

INFERÊNCIA ESTATÍSTICA

100

* NA PRÁTICA, A FAMÍLIA DA DISTRIBUIÇÃO DE PROBABILIDADES ASSOCIADA A UM DADO SISTEMA, E/OU OS SEUS PARÂMETROS, DEVEM SER ESTIMADAS A PARTIR DA OPERAÇÃO DO SISTEMA

=> É PRECISO REALIZAR INFERÊNCIAS BASEADAS EM DADOS

COLEÇÃO DE TODOS OS DADOS DISPONÍVEIS = POPULAÇÃO

QUALQUER SUBCONJUNTO DOS DADOS = AMOSTRA

OBS.: i) A AMOSTRA DEVE SER REPRESENTATIVA DA POPULAÇÃO

=> POSSUIR PROPRIEDADES SEMELHANTES ÀS QUE SERIAM OBSERVADAS NA POPULAÇÃO

ii) QUANDO O TAMANHO DA AMOSTRA CRESCE, A ESTIMATIVA SE APROXIMA DO VALOR VERDADEIRO

iii) DIFERENTES AMOSTRAS EM GERAL RESULTAM EM DIFERENTES ESTIMATIVAS

=> AS ESTIMATIVAS SEGUEM UMA DISTRIBUIÇÃO ESTATÍSTICA: A DISTRIBUIÇÃO AMOSTRAL

* POSSÍVEIS QUESTÕES DE INTERESSE:

i) SE A FORMA DA DISTRIBUIÇÃO É CONHECIDA, OS SEUS PARÂMETROS PODERÃO SER ESTIMADOS.

ii) SE A DISTRIBUIÇÃO NÃO É CONHECIDA, PODE-SE TESTAR A SUA APROXIMAÇÃO POR DIVERSAS FAMÍLIAS DE DISTRIBUIÇÃO

iii) PODEM-SE TESTAR HIPÓTESES SOBRE A DISTRIBUIÇÃO
e.g., SE SUA MÉDIA SE ENCONTRA EM CERTO INTERVALO

AQUI SÓ ESTAREMOS INTERESSADOS EM i)

* ESTIMAÇÃO DE PARÂMETROS:

\Rightarrow Supomos que a distribuição da população é conhecida, exceto pelo valor de algum parâmetro θ

ex. g., $\theta \equiv$ média da população ($E[X]$)

$\theta \equiv$ variância da população ($\text{Var}[X]$)

\Rightarrow Podemos estimar θ com base num conjunto de n resultados experimentais, $\{x_1, x_2, \dots, x_n\}$, onde cada valor x_i é uma amostra da v.a. X_i

- DEFINIÇÕES:

AMOSTRA ALEATÓRIA: O conjunto $\{x_1, x_2, \dots, x_n\}$ constitui uma amostra aleatória de uma população com distribuição $F(x)$, se os X_i são mutuamente independentes e identicamente distribuídos com função distribuição

$$F_{X_i}(x) = F(x), \quad \forall i, x$$

ESTATÍSTICA: Qualquer função real, $W(x_1, x_2, \dots, x_n)$, das observações

\Rightarrow Uma estatística é uma v.a., e sua função distribuição é chamada DISTRIBUIÇÃO AMOSTRAL DA ESTATÍSTICA

ex. g., MÉDIA AMOSTRAL

VARIÂNCIA AMOSTRAL

ESTIMADOR: QUALQUER ESTATÍSTICA USADA PARA ESTIMAR O VALOR DE UM PARÂMETRO θ DA POPULAÇÃO

e.g., $\hat{\theta} = \hat{\theta}(x_1, x_2, \dots, x_n)$

\Rightarrow O VALOR OBSERVADO $\hat{\theta} = \hat{\theta}(x_1, x_2, \dots, x_n)$ É UMA ESTIMATIVA DO θ

ESTIMADORES POINTAIS: RETORNAM UM SÓ VALOR

ESTIMADORES INTERVALAIS: RETORNAM UM INTERVALO DE VALORES

ESTIMADOR NÃO-TENDENCIOSO: $\hat{\theta} = \hat{\theta}(x_1, x_2, \dots, x_n)$ CONSTITUI UM ESTIMADOR NÃO-TENDENCIOSO DO PARÂMETRO θ , SE

$$E[\hat{\theta}(x_1, x_2, \dots, x_n)] = \theta$$

\Rightarrow O VALOR ESPERADO DO ESTIMADOR É IGUAL AO PARÂMETRO

\Rightarrow DAI RESULTA QUE O SEU ERRO QUADRÁTICO MÉDIO É IGUAL À SUA VARIÂNCIA: $E[(\hat{\theta} - \theta)^2] = \text{VAR}[\hat{\theta}]$

EFICIÊNCIA: O ESTIMADOR $\hat{\theta}_1$ É MAIS EFICIENTE QUE O ESTIMADOR $\hat{\theta}_2$, SE

i) $\hat{\theta}_1$ E $\hat{\theta}_2$ SÃO AMBOS ESTIMADORES NÃO-TENDENCIOSOS DO θ .

ii) $\text{VAR}[\hat{\theta}_1] \leq \text{VAR}[\hat{\theta}_2]$, $\forall \theta$

iii) $\exists \theta$, TAL QUE $\text{VAR}[\hat{\theta}_1] < \text{VAR}[\hat{\theta}_2]$

CONSISTÊNCIA: O ESTIMADOR $\hat{\theta}$ DO PARÂMETRO θ É DITO CONSISTENTE, SE $\hat{\theta}$ CONVERGE EM PROBABILIDADE PARA θ :

$$\lim_{n \rightarrow \infty} P_r[|\hat{\theta} - \theta| \geq \epsilon] = 0$$

\Rightarrow QUANTO O TAMANHO DA AMOSTRA CRESCE, UM ESTIMADOR CONSISTENTE SE APROXIMA DO VALOR REAL.

OBS.: Pela DESIGUALDADE DE CHEBYSHEV, QUALQUER ESTIMADOR NÃO-TENDENCIOSO $\hat{\theta}$, COM A PROPRIEDADE

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

É UM ESTIMADOR CONSISTENTE DE θ .

FUNÇÃO DE DISTRIBUIÇÃO EMPÍRICA: SE k_x É O NÚMERO DE VALORES OBSERVADOS x_i QUE SÃO MENORES OU IGUAIS A x , EM n OBSERVAÇÕES, DEFINI-SE A F.D.E. COMO

$$\hat{F}(x) = \frac{k_x}{n}$$

OBS.: A F.D.E. É UM ESTIMADOR CONSISTENTE DA FUNÇÃO DISTRIBUIÇÃO REAL DA POPULAÇÃO.

- Métodos para estimação de parâmetros:

* Método dos momentos:

Definição: k -ésimo momento amostral da V.A. X :

$$\mu_k = \sum_{i=1}^n \frac{X_i^k}{n}, \quad k=1, 2, \dots$$

onde X_i é a i -ésima observação

\Rightarrow O método dos momentos iguala os primeiros momentos amostrais aos correspondentes primeiros momentos da população sob a suposta função de densidade:

$$\mu_k = E[X^k], \quad k=1, 2, \dots$$

Assim, obtêm-se tantas equações quantos são os parâmetros desconhecidos.

Obs.: A solução simultânea das eqs. em geral fornece estimativas consistentes, mas às vezes temperais e ineficientes.

* Método da máxima verossimilhança:

\Rightarrow Escolher como estimativa de θ o valor para o qual a amostra observada seria a 'mais provável' de ocorrer

Definição: Sejam X_1, \dots, X_n uma amostra aleatória da V.A. X , e sejam x_1, \dots, x_n os valores amostrais.

Definimos a função de verossimilhança como

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

onde $f(x_i; \theta)$ é a função de densidade da V.A. X_i , discreta ou contínua, com a dependência no parâmetro θ explícita.

\Rightarrow A Função de Verossimilhança Representa a Função de Densidade Conjunta da Amostra.

Mantendo Fixos os valores observados x_1, \dots, x_n ,

$L(\theta) \equiv L(x_1, \dots, x_n; \theta)$ será Função Apenas do parâmetro θ .

\Rightarrow A Estimativa de Máxima Verossimilhança é o valor $\hat{\theta}$ que maximiza a Função $L(\theta)$.

$\Rightarrow \hat{\theta}$ é o valor 'mais provável' para θ , à luz das observações.

Definição: Para obter o estimador de M.V., resolvemos a Equação de Verossimilhança:

$$\frac{\partial \ln L(x_1, \dots, x_n; \theta)}{\partial \theta} = 0$$

Onde o logaritmo é escolhido por ser uma função crescente de L , e mais suave do que esta.

Obs. i) No caso de haver mais de um parâmetro a estimar $\underline{\theta} = (\theta_1, \dots, \theta_k)$, obtemos um sistema de equações simultâneas:

$$\frac{\partial \ln L(\underline{\theta})}{\partial \theta_i} = 0, \quad i = 1, 2, \dots, k$$

Possíveis dificuldades: Múltiplas Soluções Encontradas

\Rightarrow Múltiplas Múltiplas

Solução Não-Única

\Rightarrow Análise das Soluções

Solução Fora do Domínio dos Parâmetros

\Rightarrow Maximização Condicional

ii) O método de M.V. em geral produz estimadores consistentes, mas que podem ser temperamentais, para pequenas amostras.

* ANÁLISE DE REGRESSÃO

109

\Rightarrow ESTIMAR UMA V.A. INACESSÍVEL, Y , DADAS OBSERVAÇÕES DA V.A. ACESSÍVEL, X .

\Rightarrow ENCONTRAR UMA CURVA DE REGRESSÃO QUE DESCREVA COMO Y DEPENDE DE X (REGRESSÃO DE Y EM X).

ABOLUÇÃO: DETERMINAR UMA FUNÇÃO $d(x)$ TAL QUE ELA SEJA TÃO PRÓXIMA DE Y QUANTO POSSÍVEL.

$\Rightarrow d(x)$ SERÁ USADA PARA PREVER O VALOR DE Y , QUANDO X É CONHECIDA.

- REGRESSÃO DE MÍNIMOS QUADRADOS:

$\Rightarrow d(x)$ DEVE MINIMIZAR O VALOR ESPERADO DO ERRO QUADRÁTICO: $E[D^2]$

ONDE $D = Y - d(x)$

\Rightarrow MINIMIZAÇÃO DO ERRO MÉDIO QUADRÁTICO

OBSERVAÇÕES:

i) SE A MINIMIZAÇÃO É SEM RESTRIÇÕES

$$d(x) = E[Y|X] = \int_{-\infty}^{\infty} y f(y|x) dy$$


\equiv ESPERANÇA CONDICIONAL

MAS COMO DENSIDADES CONDICIONAIS SÃO DIFÍCIS DE OBTEN, EM GERAL RESTRINGE-SE A ESCOLHA DE $d(x)$ A CLASSES ESPECÍFICAS DE FUNÇÕES

e.g., LINEARES OU QUADRÁTICAS

ii) Em geral, a classe de funções pode ser determinada a partir da análise dos dados

e.g., Diagrama de dispersão



- REGRESSÃO LINEAR:

\Rightarrow ASSUMINDO QUE A FORMA

$$d(x) = a + bx$$

É SATISFATÓRIA

\Rightarrow OBTENDO OS PARÂMETROS a E b , PELA MINIMIZAÇÃO DO ERRO

$$C(a, b) \equiv E[d^2] = E[(Y - a - bx)^2]$$

SEMO

$$\mu_x = E[X], \mu_y = E[Y]$$

PODEMOS ESCREVER

$$C(a, b) = E[(Y - \mu_y) + (\mu_y - a) - b(X - \mu_x) - b\mu_x]^2]$$

\Rightarrow DESDE QUE O OBRIGADO, USANDO

$$E[(Y - \mu_y)] = E[(X - \mu_x)] = 0$$

É DEFININDO

$$\sigma_x^2 = \text{Var}[X]$$

$$\sigma_y^2 = \text{Var}[Y]$$

$$\rho = \frac{\text{COV}(X, Y)}{\sigma_x \sigma_y} \equiv \text{COEFICIENTE DE CORRELACÃO}$$

$$C(a, b) = \sigma_y^2 + b^2 \sigma_x^2 + (\mu_y - a - b\mu_x)^2 - 2b\rho\sigma_x\sigma_y$$

\Rightarrow Para obter o mínimo:

$$\frac{\partial C}{\partial a} = -2(\mu_y - a - b\mu_x) = 0$$

$$\frac{\partial C}{\partial b} = 2b\sigma_x^2 - 2\mu_x(\mu_y - a - b\mu_x) - 2\rho\sigma_x\sigma_y = 0$$

\Rightarrow Sistema Linear:

$$\begin{cases} a + \mu_x b = \mu_y \\ \mu_x a + (\sigma_x^2 + \mu_x^2) b = \rho\sigma_x\sigma_y + \mu_x\mu_y \end{cases}$$

\Rightarrow Solução:

$$b = \rho \frac{\sigma_y}{\sigma_x}, \quad a = \mu_y - \rho \frac{\sigma_y}{\sigma_x} \mu_x$$

\Rightarrow A curva de regressão linear

$$y = a + bx$$

Podem ser escrita como

$$\left(\frac{y - \mu_y}{\sigma_y} \right) = \rho \left(\frac{x - \mu_x}{\sigma_x} \right) \quad \left(\text{RETA DE REGRESSÃO DE } y \text{ em } x \right)$$

- DE FORMA SEMELHANTE, A RETA DE REGRESSÃO DE X em Y

Podem ser obtida como

$$\left(\frac{x - \mu_x}{\sigma_x} \right) = \rho \left(\frac{y - \mu_y}{\sigma_y} \right)$$

i) O MÍNIMO ERRO DE PREVISÃO, PARA A REGRESSÃO LINEAR, É DADO POR

$$E[D^2] = C\left(\mu_Y - \rho \frac{\sigma_Y}{\sigma_X} \mu_X, \rho \frac{\sigma_Y}{\sigma_X}\right) = (1 - \rho^2) \sigma_Y^2$$

\Rightarrow QUANDO $\rho = \pm 1$, O MODELO LINEAR É EXATO

i.e., X E Y TÊM UMA RELAÇÃO FUNCIONAL

\Rightarrow SÃO TOTALMENTE DEPENDENTES

ii) O MODELO LINEAR TAMBÉM É EXATO QUANDO X E Y TÊM UMA DISTRIBUIÇÃO CONJUNTA NORMAL

iii) SE $\rho = 0$, X E Y SÃO DESCORRELACIONADAS, E AS RETAS DE REGRESSÃO DE Y EM X E DE X EM Y SÃO ORTOGONAIS

$$y = \mu_Y, \quad x = \mu_X$$

iv) ρ É APENAS UM INDICADOR DE INDEPENDÊNCIA LINEAR:

SE X E Y SÃO INDEPENDENTES, $\rho = 0$, MAS

NÃO VICE-VERSA NECESSARIAMENTE

* APENAS QUANDO X E Y TÊM DISTRIBUIÇÃO CONJUNTA NORMAL, $\rho = 0$ IMPLICA NA INDEPENDÊNCIA DAS DUAS VARIÁVEIS.

v) QUANDO $\rho^2 \neq 1$, PODAMOS ESCREVER

$$\sigma_Y^2 = \rho^2 \sigma_Y^2 + E[D^2]$$

$\Rightarrow \rho^2 \sigma_Y^2$ É A VARIÂNCIA DE Y QUE PODE SER ATRIBUÍDA A UMA DEPENDÊNCIA LINEAR DE X

$E[D^2] = (1 - \rho^2) \sigma_Y^2$ É A VARIÂNCIA RESIDUAL