de máxima verossimilhança de $\theta_1, \theta_2, \dots, \theta_k$ são variáveis aleatórias (que dependem da amostra), em que $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k$ são valores em Θ que maximizam $L(\theta_1, \theta_2, \dots, \theta_k)$.

Procedimento usual

- ∇ O logaritmo natural da função de verossimilhança de θ é denotado por

$$\ell(\theta) = \log[L(\theta)].$$

- ∇ Como o logaritmo é uma função crescente e contínua, o valor de θ que maximiza $L(\theta)$ também maximiza $\ell(\theta)$. Se $\ell(\theta)$ é variável, o estimador de máxima verossimilhança pode ser encontrado como a raiz da equação de verossimilhança

$$\ell'(\theta) = \frac{d\ell(\theta)}{d\theta} = 0.$$

- ∇ Para se concluir que é um ponto de máximo, é necessário verificar se

$$\ell''(\theta) = \frac{\partial^2 \ell(\theta)}{\partial \theta^2} \Big|_{\theta=\hat{\theta}} < 0.$$

Outras formas de encontrar o estimador

- ▮ Nos casos em que o suporte da distribuição de X depende de θ ou o máximo ocorre na fronteira de Θ , o estimador de máxima verossimilhança é em geral obtido inspecionando o gráfico da função de verossimilhança.
- ▮ Quando não é possível encontrar analiticamente o ponto de máximo da função de verossimilhança, podemos utilizar métodos numéricos, como o método de Newton-Raphson. Computacionalmente, no R temos a rotina *"mle"* do pacote *"stats4"* ou o *"optim"* do pacote *"stats"*.

Exemplo

Exponencial

Sejam X_1, X_2, \dots, X_n uma amostra aleatória da variável aleatória $X \sim \text{Exp}(\theta)$ com densidade

$$f(x; \theta) = \theta e^{-\theta x},$$

$\theta > 0$ e $x \geq 0$. Encontre o estimador de máxima verossimilhança para θ .

$$f(x_i; \theta) = \theta e^{-\theta x_i} \quad \boxed{|n|}$$

$$L(\theta) = L(\theta; x_1, \dots, x_n) = \prod_{i=1}^n f(x_i; \theta) = \theta^n e^{-\theta \sum_{i=1}^n x_i}$$

$$l(\theta) = \log(L(\theta)) = n \log(\theta) - \theta \sum_{i=1}^n x_i$$

$$\frac{dl(\theta)}{d\theta} = \frac{n}{\theta} - \sum_{i=1}^n x_i = 0 \rightarrow \frac{n}{\theta} = \sum_{i=1}^n x_i \quad \hat{\theta} = \frac{n}{\sum_{i=1}^n x_i} = \frac{1}{\bar{X}}$$

$$\frac{d^2 l(\theta)}{d\theta^2} = -\frac{n}{\theta^2} < 0 \quad \hat{\theta} = \frac{1}{\bar{X}} \text{ EMV p/0}$$

Exemplo

Normal

Sejam X_1, X_2, \dots, X_n uma amostra aleatória da variável aleatória $X \sim N(\mu, \sigma^2)$, onde μ e σ^2 são desconhecidos. Temos então que $\theta = (\mu, \sigma^2)$ e

$$f(x; \theta) = \left(\frac{1}{2\pi\sigma^2} \right)^{1/2} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

$-\infty < x < \infty$, $-\infty < \mu < \infty$ e $\sigma^2 > 0$. Encontre o estimador de máxima verossimilhança para θ .

$$L(\theta) = \left(\frac{1}{2\pi\sigma^2} \right)^{n/2} e^{-\sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}}$$

$$\ell(\theta) = -\frac{n}{2} \log(2\pi\sigma^2) - \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}$$

$$\frac{\partial \ell(\theta)}{\partial \mu} = 2 \sum_{i=1}^n \frac{(x_i - \mu)}{2\sigma^2} = 0 \quad \rightarrow \quad \hat{\mu} = \bar{X}.$$

$$\ell(\sigma^2) = -\frac{n}{2} \log(2\pi\sigma^2) - \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{2\sigma^2}$$

$$\frac{\partial \ell(\sigma^2)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{2\sigma^4} = 0 \quad \rightarrow \quad \widehat{\sigma^2} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2.$$

Exemplo

Weibull

Sejam X_1, X_2, \dots, X_n uma amostra aleatória da variável aleatória $X \sim \text{Weibull}(\beta, \lambda)$, onde β e λ são desconhecidos. Temos então que $\theta = (\beta, \lambda)$

$$f(x; \theta) = \beta \lambda (\lambda x)^{\beta-1} e^{-(\lambda x)^\beta}$$

$x \geq 0$, $\beta > 0$ e $\lambda > 0$. Encontre o estimador de máxima verossimilhança de θ .

$$L(\theta; X) = \prod_{i=1}^n \beta \lambda (\lambda x_i)^{\beta-1} e^{-(\lambda x_i)^\beta}$$

$$\ell(\theta; X) = n \log(\beta) + n \beta \log(\lambda) + (\beta - 1) \sum_{i=1}^n \log(x_i) - \sum_{i=1}^n (\lambda x_i)^\beta$$

$$\frac{\partial \ell(\theta; X)}{\partial \lambda} = \frac{n \beta}{\lambda} - \beta \lambda^{\beta-1} \sum_{i=1}^n (x_i)^\beta$$

$$\frac{\partial \ell(\theta; X)}{\partial \beta} = \frac{n}{\beta} + n \log(\lambda) + \sum_{i=1}^n \log(x_i) - \sum_{i=1}^n (\lambda x_i)^\beta \log(\lambda x_i).$$

Utilizando o R

```
> library(stats)
> x=c(3, 5, 6, 7, 8, 9, 10, 10, 12, 15, 15,18, 19, 20, 22, 25, 28, 30, 40, 45)
> n=length(x)
> log.vero.W=function(l){
+ lambda=l[1]
+ beta=l[2]
+ -( log(beta)*n + (beta-1)*sum(log(x)) + beta*log(lambda)*n - sum( (lambda*x)^beta )
+ )
+ }
> optim(c(1,1),log.vero.W)
$par
[1] 0.05132946 1.62517976

$value
[1] 73.91645

$counts
function gradient
      119      NA

$convergence
[1] 0
```

Propriedades dos Estimadores de Máxima Verossimilhança

O método da máxima verossimilhança é um método estabelecido de estimação de parâmetros de modelos estatístico, sendo utilizado por muitos estatísticos teóricos e práticos. O uso generalizado do método se deve às propriedades probabilísticas das estimativas produzidas por ele.

Assumindo-se que a função de verossimilhança satisfaz algumas propriedades matemáticas básicas, que são frequentemente alcançadas pelos modelos mais utilizados, os EMV tem as seguintes propriedades:

Consistência: os EMV são consistentes, ou seja, elas convergem em probabilidade para o valor do parâmetro. Ou seja, os EMV **são não-viciados para grandes amostras** ($n \rightarrow \infty$).

Eficiência Assintótica: O Teorema do Limite Inferior de Cramer-Rao afirma que, para um dado parâmetro qualquer, existe um limite inferior para a variância das estimativas não-viciadas. **Para grandes amostras**, os EMV atingem esse limite e, portanto, **têm a menor variância possível dentre as estimativas não-viciadas**.

Invariância: os EMV são **invariantes sob transformações monotônicas**. Por exemplo, seja $\hat{\mu}$ um EMV que pode ser transformada para:

$$\begin{aligned}\hat{\theta}_1 &= \log(\hat{\mu}), \\ \hat{\theta}_2 &= \sqrt{\hat{\mu}} e \\ \hat{\theta}_3 &= e^{\hat{\mu}},\end{aligned}$$

então as estimativas $\hat{\theta}_1$, $\hat{\theta}_2$ e $\hat{\theta}_3$ também são EMV.

Normalidade Assintótica: os EMV convergem em distribuição para distribuição normal. Ou seja, para **grandes amostras** os EMV **tem distribuição aproximadamente normal**.

Teorema (O princípio da invariância):

Sejam X_1, X_2, \dots, X_n uma amostra aleatória da variável aleatória X com função de densidade (ou de probabilidade) $f(x; \theta)$. Se $\hat{\theta}$ é um estimador de máxima verossimilhança de θ , então $g(\hat{\theta})$ é um estimador de máxima verossimilhança de $g(\theta)$.

Prova:

Provamos o resultado para o caso em que g é 1:1. Sendo $g(\cdot)$ uma função 1:1, temos que $g(\cdot)$ é inversível, de modo que $\theta = g^{-1}(g(\theta))$. Assim,

$$L(\theta; X) = L(g^{-1}(g(\theta)); X),$$

de modo que $\hat{\theta}$ maximiza os dois lados da equação acima. Logo

$$\hat{\theta} = g^{-1}(\widehat{g(\theta)}),$$

portanto,

$$\widehat{g(\theta)} = g(\hat{\theta}),$$

ou seja, o estimador de máxima verossimilhança de $g(\theta)$ é $g(\hat{\theta})$.

Distribuição em grandes amostras:

No caso em que a amostra é grande, o suporte $A(x) = \{x, f(x;\theta) > 0\}$ seja independente de θ e que seja possível a troca de ordens das operações de derivação e de integração sob a distribuição da variável aleatória X , temos que

$$\sqrt{n}(\hat{\theta} - \theta) \stackrel{a}{\sim} N\left(0, \frac{1}{I_F(\theta)}\right),$$

e

$$\sqrt{n}(g(\hat{\theta}) - g(\theta)) \stackrel{a}{\sim} N\left(0, \frac{(g'(\theta))^2}{I_F(\theta)}\right).$$

Assim, para grandes amostras, os estimadores de máxima verossimilhança de θ e $g(\theta)$ são aproximadamente não viciados, cujas variâncias coincidem com os correspondentes limites inferiores das variâncias dos estimadores não viciados de θ e $g(\theta)$. Neste caso, em grandes amostras o estimador de máxima verossimilhança é **eficiente**.

O estimador de máxima verossimilhança **nem sempre é não viciado**, mas muitas vezes ele pode ser modificado para que se torne não viciado.

Erro Quadrático Médio

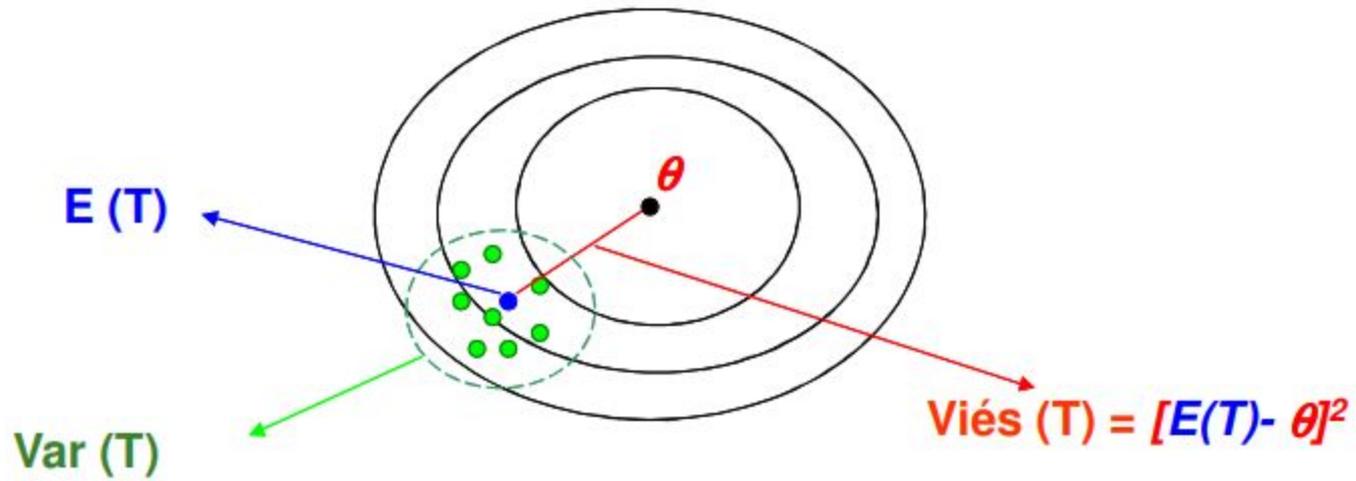
Nem sempre um estimador viciado não é bom, às vezes o que perdemos por ter um viés pequeno pode ser compensado pela concentração em torno do valor verdadeiro. De alguma forma temos que combinar os dois fatores: $E(\hat{\theta})$ “próxima” de θ e $\text{Var}(\hat{\theta})$ “próxima” de 0. Isto pode ser obtido através de uma medida muito útil de proximidade chamada erro quadrático médio (EQM).

Definição: Seja $\hat{\theta}$ um estimador de θ baseado em uma amostra aleatória X_1, X_2, \dots, X_n . O **erro quadrático médio** (EQM) de $\hat{\theta}$ é:

$$\text{EQM}(\hat{\theta}, \theta) = E[(\hat{\theta} - \theta)^2] = \text{Vício}(\hat{\theta}, \theta)^2 + \text{Var}(\hat{\theta}),$$

em que $\text{Vício}(\hat{\theta}, \theta)$ é o vício de $\hat{\theta}$ e $\text{Var}(\hat{\theta})$ é a variância de $\hat{\theta}$.

Se $\hat{\theta}$ é não viciado, então $\text{EQM}(\hat{\theta}, \theta) = \text{Var}(\hat{\theta})$. Se $\hat{\theta}$ é viciado, então $\text{EQM}(\hat{\theta}, \theta)$ pode ser pensado como uma medida de espalhamento de $\hat{\theta}$ em torno de θ .



Exemplo

Seja X_1, X_2, \dots, X_n a.a. com n observações de uma população $X \sim \text{Poisson}(\lambda)$.

1. Encontre o EMV de λ .
2. Compare o estimador encontrado anteriormente com o estimador $T = 1$.

$$d) X \sim \text{Pois}(\lambda) \quad f(x_i, \lambda) = \frac{e^{-\lambda} \lambda^{x_i}}{x_i!}$$

$$L(\lambda) = \prod_{i=1}^n \frac{e^{-\lambda} \lambda^{x_i}}{x_i!} \quad \ell(\lambda) = -n\lambda + \log(\lambda) \cdot \sum_{i=1}^n x_i - \sum_{i=1}^n \log(x_i!)$$

$$\frac{d\ell(\lambda)}{d\lambda} = -n + \frac{\sum_{i=1}^n x_i}{\lambda} = 0$$

$$\frac{\sum_{i=1}^n x_i}{\lambda} = n$$

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

$$z) \underline{EQM}(\hat{\lambda}; \lambda) = E[(\bar{x} - \lambda)^2] = \text{Var}(\bar{X}) + \text{Vício}(\bar{X}; \lambda)^2 = \frac{\lambda}{n} - 0 = \frac{\lambda}{n} \downarrow$$

$$\text{Vício}(\bar{x}; \lambda) = E(\bar{X}) - \lambda = \frac{\sum_{i=1}^n E(X_i)}{n} - \lambda = \frac{n\lambda}{n} - \lambda = 0$$

$$\text{Var}(\bar{x}) = \frac{n \text{Var}(X_i)}{n^2} = \frac{\lambda}{n}$$

$$\underline{EQM}(1; \lambda) = E[(1 - \lambda)^2] = (1 - \lambda)^2 \downarrow$$

