

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 ?

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

Estatística Aplicada à Engenharia

10

Inferência Estatística

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

Estatística Aplicada à Engenharia

11

Estimção de Parâmetros

- Estimção Pontual
- Estimção Intervalar
 - √ Intervalos de Confiança

Estatística Aplicada à Engenharia

12

Teste de Hipóteses

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

Estatística Aplicada à Engenharia

13

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 (μ)
- Desvio-padrão de uma população (σ)

√ Representadas por letras gregas

√ Notação para estimador qualquer: θ

- Estatística:

√ Qualquer função da amostra que não dependa de parâmetros desconhecidos

√ Exemplo : Algumas estatísticas da amostra aleatória X_1, X_2, \dots, X_n :

$$X_{(1)} = \min(X_1, X_2, \dots, X_n)$$

$$X_{(n)} = \max(X_1, X_2, \dots, X_n)$$

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

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

- Distribuição amostral:

√ Distribuição de probabilidades de uma estatística

√ Exemplo:

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

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

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

- Estimador de θ

- √ Qualquer estatística que assuma valores em Θ .

- √ Notação: $\hat{\theta}$

- √ Exemplo:

- Alguns estimadores para a média μ 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 μ e variância finita σ^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



27


Exemplo – Simulação

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

Estatística Aplicada à Engenharia


28

- Amostra n=1



29

- Amostras de tamanhos 2, 4, 10 e 20



31

Comparação de Populações

- Considere duas populações:
 - √ População 1: média μ_1 e variância σ_1^2
 - √ População 2: média μ_2 e variância σ_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

Estatística Aplicada à Engenharia

32

- 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:

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

Estatística Aplicada à Engenharia

33

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

Estatística Aplicada à Engenharia

34

Distribuição Amostral Aproximada de Diferença de Médias Amostrais

- Suponha:

√ Duas populações independentes, com médias μ_1 e μ_2 e variâncias σ_1^2 e σ_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

Estatística Aplicada à Engenharia

35

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 médias amostrais seja no mínimo 25 horas?

Estatística Aplicada à Engenharia

36

Estimação Pontual – Conceitos

Propriedades de um Estimador

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

Estatística Aplicada à Engenharia

38

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 θ se $E[\hat{\theta}] = \theta$
- A esperança de um estimador está relacionada com sua **exatidão**

Estatística Aplicada à Engenharia

39

• Exemplos:

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

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

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

$$E(X_1) = \mu_X$$


• A variância amostral é não viesada para estimar a variância populacional (σ^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-viesados de θ

√ 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 θ

Estimador de Variância Mínima

• Se considerarmos todos os estimadores não-tendenciosos de θ , aquele com a menor variância será chamado de **estimador não-tendencioso de variância mínima**

√ Esse estimador é o mais provável, dentre todos os não-viesados, 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 σ , mas substituímos 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 θ 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 θ :
 - √ Tem EQM menor ou igual ao EQM de qualquer outro estimador, para todos os valores de θ
 - √ Estimadores ótimos raramente existem

EQM de Estimadores Não-viciados

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

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

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