

Técnicas Computacionais em Probabilidade e Estatística I

Aula I

Chang Chiann


MAE 5704- IME/USP

1º Sem/2008

Análise de Um conjunto de dados



- objetivo: tratamento de um conjunto de dados.
- uma amostra de uma população.
- uma variável aleatória (v.a.) X , cuja distribuição de probabilidade define a população.

Estatística



Estatística Descritiva

O que fazer com as observações
que coletamos?




Primeira Etapa:

Resumo dos dados = Estatística descritiva

Variável:

Qualquer característica associada a uma população.

Classificação das variáveis:



. Considere uma população com N indivíduos:

$$P = \{ 1, 2, \dots, N \}$$

. v.a. X definida sobre cada um desses indivíduos, com valores distintos $\{x_1, \dots, x_k\}$.

. $P_i = P(x_i) = P(X=x_i)$: a probabilidade de X assumir o valor x_i .

. Os pares (x_i, p_i) , $i=1, \dots, k$, constituem a distribuição de probabilidades de X .

A média e a variância de X :

$$\mu = E(X) = \sum x_i p_i$$

$$\sigma^2 = \text{Var}(X) = \sum (x_i - E(X))^2 p_i$$

(parâmetros populacionais)

Uma v.a. continua X é caracterizada por uma função densidade de probabilidade (f.d.p.) $f(x)$, tal que:

a) $f(x) \geq 0$, $\forall x$;

b) $\int f(x) dx = 1$.

A função $f(x)$ nos diz onde X tem maior “chance” de ocorrer.

Em geral, desconhecemos a distribuição de probabilidade de uma v.a. definida sobre uma população.

Problema Importante:

Formular modelos probabilísticos para variáveis que caracterizam determinadas populações.

Procedimentos:

- a) Colher uma amostra da população e definir a v.a. sobre os elementos da amostra, obter informações desejadas a partir dos valores amostrais e tentar inferir conclusões para a população toda. (inferência estatística).
- b) se pudemos supor que a dist. de prob. de uma v.a. X possa ser representada por uma dist. Particular \rightarrow estimar os parâmetros que caracteriza essa particular dist.

Alguns modelos de interesse prático:

- a) Bernoulli; Binomial;
- b) Poisson; Geométrica; Hipergeométrica;
- c) Uniforme; Exponencial;
- d) Normal; Gama; quiquadrado; t

Caso discreto: a função de probabilidade
 $p(x)=P(X=x)$

Caso contínuo: $f(x)$ f.d.p.

- Para gerar as probabilidades de $X \sim \text{Bin}(12; 0,25)$ usando Minitab:

> PDF;

> BINOMIAL 12 0.25.

-Para gerar as probabilidades de $Y \sim \text{Pois}(2,7)$ usando Minitab

> PDF;

> POISSON 2.7.

No MINITAB,

> pdf;

> bino 12 0,25.

Probability Density Function

Binomial with $n = 12$ and $p = 0,25$

x	P(X = x)
0	0,0317
1	0,1267
2	0,2323
3	0,2581
4	0,1936
5	0,1032
6	0,0401
7	0,0115
8	0,0024
9	0,0004
10	0,0000

Portanto,

$$P(X \geq 6) = 0,0544.$$

Temos que

$$E(X) = n \times p = 12 \times 0,25 = 3,$$

Amostra de UMA População

Sejam X_1, \dots, X_n : iid com $E(X_i)=E(X)$,
 $\text{Var}(X_i)=\text{Var}(X)$

x_1, \dots, x_n : os valores observados das v.a. X_1, \dots, X_n

$X_{(1)}, \dots, X_{(n)}$: os valores observados ordenados em ordem crescente, são os valores da estatística de ordem $X_{(1)}, \dots, X_{(n)}$.

Uma análise exploratória de dados(AED) procura responder a seguinte questão:

O que os dados da amostra nos dizem sobre a população da qual eles foram selecionados?

Algumas Questões interessantes:

- a) Quais são alguns valores atípicos da amostra?
- b) Qual é o valor que representa a posição central do conjunto de dados?
- c) Qual é a medida de variabilidade ou dispersão presente nos dados?
- d) Os dados podem ser considerados simétricos?

Uma primeira tarifa da AED:

Exibir os dados de maneira apropriada e para isso utilizamos alguns resumos:

- a) Dispositivos gráficos e tabelas;
- b) Medidas resumo (medidas de posição e dispersão).

Medidas de Posição e Dispersão

MEDIDAS DE POSIÇÃO:

Média, Mediana, Média aparada, Quantis

MEDIDAS DE DISPERSÃO:

Amplitude, Intervalo-Interquartil, Variância, o Desvio médio, Desvio Padrão, Desvio mediano absoluto, variância aparada Coeficiente de Variação.

•Média:

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n}$$

Dados: 2, 5, 3, 7, 8

$$\bar{x} = \frac{2 + 5 + 3 + 7 + 8}{5} = 5$$

- **Mediana:**

A mediana é o valor da variável que ocupa a **posição central** de um conjunto de n **dados ordenados**.

Posição da mediana: $\frac{n+1}{2}$

Exemplos:

Dados: 2, 6, 3, 7, 8 $\Rightarrow n = 5$ (ímpar)

Dados ordenados: 2 3 6 7 8 $\Rightarrow \frac{5+1}{2} = 3 \Rightarrow Md=6$

Posição da Mediana \uparrow

Dados: 4, 8, 2, 1, 9, 6 $\Rightarrow n = 6$ (par)

Dados ordenados: 1 2 4 6 8 9 $\Rightarrow \frac{6+1}{2} = 3,5$

\uparrow
Md

$$Md = (4 + 6) / 2 = 5$$

- **α -média aparada:**

Para $\alpha: 0 < \alpha < 1$, α -média aparada,

$$\bar{x}(\alpha)$$

é o valor obtido eliminando-se as $100^\alpha\%$ primeiras obs. E as $100^\alpha\%$ últimas obs. E tomando a média das obs. restantes.

Ex: obs.: 1,2,3,4,5,6,50,8,9,10

Média=9,8; mediana=5,5

media aparada a 20%=5,8

Ex: obs.: 1,2,3,4,5,6,50,8,9,10

Média=9,8; mediana=5,5

media aparada a 20%=5,8

-A média é bastante afetada pelo valor atípico 50, ao passo que a mediana e a média aparada a 20% não são.

-Essas duas últimas são medidas resistentes.

-**Medidas resistentes**: muda pouco se alterarmos um número pequeno dos dados.

P-quantil:

É um valor que deixa $100p\%$ das obs. à sua esquerda, com $0 < p < 1$. (definição informal)

Casos particulares:

percentil 50 = mediana ou segundo quartil (Md)

percentil 25 = primeiro quartil (Q_1)

percentil 75 = terceiro quartil (Q_3)

percentil 10 = primeiro decil

Dados: 1,9 2,0 2,1 2,5 3,0 3,1 3,3 3,7 6,1 7,7 $\Rightarrow n=10$

Posição de Md : $0,5(n+1) = 0,5 \times 11 = 5,5 \Rightarrow Md = (3 + 3,1)/2 = 3,05$

Posição de $Q1$: $0,25(11) = 2,75 \Rightarrow Q_1 = (2 + 2,1)/2 = 2,05$

Posição de $Q3$: $0,75(11) = 8,25 \Rightarrow Q_3 = (3,7 + 6,1)/2 = 4,9$

$$Md = 3,05$$

$$Q_1 = 2,05$$

$$Q_3 = 4,9$$

Dados: 0,9 1,0 1,7 2,9 3,1 5,3 5,5 12,2 12,9 14,0 33,6

$$\Rightarrow n=11$$

$$Md = 5,3$$

$$Q1 = 1,7$$

$$Q3 = 12,9$$

- um gráfico de quantis(p x $Q(p)$) é um auxiliar importante na análise de dados;
- se os valores forem aproximadamente **simétricos**, a inclinação na parte superior do gráfico deve ser aproximadamente igual à inclinação na parte inferior ;
- os cinco valores (os extremos e os quartis), $x_{(1)}$, Q_1 , Q_2 , Q_3 , $x_{(n)}$, são medidas de localização importantes para avaliarmos a **simetria** dos dados.

Simetria dos dados:

a) $Q_2 - x_{(1)} \approx x_{(n)} - Q_2$

b) $Q_2 - Q_1 \approx Q_3 - Q_2$

c) $Q_1 - x_{(1)} \approx x_{(n)} - Q_3$

d) $Q_2 - x_{(i)} \approx x_{(n+1-i)} - Q_2, i = 1, 2, \dots, [(n+1)/2]$

Assimetria à direita

a) $Q_d - Q_2 \geq Q_2 - Q_e,$

onde Q_d : quantis a direita da mediana,

Q_e : quantis à esquerda da mediana.


Gráfico de simetria (u_i x v_i)

$$u_i = Q_2 - X_{(i)}$$

$$v_i = X_{(n+1-i)} - Q_2$$

Se a distribuição dos dados for simétrica, os pontos (u_i, v_i) deverão estar ao longo da reta $u=v$.


Simetria




Distribuição Simétrica

As variáveis $(Y-c)$ e $-(Y-c)$ são identicamente distribuídas

$$F_{Y-c}(\cdot) = F_{-(Y-c)}(\cdot)$$



Assimetria à Direita



Assimetria à Esquerda

Coeficientes de Assimetria

- **Coeficiente de Bowley**

$$ASS_B = \frac{(Q_3 - Me) - (Me - Q_1)}{Q_3 - Q_1}$$

- **Coeficiente de Pearson**

$$ASS_P = \frac{3(\bar{Y} - Me)}{s}$$

$|Ass| < 0,15 \Rightarrow$ Grau de Assimetria pequeno

$|Ass| > 1 \Rightarrow$ Grau de Assimetria elevado

$0,15 < |Ass| < 1 \Rightarrow$ Grau de Assimetria moderado


- **Coeficiente de Fisher**

$$ASS_F = \frac{m_3}{s^3} = \frac{(\sum (Y_j - \bar{Y})^3) / n}{s^3}$$


Qual é o valor destes coeficientes para a Normal ?

Curtose


Grau de Achatamento da Distribuição
“Peso das Caudas”



Distribuição Leptocúrtica
“Cauda Leve”



Distribuição Mesocúrtica



Distribuição Platicúrtica
“Cauda Pesada”

Coeficiente de Curtose

- Excesso de Curtose

$$ExCur = \frac{m_4}{s^4} - 3$$

$$m_4 = \frac{\sum (Y_j - \bar{Y})^4}{n}$$

ExCur = 0 \Rightarrow Distribuição Mesocúrtica \Rightarrow Normal

ExCur > 0 \Rightarrow Distribuição Platicúrtica

ExCur < 0 \Rightarrow Distribuição Leptocúrtica

- Percentílico de Curtose

$$C = \frac{(Q_3 - Q_1)}{2(P_{90} - P_{10})}$$


C = 0,263 \Rightarrow Distribuição Mesocúrtica \Rightarrow Normal

C > 0,263 \Rightarrow Distribuição Platicúrtica


C < 0,263 \Rightarrow Distribuição Leptocúrtica

Calcule o valor de C para a N(0;1) !


Descriptive Statistics - Simulação de 1000 N(20;9)



95% Confidence Interval for Mu



95% Confidence Interval for Median



Variable: Normal

Anderson-Darling Normality Test

A-Squared: 0.564
P-Value: 0.144

Mean 19.9592
StDev 3.0565
Variance 9.34235
Skewness 1.31E-02
Kurtosis -1.3E-02
N 1000




Minimum 9.4222
1st Quartile 17.9671
Median 19.9510
3rd Quartile 21.9066
Maximum 28.9159

95% Confidence Interval for Mu
19.7695 20.1489


95% Confidence Interval for Sigma
2.9282 3.1967

95% Confidence Interval for Median
19.7188 20.1923


Descriptive Statistics - Simulação de 1000 N(20;9)



95% Confidence Interval for Mu



95% Confidence Interval for Median



Variable: Normal

Anderson-Darling Normality Test

A-Squared: 0.564
P-Value: 0.144

Mean 19.9592
StDev 3.0565
Variance 9.34235
Skewness 1.31E-02
Kurtosis -1.3E-02
N 1000



Minimum 9.4222
1st Quartile 17.9671
Median 19.9510
3rd Quartile 21.9066
Maximum 28.9159


95% Confidence Interval for Mu
19.7695 20.1489

95% Confidence Interval for Sigma
2.9282 3.1967

95% Confidence Interval for Median
19.7188 20.1923

Descriptive Statistics - Simulação de 1000 Bino(10;0.8)

Variable: Bino



Anderson-Darling Normality Test

A-Squared: 29.313
P-Value: 0.000

Mean 8.02800
StDev 1.21684
Variance 1.48070
Skewness -3.6E-01
Kurtosis -1.7E-01
N 1000

Minimum 4.0000
1st Quartile 7.0000
Median 8.0000
3rd Quartile 9.0000
Maximum 10.0000

95% Confidence Interval for Mu

7.9525 8.1035

95% Confidence Interval for Sigma

1.1657 1.2727


95% Confidence Interval for Median

8.0000 8.0000




Descriptive Statistics - Simulação de 1000 Chi(2)

Variable: Chi



95% Confidence Interval for Mu



95% Confidence Interval for Median



Anderson-Darling Normality Test

A-Squared: 45.388
P-Value: 0.000

Mean 2.13845
StDev 2.12922
Variance 4.53357
Skewness 1.81217
Kurtosis 4.30253
N 1000



Minimum 0.0024
1st Quartile 0.5541
Median 1.5707
3rd Quartile 2.9603
Maximum 14.1631

95% Confidence Interval for Mu

2.0063 2.2706

95% Confidence Interval for Sigma

2.0398 2.2269

95% Confidence Interval for Median

1.4091 1.6853