

## **Distribuição Amostral e Estimação Pontual de Parâmetros**


### **Roteiro**

1. Introdução
2. Teorema Central do Limite
3. Conceitos de Estimação Pontual
4. Métodos de Estimação Pontual
5. Referências

### **Introdução**

### **População e Amostra**

- População:
  - √ Conjunto de elementos que apresentam pelo menos uma característica em comum
- População Alvo:
  - √ População de interesse da pesquisa
- Amostra:
  - √ Qualquer subconjunto não vazio da população



## Técnicas de Amostragem

- Procedimento a ser adotado na seleção dos elementos da amostra
- O principal objetivo central é obter uma amostra representativa
  - √ Amostra que representa toda a população da melhor maneira possível
- A representatividade depende de:
  - √ Metodologia adotada para seleção da amostra
  - √ Tamanho da amostra

## Problema Fundamental da Estatística

A partir da observação de amostras, **COMO** podemos tirar **CONCLUSÕES** sobre a **POPULAÇÃO** ?

## Planejando um Experimento

- Identificar seu objetivo
- Coletar dados amostrais
- Usar procedimento aleatório para evitar vício
- Analisar dados e tirar conclusões

### **Erro Amostral**

- Diferença entre um resultado amostral e o verdadeiro resultado populacional
  - √ são resultantes de flutuações amostrais aleatórias.

### **Erro Não-amostral**

- Incorreção na coleta, registro ou análise de dados amostrais
  - √ Ex.
    - Coleta tendenciosa de amostra
    - Utilização de instrumento descalibrado
    - Registro incorreto de dados amostrais

### **Inferência Estatística**

- Definição:
  - √ Procedimentos generalizar características de população a partir da informação contida na amostra.
- Baseia-se na Teoria de Probabilidades
- Áreas:
  - √ Estimação de parâmetros
  - √ Testes de hipóteses.

### **Estimação de Parâmetros**

- Estimação Pontual
- Estimação Intervalar
  - √ Intervalos de Confiança

## Teste de Hipóteses

- Hipótese:
  - √ Afirmação (alegação) sobre característica populacional
- Teste de Hipóteses:
  - √ Procedimento padrão para se testar uma afirmativa sobre característica populacional

## Conceitos Fundamentais

- Amostra aleatória:
  - √ As variáveis aleatórias  $X_1, X_2, \dots, X_n$  são uma amostra aleatória de tamanho  $n$ , se:
    - Forem independentes
    - Cada  $X_i$  tiver mesma distribuição de probabilidades

- Parâmetro:
  - √ Quantidades de interesse da população
  - √ Em geral, desconhecidas
    - Média de uma população ( $\mu$ )
    - Desvio-padrão de uma população ( $\sigma$ )
  - √ Representadas por letras gregas
  - √ Notação para estimador qualquer:  $\theta$

- Estatística:
  - √ Qualquer função da amostra que não dependa de parâmetros desconhecidos
  - √ Exemplo : Algumas estatísticas da amostra aleatória  $X_1, X_2, \dots, X_n$ :
    - $X_{(1)} = \text{mín}(X_1, X_2, \dots, X_n)$
    - $X_{(n)} = \text{máx}(X_1, X_2, \dots, X_n)$

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

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}$$

- Distribuição amostral:

- √ Distribuição de probabilidades de uma estatística

- √ Exemplo:

- Distribuição amostral da média
    - Parâmetros da distribuição amostral da média

$$E(\bar{X}_n) = \mu_X$$

$$\text{Var}(\bar{X}_n) = \frac{\sigma_X^2}{n}$$

- Espaço paramétrico ( $\Theta$ )

- √ Conjunto em que o parâmetro  $\theta$  toma valores

- √ Exemplo: Seja a amostra aleatória  $X_1, X_2, \dots, X_n$  da variável  $X \sim N(\mu, \sigma^2)$

- Se  $\sigma^2=1$ , então  $\theta = \mu$  é o parâmetro desconhecido e

$$\Theta = \{\mu, -\infty < \mu < \infty\}$$

- Se  $\mu = 0$ , então  $\theta = \sigma^2$  é o parâmetro desconhecido e

$$\Theta = \{\sigma^2, \sigma^2 > 0\}$$

- Estimador de  $\theta$

- √ Qualquer estatística que assuma valores em  $\Theta$ .

- √ Notação:  $\hat{\theta}$

- √ Exemplo:

- Alguns estimadores para a média  $\mu$  de uma população

- Média da amostra
      - Mediana da amostra
      - $X_1$
      - Etc.

- Estimativa de parâmetro populacional:

- √ é um valor específico, ou um intervalo de valores, usado para estimar parâmetro populacional

- Estimativa pontual:

- √ é um único valor numérico de uma estatística  $\hat{\theta}$

## Teorema Central do Limite

## Teorema Central do Limite

- Seja  $X_1, X_2, \dots, X_n$  uma amostra aleatória de tamanho  $n$  de uma população (finita ou infinita), com média  $\mu$  e variância finita  $\sigma^2$ . Então

$$Z = \frac{\bar{X}_n - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$$

quando  $n \rightarrow \infty$ .


- **Comentários:**

- √ A aproximação normal para a média amostral depende do tamanho da amostra
- √ Com população contínua, unimodal e simétrica, na maioria dos casos, o TCL trabalha bem para pequenas amostras ( $n = 4, 5$ ).
- √ Em muitos casos de interesse prático, a aproximação normal será satisfatória para  $n \geq 30$
- √ Se  $n < 30$ , o TCL funcionará se a distribuição da população não for muito diferente da normal

## Exemplo – Simulação


- População exponencial com média 1:
  - √  $\lambda = 1$
  - √ Geração de 10.000 valores dessa população
  - √ Amostra de tamanho 1 ( $n = 1$ )

- Amostra n = 1




```
> mean(amostra); sd(amostra)
[1] 0.9990838
[1] 1.010478
```

- Amostra n = 2



```
> mean(media_n); sd(media_n)
[1] 1.012711
[1] 0.7129089
```


- Amostras de tamanhos 2, 4, 10 e 20




### Exemplo – Simulação

- População com densidade em U:
  - √  $f(x) = 12(x - 0,5)^2$
  - √ Geração de 10.000 valores dessa população
  - √ Amostra de tamanho 1 ( $n = 1$ )

- Amostra n = 1



- Amostras de tamanhos 2, 4, 10 e 20



## Comparação de Populações

- Considere duas populações:
  - √ População 1: média  $\mu_1$  e variância  $\sigma_1^2$
  - √ População 2: média  $\mu_2$  e variância  $\sigma_2^2$
- Amostras aleatórias das duas populações?
  - √ Amostra da população 1 de tamanho  $n_1$ :  $\bar{X}_1$
  - √ Amostra da população 2 de tamanho  $n_2$ :  $\bar{X}_2$

- Caso 1: As duas populações são normais

√ Distribuição amostral da diferença

$$\bar{X}_1 - \bar{X}_2 \sim N(\mu_{\text{dif}}, \sigma_{\text{dif}}^2)$$

√ Média da diferença de médias amostrais:

$$\mu_{\text{dif}} = E[\bar{X}_1 - \bar{X}_2] = E[\bar{X}_1] - E[\bar{X}_2] = \mu_1 - \mu_2$$

√ Variância da diferença de médias amostrais:

$$\sigma_{\text{dif}}^2 = \text{Var}[\bar{X}_1 - \bar{X}_2] = \text{Var}[\bar{X}_1] + \text{Var}[\bar{X}_2] = \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}$$

- Caso 2: populações não normais com tamanhos amostrais maiores que 30
  - √ Pode-se usar o TCL para aproximar a distribuição amostral da diferença:

### Distribuição Amostral Aproximada de Diferença de Médias Amostrais

- Suponha:
  - √ Duas populações independentes, com médias  $\mu_1$  e  $\mu_2$  e variâncias  $\sigma_1^2$  e  $\sigma_2^2$
  - √ Amostras aleatórias independentes de tamanhos  $n_1$  e  $n_2$  dessas populações

$$Z = \frac{\bar{X}_{1,n_1} - \bar{X}_{2,n_2} - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim N(0, 1)$$

se as condições do TCL se aplicarem

### Exemplo – Vida de Motor

- Motor de turbina de aeronave a jato
  - √ Vida de componente é variável aleatória com média 5000 h e desvio-padrão 40 horas
  - √ Melhoria no componente: média 5050 h e desvio-padrão 30 horas
  - √ Suponha amostra de  $n_1 = 16$  componente do processo antigo e  $n_2 = 25$  do processo aprimorado
- Qual a probabilidade de que a diferença das média amostrais seja no mínimo 25 horas?

### Estimação Pontual – Conceitos

## Propriedades de um Estimador

- Algumas propriedades importantes:
  - √ Vício
  - √ Consistência
  - √ Eficiência

## Vício

- Vício de um estimador:
  - √  $\text{Vício}(\hat{\theta}) = E[\hat{\theta}] - \theta$
- Um estimador  $\hat{\theta}$  é não viciado (não viesado, não tendencioso) para um parâmetro  $\theta$  se  $E[\hat{\theta}] = \theta$
- A esperança de um estimador está relacionada com sua **exatidão**

## Exemplos:

- √ A média amostral é não viciada para estimar a média verdadeira (populacional):

$$E(\bar{X}_n) = \mu_X$$

- √  $X_1$  (primeiro item coletado da amostra) é não viciado para estimar a verdadeira média


$$E(X_1) = \mu_X$$

- A variância amostral é não viciada para estimar a variância populacional ( $\sigma^2$ )?

$$\begin{aligned} E[S^2] &= \frac{1}{n-1} \sum_{i=1}^n E[(X_i - \bar{X})^2] \\ &= \frac{1}{n-1} E \left[ \sum_{i=1}^n (X_i - \mu + \mu - \bar{X})^2 \right] \\ &= \frac{1}{n-1} E \left[ \sum_{i=1}^n (X_i - \mu)^2 \right] - \frac{1}{n-1} E \left[ n(\bar{X} - \mu)^2 \right] \\ &= \frac{1}{n-1} \sum_{i=1}^n E[(X_i - \mu)^2] - \frac{n}{n-1} E[(\bar{X} - \mu)^2] \\ &= \frac{n}{n-1} \sigma^2 - \frac{1}{n-1} \sigma^2 \\ &= \sigma^2 \end{aligned}$$

### Variância de Estimador

- $\hat{\theta}_1$  e  $\hat{\theta}_2$  estimadores não-viciados de  $\theta$   
√ Variâncias diferentes



$$\sqrt{\text{Var}(\hat{\theta}_1)} < \sqrt{\text{Var}(\hat{\theta}_2)}$$

- É mais provável que  $\hat{\theta}_1$  produza uma estimativa mais próxima do valor verdadeiro de  $\theta$

### Estimador de Variância Mínima

- Se considerarmos todos os estimadores não-tendenciosos de  $\theta$ , aquele com a menor variância será chamado de **estimador não-tendencioso de variância mínima**  
√ Esse estimador é o mais provável, dentre todos os não-viciados, para produzir uma estimativa que seja próxima do valor verdadeiro

### Erro Padrão

- O erro padrão de um estimador  $\hat{\theta}$  é o seu desvio-padrão.

$$\sigma_{\hat{\theta}} = \sqrt{\text{Var}[\hat{\theta}]}$$

- √ O erro padrão (ou da variância) do estimador está relacionada com sua **precisão**

- √ Se o erro-padrão envolver parâmetros desconhecidos que possam ser estimados, então a substituição daqueles valores produz um erro-padrão estimado

- Exemplo: O erro padrão da média amostral é:  $\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$

- Se não conhecermos  $\sigma$ , mas substituirmos pelo desvio-padrão amostral, então o erro-padrão amostral estimado da média amostral é:

$$\hat{\sigma}_{\bar{X}} = \frac{S}{\sqrt{n}}$$


√ Quando o estimador seguir uma distribuição normal, podemos estar confiantes que o valor verdadeiro do parâmetro estará entre dois erros-padrão da estimativa

– Para grandes valores de n este é um resultado útil

√ Nos casos em que o estimador é não-viciado e não normalmente distribuído

– Estimativa do parâmetro, em no máximo 6% das vezes, se desviará do valor verdadeiro tanto quanto 4 erros-padrão

• Quadro comparativo:



## Consistência

• Um estimador  $\hat{\theta}$  é consistente se à medida em que o tamanho amostral aumenta, seu valor esperado converge para o parâmetro de interesse e sua variância converge para zero.

√ O estimador é consistente se  $\lim_{n \rightarrow \infty} E[\hat{\theta}] = \theta$  e

$$\lim_{n \rightarrow \infty} \text{Var}[\hat{\theta}] = 0$$

√ Consistência é uma propriedade assintótica (grandes amostras)

• Exemplos:

√ A média amostral é consistente para estimar a média verdadeira

√ O primeiro item coletado da amostra não é consistente para estimar a média populacional.

### Erro Quadrático Médio

- O erro quadrático médio de um estimador  $\hat{\theta}$  do parâmetro  $\theta$  é definido como:


$$\text{EQM}[\hat{\theta}] = E[\hat{\theta} - \theta]^2$$

- EQM – Vício e erro-padrão

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

- O EQM é um critério importante para comparar dois estimadores

- √ Estimadores tendenciosos podem ser preferíveis a estimadores não-tendenciosos se tiverem EQM menor



- √ Estimativa baseada em  $\hat{\theta}_1$  estaria provavelmente mais próxima do valor verdadeiro do que a baseada em  $\hat{\theta}_2$

- Estimador ótimo de  $\theta$ :

- √ Tem EQM menor ou igual ao EQM de qualquer outro estimador, para todos os valores de  $\theta$
- √ Estimadores ótimos raramente existem

### EQM de Estimadores Não-viciados

- No caso em que  $\hat{\theta}$  é um estimador não viciado para um parâmetro  $\theta$ , então:

$$\begin{aligned}\text{EQM}[\hat{\theta}] &= \text{Var}[\hat{\theta}] + [\text{Vício}(\hat{\theta})]^2 \\ &= \text{Var}[\hat{\theta}]\end{aligned}$$

### **Eficiência**

- Dados dois estimadores  $\hat{\theta}_1$  e  $\hat{\theta}_2$ , não viciados para um parâmetro  $\theta$ , dizemos que  $\hat{\theta}_1$  é mais eficiente que  $\hat{\theta}_2$  se  $\text{Var}[\hat{\theta}_1] < \text{Var}[\hat{\theta}_2]$ .

### • Exemplo:

√ No caso de amostra proveniente de distribuição Normal.

- Média amostral e mediana amostral são não viciadas para estimar a média populacional:

$$E[\bar{X}] = \mu \quad \text{e} \quad E[\tilde{X}] = \mu$$

- Média amostral e mediana amostral são consistentes para estimar a média verdadeira

$$\text{Var}[\bar{X}] = \frac{\sigma^2}{n} \quad \text{e} \quad \text{Var}[\tilde{X}] = \frac{\pi\sigma^2}{2n}$$

- A média amostral é mais eficiente que a mediana amostral para estimar a média populacional

$$\frac{\text{Var}[\bar{X}]}{\text{Var}[\tilde{X}]} = \frac{\frac{\sigma^2}{n}}{\frac{\pi\sigma^2}{2n}} = \frac{2}{\pi} = 0,63 < 1$$

### **Métodos de Estimação Pontual**

### **Métodos para Obtenção de Estimadores**

- Obtenção de bons estimadores:

√ As propriedades de estimadores não nos orientam sobre como construí-los

- Métodos para obtenção de estimadores pontuais:

√ Método dos Momentos

√ Método da Máxima Verossimilhança

### Método dos Momentos

- Ideia geral:
  - √ Igualar os momentos da população (definidos em termos de esperanças) aos correspondentes momentos da amostra
  - √ Os momentos da população são funções de parâmetros desconhecidos
  - √ Essas equações são resolvidas de modo a se obter estimadores dos parâmetros desconhecidos

### Momentos

- Seja  $X_1, X_2, \dots, X_n$  uma amostra aleatória de população com distribuição de probabilidades expressa por  $f(x)$  (função de probabilidade, se  $X$  for discreta ou função de densidade de probabilidades, se  $X$  for contínua)
  - √  $k$ -ésimo momento populacional  $E[X^k]$
  - √  $k$ -ésimo momento da amostra  $\frac{1}{n} \sum_{i=1}^n X_i^k$   
com  $k = 1, 2, \dots$

### Estimadores de Momento

- Seja uma amostra aleatória de função de probabilidade (ou de densidade de probabilidade) com  $m$  parâmetros desconhecidos  $\theta_1, \theta_2, \dots, \theta_m$ .
  - √ Os estimadores de momento  $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_m$  são encontrados igualando os  $m$  primeiros momentos da população aos  $m$  primeiros momentos da amostra
  - √ Os estimadores serão a solução das equações resultantes

### Exemplo

- Estimador de momentos da distribuição exponencial

$$\sqrt{f(x) = \lambda e^{-\lambda x}, x > 0}$$

$$E(X) = 1/\lambda$$

$$1^\circ \text{ momento da amostra: } \bar{X}$$

$$\frac{1}{\lambda} = \bar{X}$$

logo

$$\hat{\lambda} = \frac{1}{\bar{X}}$$

### Exemplo

- Tempo de falha de módulo eletrônico de motor
  - √ Amostra:
    - n = 8
    - (11,96; 5,03; 67,40; 16,07; 31,50; 7,73; 11,10; 22,38)
    - Média amostral: 21,65
    - Estimativa de momento de  $\lambda$ :  $\hat{\lambda} = \frac{1}{21,65} = 0,0462$

### Estimador de Momento da Normal

- Amostra aleatória oriunda de população normal, com parâmetros  $\mu$  e  $\sigma^2$ .

√ Momentos da normal:  $E[X] = \mu$   
 $E[X^2] = \mu^2 + \sigma^2$

√ Estimador de momentos:  $\mu = \bar{X}$   
 $\mu^2 + \sigma^2 = \frac{1}{n} \sum_{i=1}^n X_i^2$

$$\hat{\mu} = \bar{X}$$

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n X_i^2 - n \left( \frac{1}{n} \sum_{i=1}^n X_i \right)^2}{n} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$$

### Estimador de Momento da Gama

- Amostra aleatória oriunda de população normal, com parâmetros r e  $\lambda$ .

√ Momentos da gama:  $E[X] = \frac{r}{\lambda}$   
 $E[X^2] = \frac{r(r+1)}{\lambda^2}$

√ Estimador de momentos:  $\frac{r}{\lambda} = \bar{X}$   
 $\frac{r(r+1)}{\lambda^2} = \frac{1}{n} \sum_{i=1}^n X_i^2$

$$\hat{r} = \frac{\bar{X}^2}{\frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2} \quad \hat{\lambda} = \frac{\bar{X}}{\frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2}$$

### Exemplo

- Continuação exemplo 7.6 – Tempos de falha

$$\bar{X} = 21,65$$

$$\sum_{i=1}^8 X_i^2 = 6645,43$$

$$\hat{r} = \frac{(21,65)^2}{\frac{1}{8} 6645,43 - (21,65)^2} = 1,29$$

$$\hat{\lambda} = \frac{21,65}{\frac{1}{8} 6645,43 - (21,65)^2} = 0,0598$$

√ r é um pouco maior que 1

√ É bem possível que a distribuição gama ou exponencial forneça um modelo razoável para os dados

## Método da Máxima Verossimilhança

- Exemplo de Motivação:

√ Dados oriundos de população binomial com parâmetros 10 e  $p_0$ .

$p_0$ : constante e desconhecido

Função de probabilidade de X:

$$f(x; p_0) = P(X = x) = \binom{10}{x} p_0^x (1 - p_0)^{10-x}$$

Observa-se  $X = 3$

√ Objetivo:

- Basear-se no dado disponível para estimar o valor verdadeiro do parâmetro

- Não conhecemos  $p_0$ , mas podemos considerar o cenário em  $p_0 = 1/2$ .

√ Sob esta particular condição, a probabilidade de gerar o dado que realmente observamos ( $X = 3$ ) é:

$$P(X = 3) = f(3; 0,5) = \binom{10}{3} (0,5)^3 (0,5)^7 \approx 0,117$$


- Podemos calcular esta probabilidade sob a condição que  $p_0 = p$

$$L(p; 3) = \binom{10}{3} (p)^3 (1-p)^7, p \in [0, 1]$$

√ Essa função é denominada função de verossimilhança e denotamos por  $L(p; 3)$

## Princípio da Máxima Verossimilhança

- Devemos usar como nossa estimativa de  $p_0$  o valor de  $p$  que faz  $L(p; 3)$  o maior possível



Toma-se o valor do parâmetro que torna mais provável o dado observado

$$P(X = 3) = f(3; 0,3) = \binom{10}{3} (0,3)^3 (0,7)^7 \approx 0,267$$


## Função de Log-Verossimilhança

- Como o log é uma função crescente, o valor de  $p$  que maximiza  $L(p; 3)$  é o mesmo que maximiza  $\log L(p; 3)$

√ Em geral, é conveniente maximizar  $\log L(p; 3)$  ao invés de  $L(p; 3)$

√ Assim, em nosso exemplo, a função de log-verossimilhança é definida como:

$$\begin{aligned} l(p; 3) &\stackrel{\text{def}}{=} \ln L(p; 3) \\ &= 3 \ln p + 7 \log(1 - p) + \ln \binom{10}{3} \end{aligned}$$




$$l(p; 3) = 3 \ln p + 7 \ln(1 - p) + \ln \left( \frac{10}{3} \right)$$

√ O ponto crítico da função é um ponto no domínio de em que a derivada é zero

$$0 = \frac{\partial}{\partial p} l(p; 3)$$

$$= \frac{3}{p} - \frac{7}{1-p} = 3(1-p) - 7p$$

$$\hat{p} = \frac{3}{10}$$



- A estimativa é determinada pelo valor de X  
 √ Se tivéssemos observado  $X = k$ , teríamos a estimativa  $\hat{p} = \frac{k}{10}$

- Em nosso exemplo, o estimador de máxima verossimilhança é?

$$\hat{p} = \frac{X}{10}$$

### Função de Verossimilhança – Definição

- Suponha  $X$  uma variável aleatória com distribuição de probabilidades  $f(x; \theta)$ , em que  $\theta$  é um único parâmetro desconhecido.

√ Sejam  $x_1, x_2, \dots, x_n$  os valores observados de amostra aleatória de tamanho  $n$ .

√ A função de verossimilhança da amostra é:

$$L(\theta; x_1, x_2, \dots, x_n) = f(x_1; \theta) f(x_2; \theta) \dots f(x_n; \theta)$$

### Estimador de Máxima Verossimilhança

- O estimador de máxima verossimilhança (EMV) de  $\theta$  é o valor  $\hat{\theta}$  que maximiza a função de verossimilhança  $L(\theta; \mathbf{x})$

$$L(\hat{\theta}; \mathbf{x}) = \max_{\theta \in \Theta} L(\theta; \mathbf{x})$$

- √ No caso discreto, o EMV é um estimador que maximiza a probabilidade de ocorrência dos valores da amostra

### Exemplo – Distribuição de Bernoulli

- Seja  $X$  uma variável aleatória de Bernoulli  
√ Função de probabilidade:

$$f(x; p) = \begin{cases} p^x(1-p)^{1-x} & , x = 0, 1 \\ 0 & , \text{ caso contrário} \end{cases}$$

$p$  é o parâmetro desconhecido a ser estimado

- Função de verossimilhança da amostra

$$\begin{aligned} L(p; \mathbf{x}) &= p^{x_1}(1-p)^{1-x_1} p^{x_2}(1-p)^{1-x_2} \dots p^{x_n}(1-p)^{1-x_n} \\ &= \prod_{i=1}^n p^{x_i}(1-p)^{1-x_i} \\ &= p^{\sum_{i=1}^n x_i} (1-p)^{\sum_{i=1}^n (1-x_i)} \\ &= p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i} \end{aligned}$$

- Função de log-verossimilhança

$$l(p; \mathbf{x}) = \sum_{i=1}^n x_i \ln(p) + \left( n - \sum_{i=1}^n x_i \right) \ln(1-p)$$

- Derivada da função de log-verossimilhança:

$$l'(p; \mathbf{x}) = \frac{\sum_{i=1}^n x_i}{p} - \frac{n - \sum_{i=1}^n x_i}{1-p}$$

- Estimativa de máxima verossimilhança da amostra  $\mathbf{x}$ :

$$l'(\hat{p}; \mathbf{x}) = \frac{\sum_{i=1}^n x_i}{\hat{p}} - \frac{n - \sum_{i=1}^n x_i}{1-\hat{p}} = 0 \quad \hat{p} = \frac{\sum_{i=1}^n x_i}{n}$$


- Estimador de máxima verossimilhança para amostras de Bernoulli  $\hat{p} = \bar{X}$

√ Proporção de sucessos na amostra

## Exemplo



- Bernoulli com parâmetro  $p$  desconhecido

√ Duas amostras de  $n=20$  com  $\sum_{i=1}^{20} x_i = 8$  e  $\sum_{i=1}^{20} x_i = 11$



√ Duas amostras de  $n=40$  com  $\sum_{i=1}^{20} x_i = 16$  e  $\sum_{i=1}^{20} x_i = 22$

Pontos de máxima verossimilhança correspondentes à proporção de sucessos de cada amostra



√ As curvas crescem (decrecem) mais acentuadamente nas proximidades dos pontos de máximo na amostra maior ( $n=40$ )

– Variância do EMV é menor para amostras maiores)

- Amostragem industrial pode ser modelada como amostras de variável aleatória de Bernoulli:

√  $n$  itens selecionados ao acaso de linha de produção

√ Variável Aleatória:

$$X_i = \begin{cases} 1 & \text{, item classificado como não conforme} \\ 0 & \text{, caso contrário} \end{cases}$$

√ Estatística de teste:

$$\sum_{i=1}^n x_i: \text{ quantidade de itens não conformes na amostra}$$

$\hat{p}$ : proporção de itens não conformes na amostra

### Exemplo – Distribuição Exponencial

- Seja X uma variável aleatória exponencial

√ Função de densidade de probabilidade:

$$f(x; \lambda) = \begin{cases} \lambda e^{-\lambda x} & , x > 0 \\ 0 & , \text{ caso contrário} \end{cases}$$

$\lambda$  é o parâmetro desconhecido a ser estimado

- Função de verossimilhança da amostra

$$\begin{aligned} L(\lambda; \mathbf{x}) &= \lambda e^{-\lambda x_1} \lambda e^{-\lambda x_2} \dots \lambda e^{-\lambda x_n} \\ &= \prod_{i=1}^n \lambda e^{-\lambda x_i} \\ &= \lambda^n e^{-\lambda \sum_{i=1}^n x_i} \end{aligned}$$

- Função de log-verossimilhança

$$l(\lambda; \mathbf{x}) = n \ln(\lambda) - \lambda \sum_{i=1}^n x_i$$

- Derivada da função de log-verossimilhança:

$$l'(\lambda; \mathbf{x}) = \frac{\partial}{\partial \lambda} l(\lambda; \mathbf{x}) = \frac{n}{\lambda} - \sum_{i=1}^n x_i$$

- Estimativa de máxima verossimilhança da amostra  $\mathbf{x}$ :

$$l'(\hat{\lambda}; \mathbf{x}) = \frac{n}{\hat{\lambda}} - \sum_{i=1}^n x_i = 0 \quad \hat{\lambda} = \frac{n}{\sum_{i=1}^n x_i}$$

- Estimador de máxima verossimilhança para amostras exponenciais  $\hat{\lambda} = \frac{1}{\bar{X}}$

√ O EMV da exponencial é igual a seu estimador de momentos

### Exemplo

- (Continuação Ex. 7.6)

√ Tempo de falha de módulo eletrônico de motor

√ Amostra:

- n = 8


- (11,96; 5,03; 67,40; 16,07; 31,50; 7,73; 11,10; 22,38)

- Média amostral: 21,65  $\bar{X} = 21,65$

- Estimativa de máxima verossimilhança de  $\lambda$ :

$$\hat{\lambda} = \frac{1}{21,65} = 0,0462$$

- Função de log-verossimilhança da amostra




Função atinge máximo para  $\lambda=0,0462$

- √ Função é relativamente plana na região do máximo
  - Parâmetro não é estimado muito precisamente

- Comparação exponenciais:

- √ Curvas das diferenças de log-verossimilhança com o máximo em cada tamanho amostral
- √ Mantida mesma média amostral de 21,65



| n  | $l(\lambda_{\max})$ |
|----|---------------------|
| 8  | -32,599             |
| 20 | -81,497             |
| 40 | -162,994            |

Inclinação da curva de log-verossimilhança acentua-se com aumento da amostra.

Picos acentuados = maior precisão na estimação

## Exemplo – Distribuição Normal

- Seja X uma variável aleatória normal

- √ Função de probabilidade:

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

- √ Situações de estimação dos parâmetros:

- $\mu$  é desconhecido e  $\sigma^2$  é conhecido
- $\mu$  e  $\sigma^2$  são desconhecidos

- Função de verossimilhança da amostra

- √  $\mu$  desconhecida e  $\sigma^2$  conhecido

$$\begin{aligned} L(\mu; \sigma^2, \mathbf{x}) &= \prod_{i=1}^n \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_i-\mu}{\sigma}\right)^2} \\ &= \frac{1}{(2\pi\sigma^2)^{\frac{n}{2}}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i-\mu)^2} \end{aligned}$$

- Função de log-verossimilhança

$$l(\mu; \sigma^2, \mathbf{x}) = -\frac{n}{2} \ln(2\pi\sigma^2) - (2\sigma^2)^{-1} \sum_{i=1}^n (x_i - \mu)^2$$

- Derivada da função de log-verossimilhança:

$$l'(\mu; \sigma^2, \mathbf{x}) = \frac{\partial}{\partial \mu} l(\mu; \sigma^2, \mathbf{x}) = -(2\sigma^2)^{-1}(-2) \sum_{i=1}^n (x_i - \mu)$$

$$= -(\sigma^2)^{-1} \sum_{i=1}^n (x_i - \mu)$$

- Estimativa de máxima verossimilhança da amostra  $\mathbf{x}$ :

$$l'(\hat{\mu}; \sigma^2, \mathbf{x}) = (\sigma^2)^{-1} \sum_{i=1}^n (x_i - \hat{\mu}) = 0 \quad \hat{\mu} = \frac{\sum_{i=1}^n x_i}{n}$$

- Estimador de máxima verossimilhança da média verdadeira para amostras normais

$$\hat{\mu} = \bar{X}$$

- Função de verossimilhança da amostra  
 $\mu$  e  $\sigma^2$  desconhecidos

$$L(\mu, \sigma^2; \mathbf{x}) = \prod_{i=1}^n \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_i - \mu}{\sigma}\right)^2}$$

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

- Função de log-verossimilhança

$$l(\mu, \sigma^2; \mathbf{x}) = -\frac{n}{2} \ln(2\pi\sigma^2) - (2\sigma^2)^{-1} \sum_{i=1}^n (x_i - \mu)^2$$

- Derivadas parciais da log-verossimilhança:

$$\frac{\partial}{\partial \mu} l(\mu, \sigma^2; \mathbf{x}) = -(2\sigma^2)^{-1}(-2) \sum_{i=1}^n (x_i - \mu)$$

$$= (\sigma^2)^{-1} \sum_{i=1}^n (x_i - \mu)$$

$$\frac{\partial}{\partial \sigma^2} l(\mu, \sigma^2; \mathbf{x}) = -\left(\frac{n}{2}\right) \frac{(2\pi)}{2\pi\sigma^2} + \frac{2}{(2\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2$$

$$= \frac{1}{2\sigma^2} \left[ -n + \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right]$$

- Estimativas de máxima verossimilhança da amostra  $\mathbf{x}$ :

$$\frac{\partial}{\partial \mu} l(\hat{\mu}, \hat{\sigma}^2; \mathbf{x}) = (\hat{\sigma}^2)^{-1} \sum_{i=1}^n (x_i - \hat{\mu}) = 0 \quad \hat{\mu} = \frac{\sum_{i=1}^n x_i}{n}$$

$$\frac{\partial}{\partial \sigma^2} l(\hat{\mu}, \hat{\sigma}^2; \mathbf{x}) = \frac{1}{2\hat{\sigma}^2} \left[ -n + \frac{1}{\hat{\sigma}^2} \sum_{i=1}^n (x_i - \hat{\mu})^2 \right] = 0$$

$$\hat{\sigma} = \frac{\sum_{i=1}^n (x_i - \hat{\mu})^2}{n}$$

- Estimador de máxima verossimilhança da média e variâncias verdadeiras para amostras normais

$$\hat{\mu} = \bar{X}$$

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}$$

- √ O EMV da variância amostral é viciado para a variância verdadeira

### Comentários

- Para usar a estimação de máxima verossimilhança, a distribuição da população tem de ser conhecida ou suposta
- Em geral, o método da máxima verossimilhança produz estimadores com boas propriedades estatísticas
  - √ Têm boas propriedades assintóticas dos estimadores
  - √ (são consistentes e assintoticamente eficientes)

### Estimador de Máxima Verossimilhança - Propriedades

- Sob condições gerais e não-restritivas, quando uma amostra de tamanho  $n$  for grande e se  $\hat{\theta}$  for um EMV do parâmetro  $\theta$ , então:
  - √  $\hat{\theta}$  é um estimador consistente
    - Assintoticamente não viciado
  - √ A variância de  $\hat{\theta}$  é assintoticamente eficiente
  - √  $\theta$  tem distribuição assintoticamente normal

### Propriedade da Invariância

- Seja  $\hat{\theta}$  um estimador de máxima verossimilhança de  $\theta$ .
  - √ Então o EMV de qualquer função  $h(\theta)$  desse parâmetro é a mesma função  $h(\hat{\theta})$  do estimador  $\hat{\theta}$
- No caso da distribuição normal
  - √ O EMV de  $\sigma$  é  $\hat{\sigma} = \sqrt{\hat{\sigma}^2} = \left[ \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n} \right]^{1/2}$
  - √ O EMV de  $\sigma$  não é o desvio-padrão amostral  $S$

### Complicações no Uso da Estimação de Máxima Verossimilhança

- Nem sempre é simples maximizar a função de verossimilhança
- Pode não ser possível utilizar diretamente métodos de cálculo para determinar o máximo de  $L(\theta; \mathbf{x})$

### Exemplo – Distribuição Gama

- Seja  $X$  uma variável aleatória exponencial
- √ Função de densidade de probabilidade:

$$f(x; r, \lambda) = \begin{cases} \frac{\lambda^r x^{r-1}}{\Gamma(r)} e^{-\lambda x} & , x > 0 \\ 0 & , \text{ caso contrário} \end{cases}$$

$r$  e  $\lambda$  são os parâmetros desconhecidos a serem estimados

√ Função gama:  $\Gamma(r) = \int_0^{\infty} y^{r-1} e^{-y} dy$

- Função de verossimilhança da amostra

$$\begin{aligned} L(\lambda, r; \mathbf{x}) &= \frac{\lambda^r x_1^{r-1}}{\Gamma(r)} e^{-\lambda x_1} \frac{\lambda^r x_2^{r-1}}{\Gamma(r)} e^{-\lambda x_2} \dots \frac{\lambda^r x_n^{r-1}}{\Gamma(r)} e^{-\lambda x_n} \\ &= \prod_{i=1}^n \frac{\lambda^r x_i^{r-1}}{\Gamma(r)} e^{-\lambda x_i} \\ &= \left( \frac{\lambda^r}{\Gamma(r)} \right)^n e^{-\lambda \sum_{i=1}^n x_i} \left( \prod_{i=1}^n x_i \right)^{r-1} \end{aligned}$$

- Função de log-verossimilhança

$$l(\lambda, r; \mathbf{x}) = nr \ln(\lambda) - n \ln(\Gamma(r)) + (r-1) \sum_{i=1}^n \ln(x_i) - \lambda \sum_{i=1}^n x_i$$

- Derivadas da função de log-verossimilhança:

$$\frac{\partial}{\partial \lambda} l(\lambda, r; \mathbf{x}) = \frac{nr}{\lambda} - \sum_{i=1}^n x_i$$

$$\frac{\partial}{\partial r} l(\lambda, r; \mathbf{x}) = n \ln(\lambda) + \sum_{i=1}^n \ln(x_i) - \frac{n\Gamma'(r)}{\Gamma(r)}$$

- Estimativa de máxima verossimilhança da amostra  $\mathbf{x}$ :

$$\frac{n\hat{r}}{\hat{\lambda}} - \sum_{i=1}^n x_i = 0 \quad \hat{\lambda} = \frac{n\hat{r}}{\sum_{i=1}^n x_i} = \frac{\hat{r}}{\bar{x}}$$

$$n \ln(\hat{\lambda}) + \sum_{i=1}^n \ln(x_i) = \frac{n\Gamma'(\hat{r})}{\Gamma(\hat{r})}$$

√ Não há solução exata para essas equações

## Aplicação

- Método Lincoln-Peterson de Marcação e Recaptura
  - √ Objetivo: estimar tamanho de população de animais
  - √ Variáveis:
    - t: número de animais capturados e marcados
    - k: número de animais recapturados
    - r: número de animais marcados que são recapturados
    - N: população total (desconhecida)
  - √ Os valores t e k são fixos (não são aleatórios)
    - São determinados no planejamento do estudo
  - √ r: observação amostral (pode variar)

- Função de verossimilhança da amostra

$$L(N; r) = \frac{\binom{t}{r} \binom{N-t}{k-r}}{\binom{N}{k}}$$

- O espaço paramétrico são os inteiros positivos
  - √ Não se pode usar Cálculo
- Razão de verossimilhança para sucessivos valores da população total

$$\frac{L(N; r)}{L(N-1; r)}$$

- √ N é mais provável que N-1 quando a razão > 1

- Desenvolvimento razão de verossimilhanças:

$$\begin{aligned} \frac{L(N; r)}{L(N-1; r)} &= \frac{\frac{\binom{t}{r} \binom{N-t}{k-r}}{\binom{N}{k}}}{\frac{\binom{t}{r} \binom{N-t-1}{k-r}}{\binom{N-1}{k}}} = \frac{\binom{N-t}{k-r} \binom{N-1}{k}}{\binom{N-t-1}{k-r} \binom{N}{k}} \\ &= \frac{\frac{(N-t)!}{(k-r)! (N-t-k+r)!} \frac{(N-1)!}{k! (N-1-k)!}}{\frac{(N-t-1)!}{(k-r)! (N-t-1-k+r)!} \frac{N!}{k! (N-k)!}} \\ &= \frac{(N-t)(N-k)}{N(N-t-k+r)} \end{aligned}$$

- Determinação máximo:

$$\begin{aligned} \frac{L(N; r)}{L(N-1; r)} > 1 &\Leftrightarrow (N-t)(N-k) > N(N-t-k+r) \\ N^2 - tN - kN + tk &> N^2 - tN - kN + rN \\ tk > rN &\Rightarrow \frac{tk}{r} > N \end{aligned}$$

- √ Seja [x]: parte inteira de x

$$\begin{cases} L(N; r) > L(N-1; r) & , \text{ para } N < \left[ \frac{tk}{r} \right] \\ L(N; r) \leq L(N-1; r) & , \text{ para } N \geq \left[ \frac{tk}{r} \right] \end{cases}$$


- √ Isso nos dá o EMV de N:

$$\hat{N} = \left[ \frac{tk}{r} \right]$$

### Exemplo

- **Objetivo:**
  - √ Estimar população de peixes
- **Procedimento:**
  - √ São marcados  $t = 200$  peixes
  - √ Peixes são devolvidos ao habitat
  - √ Aguarda-se que os peixes devolvidos misturem-se à população
  - √ São recapturados  $k = 400$  peixes
  - √ Dos peixes recapturados, há  $r = 43$  peixes marcados
- **Obs.** Dados obtidos em simulação com  $N=2000$

Função de Verossimilhança para Captura e Recaptura



$$\hat{N} = \left[ \frac{(200)(400)}{43} \right] = 1860$$

- √ População estimada: 1.860 peixes
- √ População real: 2000 (na prática, desconhecido)

### Referências

### Bibliografia Recomendada

- Montgomery, D. C. (LTC)  
*Estatística Aplicada e Probabilidade para Engenheiros*
- Pinheiro, J. I. D et al. (Campus)  
*Probabilidade e Estatística: Quantificando a Incerteza*