

Vantagens e Desvantagens dos Métodos Não Paramétricos

Vantagens

- Não é necessário fazer suposições sobre a distribuição de probabilidades da variável de interesse na população.
- Podem ser aplicados a dados que não são exatos do ponto de vista numérico, mas que se disponham em uma escala ordinal. Existem técnicas para dados em escala nominal.
- Simplicidade nos cálculos.
- Aplicabilidade a pequenas amostras. (Muitas vezes, as amostras são pequenas pela própria natureza da variável).

Desvantagens

- Se aplicarmos um teste não paramétrico na situação em que é possível um teste paramétrico, teremos uma perda de eficiência (o correspondente teste paramétrico é mais poderoso)

2

- Não existem testes não paramétricos para alguns problemas para os quais existe um teste paramétrico.

Escala de Medidas

Nominal - quando as medidas servem apenas para classificar os elementos em classes ou categorias, não existindo uma ordenação entre essas categorias.

Ex: Sexo, Cor de Olhos.

Ordinal (ou escala por postos) - quando existir uma ordenação natural entre os elementos de diferentes categorias. O valor numérico da medida (case exista) serve apenas como meio de ordenar as categorias.

Ex: Classe Social

Classificações do IBGE

A	B	C	D	E
↓				↓
+ 20 salários mínimos mensais				2 ou menos salários mínimos mensais

Intervalar - além da medida representar uma ordenação, como na escala ordinal, consegue-se dimensionar a magnitude da diferença entre dois elementos.

Exige um ponto zero (origem) e uma unidade de medida, que são no entanto arbitrários.

Ex: Temperatura

Escala: graus centígrados

Unidade: °C

Origem: 0° ou

Escala: Graus Fahrenheit

Unidade: °F

Origem: 32°F

Relação: $F = \frac{9}{5} C + 32$

Razão - quando a escala possuir todas as características da intervalar, com a exceção de que admite um verdadeiro ponto zero. (o zero corresponde à inexistência da quantidade a ser medida).

Ex: Peso ; em Kg

Unidade Kg

Origem: 0

em gramas

Unidade gr

Origem: 0

Peso em gramas = 1000. Peso em Kg

Escala de Temperatura Kelvin é do tipo razão porque o zero corresponde à inexistência de energia. Também é denominada escala de temperaturas absoluta.


As estatísticas a serem calculadas e os testes a serem utilizados dependem do tipo de medida que foi tomada.

Escala	Estatísticas	Testes	
nominal	Moda	não para- métricos	
ordinal	Mediana Percentis r_s (Spearman) τ (Kendall)		
intervalar	Média Desvio Padrão Correlações de Pearson		Paramétricos e não paramétricos
razões	Média Geométrica Coeficiente de Variação ($\frac{DP}{m\u00e9dia}$)		

maioria dos métodos paramétricos - escala pelo menos intervalar

Função Distribuição Empírica

X v.a., $F(x) = P(X \leq x) \rightarrow$ função distribuição acumulada



Exemplo

Amostra: X_1, X_2, \dots, X_n

$F_n(x) =$ proporção dos X_i menores ou iguais a x , $-\infty < x < \infty$


$F_n(x) \rightarrow$ f. d. empírica da amostra

$F_n(x)$ é um estimador de $F(x)$.

Exemplo

$X_1 = 6,23$ $X_2 = 5,58$ $X_3 = 7,06$ $X_4 = 6,42$ $X_5 = 5,20$

$$F_n(x) = \begin{cases} 0 & , \quad x < 5,2 \\ 1/5 & , \quad 5,2 \leq x < 5,58 \\ 2/5 & , \quad 5,58 \leq x < 6,23 \\ 3/5 & , \quad 6,23 \leq x < 6,42 \\ 4/5 & , \quad 6,42 \leq x < 7,06 \\ 1 & , \quad x \geq 7,06 \end{cases}$$



c) Quantis

da v. aleatório X

O quantil de ordem p ($0 \leq p \leq 1$) de uma dist. de probab. é um número x_p tal que

$$P(X < x_p) \leq p \quad P(X > x_p) \leq 1 - p$$

$p = \text{prob} \{ X < x_p \}$
 x_p valor de X

↳ área a esquerda de x_p é no máximo p , mas se for muito menor que p , a área à direita de x_p será maior que $1 - p$.


$p = 0,5 \Rightarrow x_p$ é a mediana

$p = 0,75, p = 0,25 \Rightarrow 3^\circ$ e 1° quartis

$p = 0,4 \Rightarrow (x_p \text{ é o } 40^\circ \text{ percentil de ordem } 40\%)$

Obs: Caso mais do que um valor satisfça a definição de quantil, $x_p =$ média entre o maior e o menor valor satisf. à def.

Ex: X v.a. contínua com densidade $f(x)$



por que não x_p ?

$$P(X < x_0) \leq p$$


$$P(X > x_0) > 1-p$$

Ex: X v.a. discretas com dist. de Prob:

$$P(X=0) = 1/4 = P(X=1)$$

$$P(X=2) = 1/3$$

$$P(X=3) = 1/6$$



$$P(X < x_p) \leq p$$

$$P(X > x_p) \leq 1-p$$

$$x_{0,75} = 2$$

$$P(X < 2) = 0,5$$

$$1-p = 1 - 0,75 = 0,25$$

$$P(X > 2) = 1/6 < 0,25$$

Poderia ser 1,9?

$$P(X < 1,9) = 0,5 < 0,75 \quad | \quad P(X > 1,9) = \frac{1}{3} + \frac{1}{6} = 0,5 > 0,25$$

ser 2,1?

$$P(X < 2,1) = 0,5 + \frac{1}{3} = \frac{5}{6} > 0,75 > 0,25$$

$$x_{0,5} = 1,5$$

$$\left\{ \begin{array}{l} P(X < 1) = \frac{1}{4} \leq 0,5 \\ P(X > 1) = 0,5 \leq 1 - 0,5 \end{array} \right.$$

$$\left\{ \begin{array}{l} P(X < 2) = 0,5 \leq 0,5 \\ P(X > 2) = \frac{1}{6} \leq 0,5 \end{array} \right.$$

$$P(X < 1,3) = 0,5 \leq 0,5$$

$$P(X > 1,3) = 0,5 \leq 0,5$$

$x_{0,5} \in [1, 2]$ Verificar que é somente este intervalo

$$\therefore x_{0,5} = 1,5$$

d) Quantis amostrais

da v. a. X

Sejam X_1, X_2, \dots, X_n uma amostra aleatória. O quantil amostral de ordem p é o valor Q_p tal que a proporção dos X_i menores que Q_p é $\leq p$ e a prop. dos X_i maiores que Q_p é $\leq 1-p$.

$$Q_p \text{ é } \leq 1-p.$$

$x_p \rightarrow$ parâmetro

$$Q_p = \hat{x}_p$$

Procedimentos não Paramétricos - Definição

10

(Conover - pag 118)

Um método estatístico é não paramétrico se satisfaz no mínimo a um dos seguintes critérios:

- 1 - O método pode ser usado em dados em uma escala nominal.
- 2 - O método pode ser usado para dados em uma escala ordinal.
- 3 - O método pode ser usado em dados em escala intervalar ou razão, quando a distribuição da variável aleatória que produziu os dados não foi especificada, ou foi especificada exceto para um n^o infinito de parâmetros desconhecidos.

Leitura: Conover

Pag 114 - seção 2.5 até Asymptotically Distribution-Free. inclusive (pag 117)

Pag 85 - Desde "An Approximate Confidence Interval" até Computer Assistance (pag 88)

2 - Testes baseados na Distribuição Binomial ¹¹

2.1 - Inferência para a proporção p .

Dados: Amostra de tamanho n consistindo dos resultados de n repetições independentes de um experimento (ensaios de Bernoulli). Cada resultado é classificado em uma de duas categorias mutuamente exclusivas: categoria 1 ou categoria 2.

T - número de resultados pertencentes à categoria 1

$n - T$ - número de resultados pertencentes à categoria 2

Suposições:

- Os n ensaios são independentes.
- Cada um deles tem probabilidade p de resultar categoria 1, p constante nas n ensaios.

A v.a. T tem distribuição binomial com parâmetros n e p .

$$T \sim B(n, p)$$

Se p é desconhecido, inferência sobre p .

Teste de Hipóteses

$$H_0: p = p^* \quad 0 \leq p^* \leq 1$$

$$H_a: p \neq p^*$$

Intervalo de Confiança para p

Amostra aleatória de tamanho n

$$\text{Estimador de } p: \hat{p} = \frac{T}{n}$$

$$E(\hat{p}) = E\left(\frac{T}{n}\right)$$

$$T \sim B(n, p) \quad E(T) = np \quad \text{Var}(T) = np(1-p)$$

$$\therefore E(\hat{p}) = \frac{np}{n} = p$$

$$\text{Var}(\hat{p}) = \frac{1}{n^2} \text{Var}(T) = \frac{np(1-p)}{n^2} = \frac{p(1-p)}{n}$$

1) Para n grande

$$\frac{T_{-np} \stackrel{(\div n)}{=} \frac{\frac{T}{n} - p}{\sqrt{\frac{p(1-p)}{n}}} = \frac{\hat{p} - p}{\sqrt{\frac{p(1-p)}{n}}} \approx N(0,1)$$

$$\xrightarrow{dO} N(0,1)$$

Fixado γ , coeficiente de confiança, obtemos z_γ tal que

$$P\left(-z_\gamma \leq \frac{\hat{p} - p}{\sqrt{\frac{p(1-p)}{n}}} \leq z_\gamma\right) = P(-z_\gamma \leq Z \leq z_\gamma) = \gamma$$

$$Z \sim N(0,1)$$

Intervalo de Confiança para p com coef. γ é

$$\left[\hat{p} - z_\gamma \sqrt{\frac{p(1-p)}{n}}, \hat{p} + z_\gamma \sqrt{\frac{p(1-p)}{n}} \right]$$

Como p é desconhecido:

a) Intervalo de Confiança Otimista

$$\left[\hat{p} - z \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} ; \hat{p} + z \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \right]$$

amplitude do intervalo: $L = 2z \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$

b) Intervalo de Confiança Conservador

Como $p(1-p) \leq \frac{1}{4}$

$$\left[\hat{p} - z \sqrt{\frac{1}{4n}} ; \hat{p} + z \sqrt{\frac{1}{4n}} \right]$$