

Pedro Alberto Morettin
INTRODUÇÃO À ESTATÍSTICA

PREFÁCIO

O objetivo destas notas é fornecer subsídios para um primeiro curso de Estatística. Não há requisito prévio, exceto um curso de álgebra elementar. Somente em raras ocasiões fazemos uso de noções de limite e integral.

São óbvias as dificuldades encontradas ao se escrever um livro em nível elementar. Em primeiro lugar, há de se decidir "quão elementar" deve ser o livro. Depois, há o problema do que deve ser incluído. Quanto ao primeiro aspecto, devo frisar que estas notas não constituem um conjunto de métodos matemáticos da Estatística, mas sim uma abordagem inicial, na maior parte das vezes heurística, dos princípios da Estatística. Dada a exigüidade de tempo, não incluímos tópicos que pretendíamos abordar: alguns testes de hipóteses usuais para distribuições normais e uma introdução ao enfoque bayesiano.

Ênfase foi dada à distribuição binomial, para introduzir as idéias básicas de estimação e testes de hipóteses. Alguns tópicos mais difíceis ou especializados estão no apêndice.

Finalmente, gostaria de agradecer à Comissão Orga-

nizadora do 10º Colóquio Brasileiro de Matemática, por ter nos convidado para ministrar este curso, a Clóvis de A. Peres, por ter lido os originais e apresentado várias sugestões e ao Sr. João Baptista Esteves de Oliveira, pelo excelente trabalho de datilografia.

São Paulo, maio de 1975

Pedro A. Morettin

I N D I C E

PREFÁCIO.	1
CAPÍTULO 1 - PRELIMINARES SOBRE PROBABILIDADES.	1
1.1 - Modelo Probabilístico.	1
1.2 - Algumas Propriedades	2
1.3 - Probabilidade Condicional e Independên- cia.	6
Problemas para o Capítulo 1.	9
CAPÍTULO 2 - VARIÁVEIS ALEATÓRIAS	13
2.1 - O Conceito de Variável Aleatória	13
2.2 - Valor Esperado de uma Variável Aleató- ria.	15
2.3 - Mais de uma Variável Aleatória	21
2.4 - Representações Gráficas para Variáveis Problemas para o Capítulo 2.	27 30
CAPÍTULO 3 - ALGUNS MODELOS PROBABILÍSTICOS	34
3.1 - A Distribuição Binomial.	34
3.2 - A Distribuição Hipergeométrica	42
3.3 - A Distribuição Normal.	44
3.4 - Variáveis Aleatórias Contínuas	54
Problemas para o Capítulo 3.	59
CAPÍTULO 4 - INTRODUÇÃO À INFERÊNCIA ESTATÍSTICA.	62
4.1 - Probabilidade e Estatística.	62
4.2 - Modelos Estatísticos	64
Problemas para o Capítulo 4.	68
CAPÍTULO 5 - ESTIMAÇÃO: PRIMEIRAS IDÉIAS.	70
5.1 - Um Estimador por Ponto de p.	70
5.2 - A Lei dos Grandes Números.	74
5.3 - Estimação de p por Intervalo	76
Problemas para o Capítulo 5.	80
CAPÍTULO 6 - TESTES DE HIPÓTESES: PRIMEIRAS IDÉIAS.	82
6.1 - Hipótese Estatística	82
6.2 - Teste de uma Hipótese para p	84
6.3 - Hipótese Alternativa. Um outro Tipo de Erro	88

6.4 - Relação entre Intervalo de Confiança e Teste de Hipótese.	95
6.5 - Uma Aplicação: Teste de Sinal.	100
Problemas para o Capítulo 6.	102
CAPÍTULO 7 - DISTRIBUIÇÃO AMOSTRAIS	105
7.1 - Estatísticas	105
7.2 - Distribuições Amostrais.	109
Problemas para o Capítulo 7.	116
CAPÍTULO 8 - IDÉIAS GERAIS SOBRE INFERÊNCIA ESTATÍSTICA	119
8.1 - Propriedades dos Estimadores	119
8.2 - Estimadores de Mínimos Quadrados e Estimadores de Máxima Verossimilhança.	124
8.3 - O Problema Geral do Teste de Hipótese.	129
8.4 - O Teste da Razão de Verossimilhança.	136
Problemas para o Capítulo 8.	143
REFERÊNCIAS	146
APÊNDICE 1.	147
APÊNDICE 2.	157

1. PRELIMINARES SOBRE PROBABILIDADES

Neste capítulo vamos introduzir alguns conceitos básicos de probabilidades de maneira simples e utilizando vários exemplos. Vamos nos restringir ao caso de espaços amostrais discretos, pois pretendemos introduzir as idéias principais de estimação e testes de hipóteses para parâmetros de uma distribuição discreta de probabilidades.

1.1 - MODELO PROBABILÍSTICO

Todo experimento ou fenômeno que envolva um elemento casual ficará especificado no momento que estabelecemos:

- (i) um *espaço amostral*, Ω , que consiste, no caso discreto, da enumeração (finita ou infinita) de todos os resultados possíveis do experimento em questão: $\Omega = \{\omega_1, \omega_2, \dots\}$. Os elementos ω são os *pontos amostrais*;
- (ii) uma *probabilidade*, $P(\omega)$, para cada ponto amostral, de tal sorte que seja possível encontrar a probabilidade $P(A)$ de qualquer subconjunto A de Ω , isto é, a probabilidade do que chamaremos um *evento*.

Exemplo 1.1 - Uma urna contém duas bolas brancas (B) e três bolas vermelhas (V). Retirando-se uma bola ao acaso da urna,

a probabilidade de se obter uma bola branca será $P(B) = \frac{2}{5}$ e a probabilidade de se obter uma bola vermelha será $P(V) = \frac{3}{5}$. Aqui, $\Omega = \{B, V\}$.

Exemplo 1.2 - Suponha que lançamos uma moeda duas vezes. Se C indica cara e R indica coroa, então um espaço amostral será $\Omega = \{\omega_1, \omega_2, \omega_3, \omega_4\}$, onde $\omega_1 = (C, C)$, $\omega_2 = (C, R)$, $\omega_3 = (R, C)$, $\omega_4 = (R, R)$. É razoável supor que cada ponto ω tem probabilidade $\frac{1}{4}$, se a moeda é perfeitamente simétrica e homogênea.

Se A é o evento que consiste na obtenção de faces iguais nos dois lançamentos, então

$$P(A) = P\{\omega_1, \omega_4\} = \frac{1}{4} + \frac{1}{4} = \frac{1}{2}.$$

De um modo geral, se A é um evento, então

$$P(A) = \sum P(\omega_j), \quad (1.1)$$

onde a soma é estendida a todos os $\omega_j \in A$.

Vale, aqui, uma observação sobre espaços amostrais. Para um mesmo experimento podemos ter vários espaços amostrais, dependendo do objetivo do problema que se quer estudar. Por exemplo, suponha que lancemos uma moeda 5 vezes. Se estamos interessados apenas na seqüência de caras e coroas obtida, um espaço amostral é $\Omega_1 = \{(x_1, \dots, x_5) : x_i = 0 \text{ ou } x_i = 1, i=1, \dots, 5\}$. Mas se estamos interessados no número de caras obtidas, então um espaço amostral mais conveniente é $\Omega_2 = \{0, 1, 2, 3, 4, 5\}$.

1.2 - ALGUMAS PROPRIEDADES

Suponha que lancemos uma moeda; costumamos dizer

que a probabilidade de cara ou coroa é $\frac{1}{2}$. Podemos dar a seguinte explicação em termos de frequência relativa. Considere 10 lançamentos da moeda; se obtemos 6 caras, então $\frac{6}{10} = 0,6$ é a frequência relativa de ocorrência de caras nestes 10 lançamentos. Suponha que aumentemos progressivamente o número de lançamentos, e para cada um deles calculemos a frequência relativa. Esta variará de prova para prova mas a medida que aumentamos o número de lançamentos ela tenderá a se estabilizar ao redor de um número, que será a probabilidade de "cara"; este número será $\frac{1}{2}$ se a moeda for "honestá".

Esta interpretação freqüencial poderá ser útil ao leitor, se quiser verificar heurísticamente as propriedades que passamos a considerar, em especial a regra de adição. Em particular, como toda frequência relativa é um número entre 0 e 1, vemos que $0 \leq P(A) \leq 1$, para qualquer evento A. Para efeito de completividade, será útil considerarmos o espaço todo Ω e o conjunto vazio, \emptyset , como eventos. O primeiro é denominado *evento certo* e $P(\Omega) = 1$, enquanto que \emptyset é o *evento impossível* e $P(\emptyset) = 0$.

Exemplo 1.3 - Suponha que o seguinte quadro represente uma possível divisão dos alunos matriculados em dado instituto de matemática, num dado ano. (Vide quadro na pág. seguinte).

Vamos indicar por P o evento que ocorre quando, escolhendo-se ao acaso um aluno do instituto, ele for um estudante de matemática pura. A, E, C, H e M têm significados a

	HOMENS	MULHERES	TOTAIS
MATEMÁTICA PURA . .	70	40	110
MATEMÁTICA APLICADA	15	15	30
ESTATÍSTICA	10	20	30
COMPUTAÇÃO	20	10	30
TOTAIS	115	85	200

Tabela 1.1

nálogos. Desta maneira vemos que $P(E) = \frac{30}{200}$, ao passo que $P(H) = \frac{115}{200}$.

Dado os eventos A e H podemos considerar dois novos eventos:

$A \cup H$, chamado a *reunião* de A e H, que ocorre quando pelo menos um dos eventos ocorre;

$A \cap H$, chamado a *intersecção* de A e H, que ocorre quando A e H ocorrem simultaneamente.

É fácil ver que $P(A \cap H) = \frac{15}{200}$, pois o aluno escolhido terá que ser ao mesmo tempo, matriculado no curso de matemática aplicada e ser homem.

Vemos que $P(A) = \frac{30}{200}$ e $P(H) = \frac{115}{200}$; suponha que nosso cálculo para $P(A \cup H)$ fosse

$$P(A \cup H) = P(A) + P(H) = \frac{30}{200} + \frac{115}{200} = \frac{145}{200}.$$

Se assim o fizéssemos, estaríamos contando duas vezes os alunos que são homens e estão matriculados no curso de matemática aplicada, como está destacado na tabela 1.1. Portanto, a resposta correta é

$$\begin{aligned} P(A \cup H) &= P(A) + P(H) - P(A \cap H) \\ &= \frac{30}{200} + \frac{115}{200} - \frac{15}{200} = \frac{130}{200}. \end{aligned}$$

No entanto, considerando-se os eventos A e C, vemos que $P(A) = \frac{30}{200}$, $P(C) = \frac{30}{200}$ e $P(A \cup C) = \frac{60}{200} = P(A) + P(C)$. Neste caso, os eventos A e C são disjuntos ou *mutuamente exclusivos*, pois se A ocorre então C não ocorre e vice-versa. Aqui, $A \cap C = \emptyset$ e $P(A \cap C) = 0$.

Portanto, se M e N são dois eventos quaisquer temos a chamada *regra da adição de probabilidades*

$$P(M \cup N) = P(M) + P(N) - P(M \cap N), \quad (1.2)$$

que se reduz a

$$P(M \cup N) = P(M) + P(N), \quad (1.3)$$

se M e N são eventos mutuamente exclusivos.

Suponha, agora, que estamos somente interessados em saber se um estudante escolhido ao acaso está matriculado como aluno de matemática pura, aplicada, estatística ou computação, não interessando saber se é homem ou mulher. Um espaço amostral é $\Omega = \{P, A, E, C\}$. Os eventos A e B = $\{P, E, C\}$ são chamados *complementares* e são tais que $A \cup B = \Omega$ e $A \cap B = \emptyset$. Vemos que $P(A) = \frac{30}{200}$, enquanto $P(B) = \frac{110}{200} + \frac{30}{200} + \frac{30}{200} = \frac{170}{200}$, isto é,

$$P(A) + P(B) = 1. \quad (1.4)$$

Em geral, vamos indicar por A^c o complementar de um evento A e teremos, então,

$$P(A^c) = 1 - P(A). \quad (1.5)$$

1.3 - PROBABILIDADE CONDICIONAL E INDEPENDÊNCIA

Voltemos ao quadro do exemplo 1.3. Dado que um estudante, escolhido ao acaso, esteja matriculado no curso de Estatística, a probabilidade dele ser mulher é $\frac{10}{30} = \frac{1}{3}$. Isto porque do total de 30 alunos que estudam estatística, 10 são mulheres. Escrevemos

$$P(\text{mulher} \mid \text{estatística}) = \frac{1}{3}.$$

Para dois eventos quaisquer A e B, sendo $P(B) > 0$, definimos a *probabilidade condicional de A, dado B*, $P(A|B)$, como sendo

$$P(A|B) = \frac{P(A \cap B)}{P(B)}. \quad (1.6)$$

Para o exemplo mencionado, se B e A indicam, respectivamente, os eventos "aluno matriculado em Estatística" e "aluno é mulher", então $P(A \cap B) = 10/200$, $P(B) = 30/200$ e, portanto,

$$P(A|B) = \frac{10/200}{30/200} = \frac{1}{3},$$


como havíamos obtido.

Da relação (1.6) obtemos a chamada *regra do produto de probabilidades*,

$$P(A \cap B) = P(B) \cdot P(A|B). \quad (1.7)$$


Exemplo 1.4 - Retomemos a urna do exemplo 1.1 mas suponha agora que extraímos duas bolas ao acaso, *sem reposição*. Isto significa que escolhemos a primeira bola, verificamos a sua

cor e *não* a devolvemos à urna, misturamos as bolas restantes e retiramos a segunda bola. O diagrama em árvore abaixo ilustra as possibilidades. Em cada "galho" da árvore estão indicadas as probabilidades de ocorrência, sendo que, para as segundas bolas temos probabilidades condicionais. A probabilidade do resultado conjunto é, então, dada por (1.7).



RESULTADOS	PROBABILIDADES
BB	$\frac{2}{5} \times \frac{1}{4} = \frac{2}{20}$
BV	$\frac{2}{5} \times \frac{3}{4} = \frac{6}{20}$
VB	$\frac{3}{5} \times \frac{2}{4} = \frac{6}{20}$
VV	$\frac{3}{5} \times \frac{2}{4} = \frac{6}{20}$
SOMA	1

Exemplo 1.5 - Imagine, agora, que as duas extrações são feitas da urna, mas a primeira bola é *reposta* na urna antes da extração da segunda bola. Nestas condições, as extrações são *independentes*, no sentido que o resultado de cada extração não tem influência no resultado da outra. Obtemos a situação a seguir.



RESULTADOS	PROBABILIDADES
BB	$\frac{2}{5} \times \frac{2}{5} = \frac{4}{25}$
BV	$\frac{2}{5} \times \frac{3}{5} = \frac{6}{25}$
VB	$\frac{3}{5} \times \frac{2}{5} = \frac{6}{25}$
VV	$\frac{3}{5} \times \frac{3}{5} = \frac{9}{25}$
SOMA	1

Observe que, aqui,

$$P(\text{branca na } 2^{\text{a}} \mid \text{branca na } 1^{\text{a}}) = \frac{2}{5} = P(\text{branca na } 2^{\text{a}}),$$

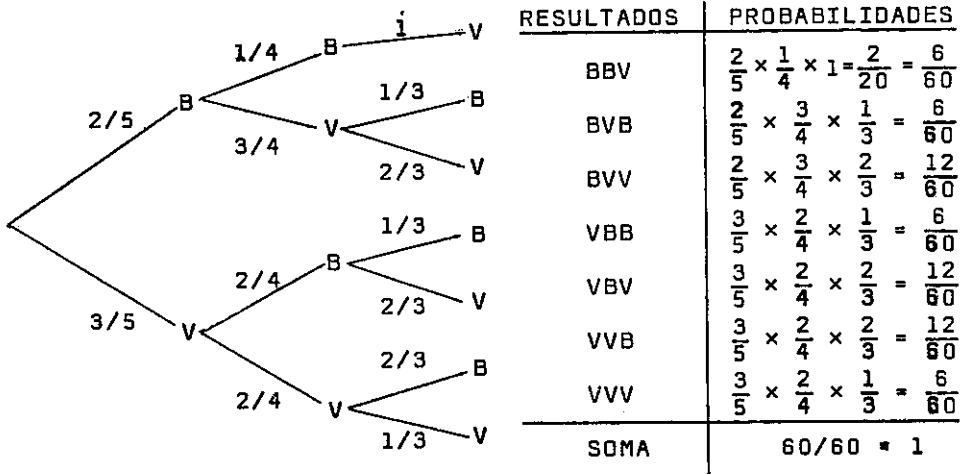
Ou seja, se dois eventos A e B são *independentes*,

$P(A|B) = P(A)$ e $P(B|A) = P(B)$. Se assim é, a relação (1.7) fica para A e B independentes:

$$P(A \cap B) = P(A) \cdot P(B). \quad (1.8)$$

A fórmula (1.8) pode ser tomada como definição de independência: A e B são independentes se e somente se (1.8) é válida.

Exemplo 1.6 - Considere, ainda, a mesma urna dos exemplos anteriores, mas vamos fazer três extrações *sem reposição*. Obtemos o esquema abaixo.



Observe que $P(B|B) = \frac{1}{4}$, ao passo que $P(V|B \text{ e } B) = 1$, daí

$$P(B \text{ e } B \text{ e } V) = P(B) \cdot P(B|B) \cdot P(V|B \text{ e } B) = \frac{2}{5} \times \frac{1}{4} \times 1 = \frac{1}{10}.$$

De modo geral, dados 3 eventos M, N e R, temos que

$$P(MnNnR) = P(M) \cdot P(N|M) \cdot P(R|MnN) \quad (1.9)$$

PROBLEMAS PARA O CAPÍTULO 1

- 1.1 - Duas moedas são lançadas. Dê dois possíveis espaços amostrais para este experimento. Represente um destes como o *produto cartesiano* de dois outros espaços amostrais.
- 1.2 - Uma moeda e um dado são lançados. Dê um espaço amostral do experimento e depois represente-o como produto cartesiano dos dois espaços amostrais correspondente aos experimentos considerados individualmente.
- 1.3 - No exercício 1.1, liste os eventos:
a) pelo menos uma cara;
b) duas caras;
c) o complementar de b).
- 1.4 - Considere o lançamento de dois dados. Considere os eventos A: soma dos números obtidos igual a 9 e B: número no primeiro dado maior ou igual a 4. Enumere os elementos de A e B. Obtenha $A \cup B$, $A \cap B$ e A^c .
- 1.5 - Obtenha as probabilidades dos eventos que aparecem nos problemas 1.3 e 1.4.
- 1.6 - Considere uma urna contendo 3 bolas pretas e 5 bolas vermelhas. Retire duas bolas da urna, sem reposição. Obtenha os resultados possíveis e as respectivas probabilidades. Mesmo problema, para extrações com reposição.
- 1.7 - No problema anterior, calcule as probabilidades dos eventos:

- a) bola preta na primeira e segunda extrações;
- b) bola preta na segunda extração;
- c) bola branca na primeira extração.

1.8 - Se A e B são independentes, mostre que também são independentes: A e B^C , A^C e B, A^C e B^C .

- 1.9 - As probabilidades que dois eventos independentes ocorram são p e q, respectivamente. Qual a probabilidade:
- a) que nenhum destes eventos ocorra?
 - b) pelo menos um destes eventos ocorra?

1.10- Na tabela abaixo, os números que aparecem são probabilidades relacionadas com a ocorrência de A, B, A^C e B^C , etc. Assim, $P(A) = 0,1$, enquanto que $P(A \cap B) = 0,04$. Verifique se A e B são independentes.

	B	B^C	
A	0,04	0,06	0,10
A^C	0,08	0,82	0,90
	0,12	0,86	1,00

1.11- Suponha uma população de N elementos a_1, a_2, \dots, a_N . Qualquer arranjo *ordenado* $a_{i_1}, a_{i_2}, \dots, a_{i_n}$ de n símbolos é chamado uma *amostra ordenada de tamanho n* extraída da população. Considere o símbolo $(N)_n$ como significando $N(N-1)\dots(N-n+1)$. Suponha $n < N$. Mostre que existem N^n amostras *com reposição* (um mesmo elemento pode ser retirado mais de uma vez) e $(N)_n$ amostras *sem reposição* (um elemento quando escolhido é removido da população, não havendo pois repetição na amostra).

1.12- Uma amostra de tamanho n extraída de uma população com N elementos diz-se *casual* (ou *aleatória*) se todas as possíveis amostras têm a mesma probabilidade de serem escolhidas; esta probabilidade será $1/N_n$ se a amostra

que a probabilidade de cara ou coroa é $\frac{1}{2}$. Podemos dar a seguinte explicação em termos de frequência relativa. Considere 10 lançamentos da moeda; se obtemos 6 caras, então $\frac{6}{10} = 0,6$ é a frequência relativa de ocorrência de caras nestes 10 lançamentos. Suponha que aumentemos progressivamente o número de lançamentos, e para cada um deles calculemos a frequência relativa. Esta variará de prova para prova mas a medida que aumentamos o número de lançamentos ela tenderá a se estabilizar ao redor de um número, que será a probabilidade de "cara"; este número será $\frac{1}{2}$ se a moeda for "honestá".

Esta interpretação freqüencial poderá ser útil ao leitor, se quizer verificar heurísticamente as propriedades que passamos a considerar, em especial a regra de adição. Em particular, como toda frequência relativa é um número entre 0 e 1, vemos que $0 \leq P(A) \leq 1$, para qualquer evento A. Para efeito de completividade, será útil considerarmos o espaço todo Ω e o conjunto vazio, \emptyset , como eventos. O primeiro é denominado *evento certo* e $P(\Omega) = 1$, enquanto que \emptyset é o *evento impossível* e $P(\emptyset) = 0$.

Exemplo 1.3 - Suponha que o seguinte quadro represente uma possível divisão dos alunos matriculados em dado instituto de matemática, num dado ano. (Vide quadro na pág. seguinte).

Vamos indicar por P o evento que ocorre quando, escolhendo-se ao acaso um aluno do instituto, ele for um estudante de matemática pura. A, E, C, H e M têm significados a

	HOMENS	MULHERES	TOTAIS
MATEMÁTICA PURA . .	70	40	110
MATEMÁTICA APLICADA	15	15	30
ESTATÍSTICA	10	20	30
COMPUTAÇÃO.	20	10	30
TOTAIS.	115	85	200

Tabela 1.1

nálogos. Desta maneira vemos que $P(E) = \frac{30}{200}$, ao passo que $P(H) = \frac{115}{200}$.

Dado os eventos A e H podemos considerar dois novos eventos:

$A \cup H$, chamado a *reunião* de A e H, que ocorre quando pelo menos um dos eventos ocorre;

$A \cap H$, chamado a *intersecção* de A e H, que ocorre quando A e H ocorrem simultaneamente.

É fácil ver que $P(A \cap H) = \frac{15}{200}$, pois o aluno escolhido terá que ser ao mesmo tempo, matriculado no curso de matemática aplicada e ser homem.

Vemos que $P(A) = \frac{30}{200}$ e $P(H) = \frac{115}{200}$; suponha que nosso cálculo para $P(A \cup H)$ fosse

$$P(A \cup H) = P(A) + P(H) = \frac{30}{200} + \frac{115}{200} = \frac{145}{200}.$$

Se assim o fizéssemos, estaríamos contando duas vezes os alunos que são homens e estão matriculados no curso de matemática aplicada, como está destacado na tabela 1.1. Portanto, a resposta correta é

$$\begin{aligned}P(A \cup H) &= P(A) + P(H) - P(A \cap H) \\ &= \frac{30}{200} + \frac{115}{200} - \frac{15}{200} = \frac{130}{200}.\end{aligned}$$

No entanto, considerando-se os eventos A e C, vemos que $P(A) = \frac{30}{200}$, $P(C) = \frac{30}{200}$ e $P(A \cup C) = \frac{60}{200} = P(A) + P(C)$. Neste caso, os eventos A e C são disjuntos ou *mutuamente exclusivos*, pois se A ocorre então C não ocorre e vice-versa. Aqui, $A \cap C = \emptyset$ e $P(A \cap C) = 0$.

Portanto, se M e N são dois eventos quaisquer temos a chamada *regra da adição de probabilidades*

$$P(M \cup N) = P(M) + P(N) - P(M \cap N), \quad (1.2)$$

que se reduz a

$$P(M \cup N) = P(M) + P(N), \quad (1.3)$$

se M e N são eventos mutuamente exclusivos.

Suponha, agora, que estamos somente interessados em saber se um estudante escolhido ao acaso está matriculado como aluno de matemática pura, aplicada, estatística ou computação, não interessando saber se é homem ou mulher. Um espaço amostral é $\Omega = \{P, A, E, C\}$. Os eventos A e B = $\{P, E, C\}$ são chamados *complementares* e são tais que $A \cup B = \Omega$ e $A \cap B = \emptyset$. Vemos que $P(A) = \frac{30}{200}$, enquanto $P(B) = \frac{110}{200} + \frac{30}{200} + \frac{30}{200} = \frac{170}{200}$, isto é,

$$P(A) + P(B) = 1. \quad (1.4)$$

Em geral, vamos indicar por A^c o complementar de um evento A e teremos, então,

$$P(A^c) = 1 - P(A). \quad (1.5)$$

1.3 - PROBABILIDADE CONDICIONAL E INDEPENDÊNCIA

Voltemos ao quadro do exemplo 1.3. Dado que um estudante, escolhido ao acaso, esteja matriculado no curso de Estatística, a probabilidade dele ser mulher é $\frac{10}{30} = \frac{1}{3}$. Isto porque do total de 30 alunos que estudam estatística, 10 são mulheres. Escrevemos

$$P(\text{mulher} \mid \text{estatística}) = \frac{1}{3}.$$

Para dois eventos quaisquer A e B, sendo $P(B) > 0$, definimos a *probabilidade condicional de A, dado B*, $P(A|B)$, como sendo

$$P(A|B) = \frac{P(A \cap B)}{P(B)}. \quad (1.6)$$

Para o exemplo mencionado, se B e A indicam, respectivamente, os eventos "aluno matriculado em Estatística" e "aluno é mulher", então $P(A \cap B) = 10/200$, $P(B) = 30/200$ e, portanto,

$$P(A|B) = \frac{10/200}{30/200} = \frac{1}{3},$$


como havíamos obtido.

Da relação (1.6) obtemos a chamada *regra do produto de probabilidades*,

$$P(A \cap B) = P(B) \cdot P(A|B). \quad (1.7)$$


Exemplo 1.4 - Retomemos a urna do exemplo 1.1 mas suponha agora que extraímos duas bolas ao acaso, *sem reposição*. Isto significa que escolhemos a primeira bola, verificamos a sua

cor e não a devolvemos à urna, misturamos as bolas restantes e retiramos a segunda bola. O diagrama em árvore abaixo ilustra as possibilidades. Em cada "galho" da árvore estão indicadas as probabilidades de ocorrência, sendo que, para as segundas bolas temos probabilidades condicionais. A probabilidade do resultado conjunto é, então, dada por (1.7).



RESULTADOS	PROBABILIDADES
BB	$\frac{2}{5} \times \frac{1}{4} = \frac{2}{20}$
BV	$\frac{2}{5} \times \frac{3}{4} = \frac{6}{20}$
VB	$\frac{3}{5} \times \frac{2}{4} = \frac{6}{20}$
VV	$\frac{3}{5} \times \frac{2}{4} = \frac{6}{20}$
SOMA	1

Exemplo 1.5 - Imagine, agora, que as duas extrações são feitas da urna, mas a primeira bola é *reposta* na urna antes da extração da segunda bola. Nestas condições, as extrações são *independentes*, no sentido que o resultado de cada extração não tem influência no resultado da outra. Obtemos a situação a seguir.



RESULTADOS	PROBABILIDADES
BB	$\frac{2}{5} \times \frac{2}{5} = \frac{4}{25}$
BV	$\frac{2}{5} \times \frac{3}{5} = \frac{6}{25}$
VB	$\frac{3}{5} \times \frac{2}{5} = \frac{6}{25}$
VV	$\frac{3}{5} \times \frac{3}{5} = \frac{9}{25}$
SOMA	1

Observe que, aqui,

$$P(\text{branca na } 2^{\text{a}} \mid \text{branca na } 1^{\text{a}}) = \frac{2}{5} = P(\text{branca na } 2^{\text{a}}),$$

Ou seja, se dois eventos A e B são *independentes*,

$P(A|B) = P(A)$ e $P(B|A) = P(B)$. Se assim é, a relação (1.7) fica para A e B independentes:

$$P(A \cap B) = P(A) \cdot P(B). \quad (1.8)$$

A fórmula (1.8) pode ser tomada como definição de independência: A e B são independentes se e somente se (1.8) é válida.

Exemplo 1.6 - Considere, ainda, a mesma urna dos exemplos anteriores, mas vamos fazer três extrações *sem reposição*. Obtemos o esquema abaixo.

RESULTADOS	PROBABILIDADES
BBV	$\frac{2}{5} \times \frac{1}{4} \times 1 = \frac{2}{20} = \frac{6}{60}$
BVB	$\frac{2}{5} \times \frac{3}{4} \times \frac{1}{3} = \frac{6}{60}$
BVV	$\frac{2}{5} \times \frac{3}{4} \times \frac{2}{3} = \frac{12}{60}$
VBB	$\frac{3}{5} \times \frac{2}{4} \times \frac{1}{3} = \frac{6}{60}$
VBV	$\frac{3}{5} \times \frac{2}{4} \times \frac{2}{3} = \frac{12}{60}$
VVB	$\frac{3}{5} \times \frac{2}{4} \times \frac{2}{3} = \frac{12}{60}$
VVV	$\frac{3}{5} \times \frac{2}{4} \times \frac{1}{3} = \frac{6}{60}$
SOMA	$60/60 = 1$

Observe que $P(B|B) = \frac{1}{4}$, ao passo que $P(V|B \text{ e } B) = 1$; daí

$$P(B \text{ e } B \text{ e } V) = P(B) \cdot P(B|B) \cdot P(V|B \text{ e } B) = \frac{2}{5} \times \frac{1}{4} \times 1 = \frac{1}{10}.$$

De modo geral, dados 3 eventos M, N e R, temos que

$$P(MnNr) = P(M) \cdot P(N|M) \cdot P(R|MnN) \quad (1.9)$$

PROBLEMAS PARA O CAPÍTULO 1

- 1.1 - Duas moedas são lançadas. Dê dois possíveis espaços amostrais para este experimento. Represente um destes como o *produto cartesiano* de dois outros espaços amostrais.
- 1.2 - Uma moeda e um dado são lançados. Dê um espaço amostral do experimento e depois represente-o como produto cartesiano dos dois espaços amostrais correspondente aos experimentos considerados individualmente.
- 1.3 - No exercício 1.1, liste os eventos:
a) pelo menos uma cara;
b) duas caras;
c) o complementar de b).
- 1.4 - Considere o lançamento de dois dados. Considere os eventos A: soma dos números obtidos igual a 9 e B: número no primeiro dado maior ou igual a 4. Enumere os elementos de A e B. Obtenha $A \cup B$, $A \cap B$ e A^c .
- 1.5 - Obtenha as probabilidades dos eventos que aparecem nos problemas 1.3 e 1.4.
- 1.6 - Considere uma urna contendo 3 bolas pretas e 5 bolas vermelhas. Retire duas bolas da urna, sem reposição. Obtenha os resultados possíveis e as respectivas probabilidades. Mesmo problema, para extrações com reposição.
- 1.7 - No problema anterior, calcule as probabilidades dos eventos:

- a) bola preta na primeira e segunda extrações;
- b) bola preta na segunda extração;
- c) bola branca na primeira extração.

1.8 - Se A e B são independentes, mostre que também são independentes: A e B^c , A^c e B, A^c e B^c .

1.9 - As probabilidades que dois eventos independentes ocorram são p e q, respectivamente. Qual a probabilidade:

- a) que nenhum destes eventos ocorra?
- b) pelo menos um destes eventos ocorra?

1.10- Na tabela abaixo, os números que aparecem são probabilidades relacionadas com a ocorrência de A, B, A^c e B^c , etc. Assim, $P(A) = 0,1$, enquanto que $P(A \cap B) = 0,04$. Verifique se A e B são independentes.

	B	B^c	
A	0,04	0,06	0,10
A^c	0,08	0,82	0,90
	0,12	0,86	1,00

1.11- Suponha uma população de N elementos a_1, a_2, \dots, a_N . Qualquer arranjo *ordenado* $a_{i_1}, a_{i_2}, \dots, a_{i_n}$ de n símbolos é chamado uma *amostra ordenada de tamanho n* extraída da população. Considere o símbolo $(N)_n$ como significando $N(N-1)\dots(N-n+1)$. Suponha $n < N$. Mostre que existem N^n amostras *com reposição* (um mesmo elemento pode ser retirado mais de uma vez) e $(N)_n$ amostras *sem reposição* (um elemento quando escolhido é removido da população, não havendo pois repetição na amostra).

1.12- Uma amostra de tamanho n extraída de uma população com N elementos diz-se *casual* (ou *aleatória*) se todas as possíveis amostras têm a mesma probabilidade de serem escolhidas; esta probabilidade será $1/N_n$ se a amostra

for com reposição e $1/(N)_n$ se for sem reposição.


Uma amostra casual de tamanho n com reposição é extraída de uma população com N elementos. Encontre a probabilidade de não haver repetição na amostra.

1.13- Considere os aniversários de n pessoas como constituindo uma amostra de tamanho n da população dos 365 dias do ano. Aplique o resultado do problema anterior para encontrar a probabilidade que todos os n aniversários caíam em dias diferentes.

1.14- Denote por $\binom{N}{n} = \frac{(N)_n}{n!} = \frac{N!}{n!(N-n)!}$. Considere a situação do problema 1.11, mas na qual *não levamos em conta a ordem do conjunto* $a_{i_1}, a_{i_2}, \dots, a_{i_n}$. Mostre que existem $\binom{N}{n}$ amostras sem reposição.

1.15- Suponha que $\{B_1, B_2, \dots, B_m\}$ é um conjunto de eventos mutuamente exclusivos e exaustivos, ou seja, quaisquer dois eventos B_i e B_j não podem ocorrer ao mesmo tempo e um deles deve ocorrer. Simbolicamente, $B_i \cap B_j = \emptyset$, $i \neq j$ e $B_1 \cup B_2 \cup \dots \cup B_m = \Omega$. Seja A um evento qualquer. Se A ocorre, então A deve ocorrer juntamente com um dos B_i . (Ver figura). Prove que

$$P(A) = \sum_{i=1}^m P(A|B_i) \cdot P(B_i).$$



Faça um diagrama em árvore.

1.16- Utilize o resultado anterior para resolver este problema. Uma companhia produz rádios em 3 fábricas A, B e C. A fábrica A produz 40% dos rádios, enquanto B e C produzem 30% cada uma. As probabilidades que um rádio produzido por estas fábricas não funcione são 0,01, 0,04 e 0,03, respectivamente. Escolhido um rádio da produção conjunta das três fábricas, qual a probabilidade do mesmo não funcionar?

1.17- Considere a situação do problema anterior, mas suponha agora que um rádio é escolhido ao acaso e ele é defeituoso. Determinar qual a probabilidade de ter sido fabricado por A. No caso geral referido em 1.15, queremos obter $P(B_j|A)$; para $j=1, \dots, m$. Verificar que se chega a

$$P(B_j|A) = \frac{P(A|B_j)P(B_j)}{P(A)} = \frac{P(A|B_j)P(B_j)}{\sum_{i=1}^m P(A|B_i)P(B_i)}$$

Este resultado é denominado *fórmula de Bayes* e é útil em muitas aplicações.

1.18- O colégio A tem 40% de rapazes, o colégio B tem 30% e o colégio C tem 10%. De um colégio selecionado ao acaso são escolhidos 8 alunos, com reposição. Se obtemos (R para rapaz e M para moça) RRRMMMMM, qual a probabilidade de ter sido selecionado o colégio C?

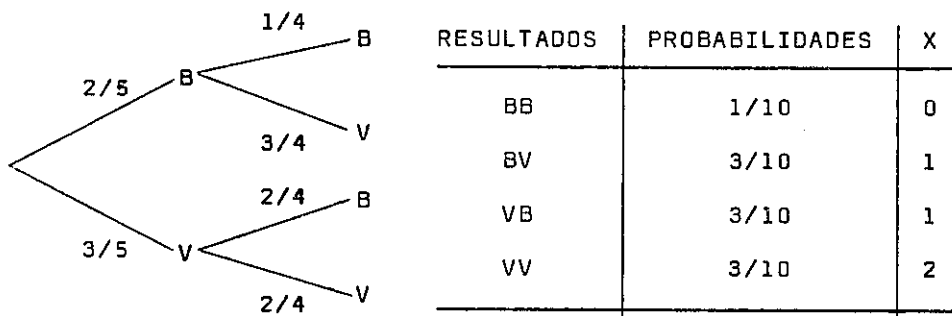
2. VARIÁVEIS ALEATÓRIAS

Em todas as situações de interesse prático que consideramos queremos estudar o comportamento de uma ou mais variáveis. Assim, podemos estar interessados em estudar a distribuição das alturas e pesos de pessoas de uma dada população. Escolhida uma pessoa ao acaso desta população, obtemos o seu peso e a sua altura e estamos, pois, considerando duas variáveis. Em muitas situações, como a descrita, a associação de números a resultados de experimentos é natural. Em outras, a associação pode ser arbitrária. Por exemplo, considere o caso de um questionário, em que uma pessoa é indagada a respeito de uma certa proposição e as respostas possíveis são "SIM" ou "NÃO". Podemos definir uma variável que tome dois valores, 1 ou 0, por exemplo, correspondentes às respostas "SIM" ou "NÃO", respectivamente. Teremos ocasião de estudar com pormenores este tipo de variável.

2.1 - O CONCEITO DE VARIÁVEL ALEATÓRIA

Exemplo 2.1 - Consideremos a situação do exemplo 1.4, em que consideramos duas extrações, sem reposição, de uma urna contendo 2 bolas brancas e 3 bolas vermelhas. Definamos a variável

vel X igual número de bolas vermelhas obtidas nas duas extrações. Obtemos o seguinte esquema.



Vemos, pois, que a cada resultado do experimento está associado um valor da variável aleatória (v.a.) X ; estes valores são 0, 1 e 2.

Dizemos que $X=0$, com probabilidade $1/10$, pois $X=0$ se e somente se ocorre o resultado BB; $X=1$ com probabilidade de $\frac{3}{10} + \frac{3}{10} = \frac{6}{10}$, pois $X=1$ se e somente se ocorrem os resultados BV ou VB, que são mutuamente exclusivos; finalmente, $X=2$ com probabilidade $\frac{3}{10}$, pois $X=2$ se e somente se ocorrem duas bolas vermelhas nas duas extrações. A notação que usaremos será $P(X=0)$, $P(X=1)$, etc. Temos, pois que

$$P(X=0) = P(BB) = \frac{1}{10},$$

$$P(X=1) = P(BV \text{ ou } VB) = \frac{6}{10},$$

$$P(X=2) = P(VV) = \frac{3}{10}.$$


No quadro a seguir, esquematizamos a *distribuição de probabilidades da v.a. X* , que consiste nos possíveis valores de X , com as respectivas probabilidades.

Usaremos a notação $P(X=x_1) = p_1$, isto é, designare

mos por letras minúsculas x_i os valores da v.a. X e por p_i as respectivas probabilidades, $i=1, 2, 3, \dots$.

x_i	0	1	2
p_i	1/10	6/10	3/10

Exemplo 2.2 - Retomemos o exemplo 1.2, em que consideramos o lançamento de uma moeda duas vezes. Definamos a v.a. Y = número de "caras" obtidas nos dois lançamentos.



Temos, então:

$$P(Y=0) = P(RR) = \frac{1}{4},$$

$$P(Y=1) = P(CR \text{ ou } RC) = \frac{1}{4} + \frac{1}{4} = \frac{1}{2},$$

$$P(Y=2) = P(CC) = \frac{1}{4}.$$

A distribuição de probabilidades de Y está indicada abaixo.

y_i	0	1	2
p_i	1/4	1/2	1/4

2.2 - VALOR ESPERADO DE UMA VARIÁVEL ALEATÓRIA

Se x_1, x_2, \dots são os possíveis valores da v.a. X e

p_1, p_2, \dots são as respectivas probabilidades, então o *valor esperado* (ou *esperança* ou *média*) de X é definido como

$$E(X) = \sum_{i=1}^{\infty} x_i \cdot p_i. \quad (2.1)$$

Exemplo 2.3 - Para a distribuição da v.a. X do exemplo 2.1, temos que

$$E(X) = 0 \times \frac{1}{10} + 1 \times \frac{6}{10} + 2 \times \frac{3}{10} = \frac{12}{10} = 1,2.$$

Para a distribuição da v.a. Y do exemplo 2.2,

$$E(Y) = 0 \times \frac{1}{2} + 1 \times \frac{1}{2} + 2 \times \frac{1}{4} = 1.$$

Exemplo 2.4 - Consideremos o lançamento de um dado e seja X a v.a. que representa o número obtido na face voltada para cima. Então, X toma os valores 1, 2, 3, 4, 5, 6 com probabilidades todas iguais a $1/6$. Calculemos $E(X)$ e $E(X^2)$.

$$E(X) = 1 \times \frac{1}{6} + 2 \times \frac{1}{6} + \dots + 6 \times \frac{1}{6} = (1+2+\dots+6) \times \frac{1}{6} = \frac{21}{6} = 3,5.$$

Os valores da v.a. X^2 são 1, 4, 9, 16, 25, 36 e as probabilidades respectivas são iguais a $1/6$. De fato,

$$P(X^2=9) = P(X=3) = \frac{1}{6}, \text{ etc.}$$

Então,

$$E(X^2) = (1+4+9+16+25+36) \times \frac{1}{6} = \frac{91}{6}.$$

Exemplo 2.5 - Considere a v.a. V com a distribuição dada pela tabela abaixo:

v	-2	-1	0	1	2
p	1/5	1/5	1/5	1/5	1/5

Calculemos $E(V)$, $E(V^2)$ e $E(2V)$.

$$E(V) = (-2) \times \frac{1}{5} + (-1) \times \frac{1}{5} + 0 \times \frac{1}{5} + 1 \times \frac{1}{5} + 2 \times \frac{1}{5} = 0$$

Obtemos, depois, as distribuições de $2V$ e V^2 .

2v	-4	-2	0	2	4
p	1/5	1/5	1/5	1/5	1/5

v ²	0	1	4
p	1/5	2/5	2/5

Por exemplo,

$$P(2V=4) = P(V=2) = \frac{1}{5} \text{ e}$$

$$P(V^2=1) = P(V=-1 \text{ ou } V=1) = \frac{1}{5} + \frac{1}{5} = \frac{2}{5}.$$

Então,

$$E(2V) = (-4) \times \frac{1}{5} + \dots + 4 \times \frac{1}{5} = 0,$$

enquanto que

$$E(V^2) = 0 \times \frac{1}{5} + 1 \times \frac{2}{5} + 4 \times \frac{2}{5} = \frac{10}{5} = 2.$$

Observe as distribuições de V e $2V$; dizemos que elas são simétricas ao redor de 0; a média será, obviamente, o ponto de simetria. (Veja Fig. 2.1).

Observe, também, que $E(V^2) = 2 \neq [E(V)]^2 = 0$. No entanto, é fácil ver que

$$E(cX) = cE(X), \tag{2.2}$$




Figura 2.1

se c é uma constante, o que decorre imediatamente da definição (2.1).

Observando o gráfico da figura 2.1, vemos que $E(V)$ é uma medida de posição central da distribuição de V .

A v.a. $2V$ pode ser representada pelo gráfico da figura 2.2.




Figura 2.2

As variáveis aleatórias V e $2V$ têm a mesma média, zero, mas notamos que $2V$ é "mais espalhada" ao redor de 0 do que V . Uma medida da dispersão de uma v.a. ao redor de sua média é dada pela *variância* da v.a.

Se X é uma v.a. com média $E(X)$, então a variância

de X é definida por

$$\text{Var}(X) = \sum_{i=1}^{\infty} (x_i - E(X))^2 \cdot p_i \quad (2.3)$$

e é fácil ver que

$$\text{Var}(X) = E(X^2) - [E(X)]^2. \quad (2.4)$$

Exemplo 2.6 - Para a v.a. V do exemplo anterior, $E(V) = 0$ e $E(V^2) = 2$, logo $\text{Var}(V) = 2$.

Vimos que $E(2V) = 0$. Vejamos $E[(2V)^2]$; a distribuição de $(2V)^2$ é aquela abaixo:

$(2v)^2$	0	4	16
p	$\frac{1}{5}$	$\frac{2}{5}$	$\frac{2}{5}$

Logo,

$$E[(2V)^2] = 0 \times \frac{1}{5} + 4 \times \frac{2}{5} + 16 \times \frac{2}{5} = \frac{40}{5} = 8,$$

do que segue que $\text{Var}(2V) = 8$, usando (2.4).

Notamos que

$$\text{Var}(2V) = 8 = 2^2 \cdot \text{Var}(V) = 4 \times 2.$$

De modo geral, utilizando (2.3), vemos que

$$\text{Var}(cX) = c^2 \cdot \text{Var}(X) \quad (2.5)$$

se c é uma constante.

Exemplo 2.7 - Considere a v.a. V do exemplo 2.5 e seja $W=V+6$.

Então, a distribuição de W é dada por:

w	4	5	6	7	8
p	1/5	1/5	1/5	1/5	1/5

Segue-se que

$$E(W) = (4+5+6+7+8) \times \frac{1}{5} = \frac{30}{5} = 6 = E(V) + 6$$

e

$$E(W^2) = (16+25+36+49+64) \times \frac{1}{5} = \frac{190}{5} = 38,$$

do que decorre que

$$\text{Var}(W) = 38 - 6^2 = 38 - 36 = 2 = \text{Var}(V).$$

Genericamente, se c é uma constante,

$$E(X+c) = E(X)+c \tag{2.6}$$

e

$$\text{Var}(X+c) = \text{Var}(X). \tag{2.7}$$

A relação (2.6) expressa o fato intuitivo que, ao transladarmos todos os valores de X por uma constante c , a média será transladada pela mesma constante, ao passo que (2.7) expressa o fato que a variabilidade não muda, pois a posição relativa dos novos valores em relação à nova média é a mesma que antes.

As fórmulas (2.2), (2.5), (2.6) e (2.7) podem ser combinadas para se obter:

$$E(aX+b) = aE(X) + b, \quad (2.8)$$

$$\text{Var}(aX + b) = a^2 \cdot \text{Var}(X), \quad (2.9)$$

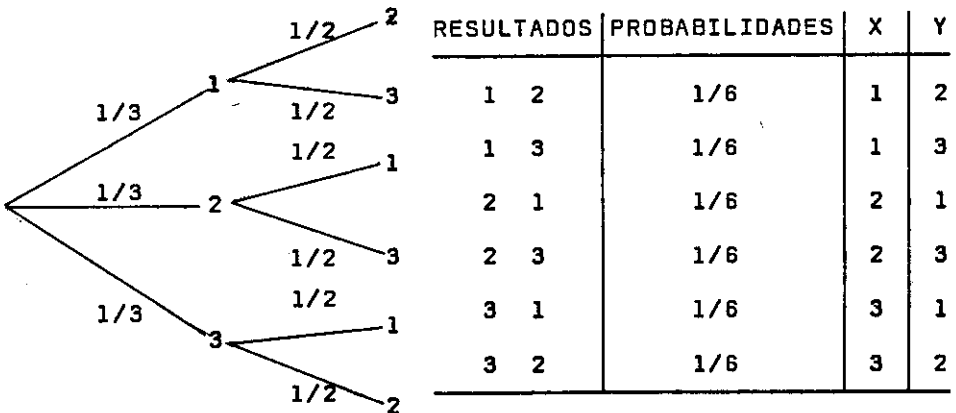
sendo a e b constantes.

O *desvio padrão* de X é definido como a raiz quadrada positiva da $\text{Var}(X)$ e será indicado por $\sigma(X)$ ou σ_X ; a variância de X também é denotada por $\sigma^2(X)$ ou σ_X^2 . A relação (2.9) fica, para $\sigma(X)$:

$$\sigma(aX+b) = |a| \cdot \sigma(X). \quad (2.10)$$

2.3 - MAIS DE UMA VARIÁVEL ALEATÓRIA

Exemplo 2.8 - Suponha que temos uma urna contendo 3 bolas numeradas 1, 2 e 3. Retiramos duas delas, sem reposição; seja X o número da primeira bola e Y o número da segunda bola retirada.



Temos, então, duas variáveis aleatórias, X e Y , cu

jas distribuições de probabilidades são:

x	1	2	3
p	1/3	1/3	1/3

y	1	2	3
p	1/3	1/3	1/3

O quadro seguinte representa a chamada *distribuição conjunta* de X e Y, onde $P(X=x, Y=y)$ denota a probabilidade do evento $\{X=x \text{ e } Y=y\} = (X=x) \cap (Y=y)$.

(X,Y)	P(X=x,Y=y)
(1,2)	1/6
(1,3)	1/6
(2,1)	1/6
(2,3)	1/6
(3,1)	1/6
(3,2)	1/6

Lembremos como $P(X=x, Y=y)$ é calculada; de acordo com a fórmula (1.7),

$$P(X=x, Y=y) = P(X=x) \cdot P(Y=y | X=x). \quad (2.11)$$

Por exemplo,

$$P(X=2, Y=3) = P(X=2)P(Y=3 | X=2) = \frac{1}{3} \times \frac{1}{2} = \frac{1}{6}.$$

Uma maneira mais cômoda e usual de se representar a distribuição conjunta de X e Y é através de uma tabela de dupla entrada, como a seguir:

Y \ X	1	2	3	P(Y=y)
1	0	1/6	1/6	1/3
2	1/6	0	1/6	1/3
3	1/6	1/6	0	1/3
P(X=x)	1/3	1/3	1/3	1

A vantagem desta tabela é que, tendo-se a distribuição conjunta de X e Y podemos obter as distribuições de X e Y (a recíproca não é verdadeira, em geral; por que?) que são chamadas *distribuições marginais*. Assim, a primeira e a última coluna da tabela dão a distribuição de Y, ao passo que a primeira e a última linha dão a distribuição de X.

Dada a distribuição de X e Y acima, podemos considerar, por exemplo, a v.a. $X+Y$, ou a v.a. XY . A soma $X+Y$ é definida de modo natural: a cada resultado do experimento e la associa a soma dos valores de X e Y.

Podemos, pois, obter a tabela seguinte:

(X,Y)	X+Y	XY	PROBABILIDADES
(1,2)	3	2	1/6
(1,3)	4	3	1/6
(2,1)	3	2	1/6
(2,3)	5	6	1/6
(3,1)	4	3	1/6
(3,2)	5	6	1/6

As distribuições de $X+Y$ e XY serão:

$x+y$	3	4	5
p	1/3	1/3	1/3

xy	2	3	6
p	1/3	1/3	1/3

Calculemos $E(X)$, $E(Y)$, $E(X+Y)$ e $E(XY)$. Temos:

$$E(X) = \frac{1}{3} + \frac{2}{3} + \frac{3}{3} = 2 = E(Y)$$

$$E(X+Y) = \frac{3}{3} + \frac{4}{3} + \frac{5}{3} = 4 = E(X) + E(Y)$$


$$E(XY) = \frac{2}{3} + \frac{3}{3} + \frac{6}{3} = \frac{11}{3} \neq E(X) \cdot E(Y) = 4.$$

De modo geral, é verdade que

$$E(X+Y) = E(X) + E(Y), \quad (2.12)$$

para quaisquer v.a. X e Y , mas não é verdade que $E(XY) = E(X) \cdot E(Y)$; isto só acontece num caso particular que veremos a seguir.

Exemplo 2.9 - Considere a situação do exemplo 2.8, mas onde as extrações são feitas com reposição, isto é, a primeira bola é repostada antes de se retirar a segunda bola. Nestas condições, a $P(Y=y|X=x) = P(Y=y)$, isto é, o valor assumido por X não tem influência nenhuma no valor que Y vai assumir. A situação é descrita a seguir.



RESULTADOS		PROBABILIDADES	X	Y
1	1	1/9	1	1
1	2	1/9	1	2
1	3	1/9	1	3
2	1	1/9	2	1
2	2	1/9	2	2
2	3	1/9	2	3
3	1	1/9	3	1
3	2	1/9	3	2
3	3	1/9	3	3

A distribuição conjunta de X e Y é dada abaixo, juntamente com as marginais de X e de Y.

Y \ X	1	2	3	P(Y=y)
1	1/9	1/9	1/9	1/3
2	1/9	1/9	1/9	1/3
3	1/9	1/9	1/9	1/3
P(X=x)	1/3	1/3	1/3	1

Observe que, embora as distribuições marginais de X e Y sejam as mesmas que no exemplo anterior, a distribuição conjunta é diferente. A relação (2.11) ficará, neste caso,

$$P(X=x, Y=y) = P(X=x) \cdot P(Y=y), \quad (2.13)$$

para todos os possíveis pares (x,y), x=1,2,3; y=1,2,3.

Dizemos que X e Y são *independentes*.

Ainda temos, aqui, $E(X) = E(Y) = 2$ e (2.12) continua válida. A distribuição de XY será:

xy	1	2	3	4	6	9
p	1/9	2/9	2/9	1/9	2/9	1/9

de modo que $E(XY) = \frac{1}{9} + \frac{4}{9} + \frac{6}{9} + \frac{4}{9} + \frac{12}{9} + \frac{9}{9} = \frac{36}{9} = 4$, que é igual a $E(X) \cdot E(Y)$. Então, obtemos o fato importante:

"Se X e Y são v.a. independentes,

$$E(XY) = E(X) \cdot E(Y)". \quad (2.14)$$

Uma observação importante é a seguinte: para que X e Y sejam independentes é necessário que (2.13) esteja verificada para *todos os pares* (x, y) . Basta que ela não se verifique para *um* par para que X e Y não sejam independentes. Neste caso diremos que X e Y são *dependentes*. A pergunta que pode surgir é: pode (2.14) valer para v.a. dependentes? Ver exercícios para a resposta.

Exemplo 2.10 - Vamos calcular $\text{Var}(X)$, $\text{Var}(Y)$ e $\text{Var}(X+Y)$ para o exemplo 2.9.

Vimos que $E(X) = E(Y) = 2$, também

$$E(X^2) = E(Y^2) = 1 \times \frac{1}{3} + 4 \times \frac{1}{3} + 9 \times \frac{1}{3} = \frac{14}{3}.$$

Portanto,

$$\text{Var}(X) = \text{Var}(Y) = \frac{14}{3} - 2^2 = \frac{2}{3}$$

A distribuição de $X+Y$ é:

$x+y$	2	3	4	5	6
p	$1/9$	$2/9$	$3/9$	$2/9$	$1/9$

logo $E(X+Y) = 4$ e

$$E[(X+Y)^2] = 4 \times \frac{1}{9} + 9 \times \frac{2}{9} + 16 \times \frac{3}{9} + 25 \times \frac{2}{9} + 36 \times \frac{1}{9} = \frac{156}{9}$$

de modo que

$$\text{Var}(X+Y) = \frac{156}{9} - 16 = \frac{12}{9} = \frac{4}{3} = \text{Var}(X) + \text{Var}(Y).$$

Este resultado também é geral para v.a. independentes:

"Se X e Y são independentes, então

$$\text{Var}(X+Y) = \text{Var}(X) + \text{Var}(Y)."$$
 (2.15)

Esta relação pode não ser verdadeira se X e Y são dependentes. Para um exemplo, ver exercícios.

2.4 - REPRESENTAÇÕES GRÁFICAS PARA VARIÁVEIS

No exemplo 2.5 vimos um tipo de representação gráfica para uma v.a., V , naquele caso. Outro tipo de gráfico que pode ser usado é o histograma.

Exemplo 2.11 - Consideremos o lançamento de 3 moedas e sejam as v.a. X e Y definidas como segue: X é o número de "caras" que aparecem e Y o número de "seqüências", onde uma se

qüência é um conjunto (uma ou mais) de letras iguais.

RESULTADO	X	Y
C C C	3	1
C C R	2	2
C R C	2	3
C R R	1	2
R C C	2	2
R C R	1	3
R R C	1	2
R R R	0	1

A distribuição conjunta de X e Y é obtida facilmente, bem como as marginais.

Y \ X	0	1	2	3	P(Y=y)
1	1/8	0	0	1/8	2/8
2	0	2/8	2/8	0	4/8
3	0	1/8	1/8	0	2/8
P(X=x)	1/8	3/8	3/8	1/8	1

Na figura 2.3 temos representações gráficas para as distribuições de X e Y na forma de gráfico em barra e histogramas.




Figura 2.3

Podemos obter, também, um gráfico para a distribuição conjunta de X e Y , como na figura 2.4.




Figura 2.4

Um outro tipo de gráfico bastante útil na análise de dependência entre v.a. é o gráfico de dispersão, que consiste em colocar, num gráfico cartesiano, os possíveis pontos (x,y) . Para o caso em questão obtemos a figura 2.5, onde os círculos duplos indicam os pontos com probabilidade $2/8$.




Figura 2.5

Este tipo de gráfico pode nos mostrar, por exemplo: que à medida que x cresce, y também cresce; ou a medida que x cresce, y decresce, etc.

PROBLEMAS PARA O CAPÍTULO 2

- 2.1 - Considere uma urna contendo 3 bolas vermelhas e 5 bolas pretas. Retire três bolas, sem reposição e defina a v.a. X igual ao número de bolas pretas. Obtenha a distribuição de X , $3X$ e X^2 .
- 2.2 - Repita o problema anterior, mas agora considerando extrações com reposição.

2.3 - Considere o lançamento de três moedas. Se ocorre o evento CCC dizemos que temos *uma seqüência*, ao passo que se ocorre CRC temos *três seqüências*. Defina as v. a.: X igual ao número de caras obtidas e Y igual ao número de seqüências, isto para cada resultado possível. Assim, X(CRR) = 1 e Y(CRR) = 2. Obtenha as distribuições de X, Y, X+Y, |X-Y|. Faça o gráfico de dispersão das v.a. X e X+Y.

2.4 - Obtenha: E(X) e Var(3X), para o problema 2.1; E(X), E(Y), E(X+Y), Var(X+Y) para o problema 2.3.

2.5 - Suponha que a v.a. V tem a distribuição seguinte:

v	0	1
p	q	1-q

Obtenha E(V) e Var(V).

2.6 - Lance uma moeda e defina a v.a. V=0 se ocorre cara e V=1 se ocorre coroa e seja $q = P(\text{cara})$. Lance a moeda, agora, n vezes e para cada lançamento defina a v.a. V_i como acima, $i=1, \dots, n$. Seja $W = V_1 + \dots + V_n$.

a) qual o significado de W?

b) obtenha a distribuição de $W = V_1 + V_2$,

c) obtenha E(W) e Var(W).

2.7 - Utilizando a fórmula (1.3) prove que a variância de X pode ser obtida pela fórmula (2.4).

2.8 - Verifique se as v.a. X e Y definidas no problema 2.2 são independentes.

2.9 - No problema 2.2, calcule E(XY), E(X/Y) e E(X+Y).

2.10- Verifique, para o problema 2.2, se $E(XY) = E(X) \cdot E(Y)$. Utilizando a resposta do problema 2.8, o que você pode concluir? Verifique se $E(X/Y) = \frac{E(X)}{E(Y)}$.

2.11- Calcule $\text{Var}(X+Y)$, $\text{Var}(X)$ e $\text{Var}(Y)$ para as v.a. do problema 2.2. É verdade que $\text{Var}(X+Y) = \text{Var}(X) + \text{Var}(Y)$?

2.12- Se X é uma v.a. e x é um número real qualquer denominamos *função de distribuição acumulada* de X à função

$$F(x) = P(X \leq x).$$

Obtenha $F(x)$ para a v.a. X com distribuição dada por


x	-2	-1	0	1	2
p	1/5	1/5	1/5	1/5	1/5

Faça o gráfico de $F(x)$ e verifique que é uma "função em escada", não decrescente e tal que

$$F(x) = 0, x < 0 \text{ e } F(x) = 1, x \geq 2.$$

2.13- Para a função $F(x)$ do problema anterior, obtenha $F(-5)$, $F(-2)$, $F(0,5)$ e $F(556)$. Qual o valor de $F(1)-F(0)$? e de $F(-1)-F(-2)$?

2.14- O diagrama de dispersão entre as variáveis U e V é da do abaixo. Obter a distribuição conjunta e as distribuições marginais de U e V ; somente pelo exame do gráfico, obter $E(U)$.



2.15- Seja X com distribuição dada abaixo.

x	0	1	2
p	1/2	1/4	1/4

Calcule $E(X)$. Considere a v.a. $(X-a)^2$ e calcule $E(X-a)^2$ para $a = 0, 1/4, 1/2, 3/4, 1$. Obtenha o gráfico de $E(X-a)^2 = g(a)$. Para qual valor de a , $g(a)$ é mínimo?

2.16- Obtenha formalmente o resultado de 2.15, utilizando o fato que $X-a = X-E(X)+E(X)-a$.

2.17- Se $E(X) = \mu_X$, $E(Y) = \mu_Y$, a covariância entre X e Y é definida como

$$\text{Cov}(X,Y) = E[(X-\mu_X)(Y-\mu_Y)].$$

Mostre que:

- a) $\text{Cov}(X,Y) = \text{Cov}(Y,X)$;
- b) $\text{Cov}(X,X) = \text{Var}(X)$;
- c) $\text{Var}(X+Y) = \text{Var}(X) + \text{Var}(Y) + 2 \text{Cov}(X,Y)$;
- d) $\text{Cov}(X,Y) = E(XY) - E(X) \cdot E(Y)$;
- e) Se X e Y são independentes, $\text{cov}(X,Y) = 0$.

3 - ALGUNS MODELOS PROBABILÍSTICOS

Vamos apresentar, neste capítulo, alguns modelos que se adequam a uma série de problemas práticos. Estes modelos envolvem certos *parâmetros*, cujo conhecimento é indispensável quando queremos calcular certas probabilidades. Na maioria dos problemas reais, estes parâmetros são desconhecidos e há necessidade de fazer algum tipo de inferência sobre eles; este assunto será abordado em capítulos seguintes.

3.1 - A DISTRIBUIÇÃO BINOMIAL

Muitos experimentos são tais que os resultados possíveis apresentam ou não uma determinada característica.

- (1) Uma moeda é lançada; o resultado ou é "cara" ou não é (coroa);
- (2) Um dado é lançado; ou ocorre face 5 ou não (ocorrendo então, uma das faces 1, 2, 3, 4 ou 6);
- (3) Uma peça é escolhida ao acaso de um lote contendo 500 peças; esta peça é defeituosa ou não defeituosa;
- (4) Uma pessoa escolhida ao acaso dentre 1.000 pessoas é ou não do sexo masculino;
- (5) Um livro é escolhido ao acaso de uma biblioteca; este li

vro é ou não um livro de Matemática.

Em todos estes casos, estamos interessados na ocorrência de um *sucesso* (ocorrência de cara, face 5, peça defeituosa, etc.) ou *fracasso* (ocorrência de coroa, face diferente de 5, peça boa, etc.). Esta terminologia será usada freqüentemente.

Podemos, para cada experimento acima, definir uma v.a. X , que tem apenas dois valores: o valor 1, digamos, se ocorre sucesso e o valor 0 se ocorre fracasso. Se indicamos por $p = P(\text{sucesso})$, então a distribuição de probabilidades de X é dada por

x	1	0
$P(X=x)$	p	$1-p$

Os experimentos (1)-(5) são chamados *ensaios de Bernoulli* e a v.a. X tem uma *distribuição de Bernoulli*.

Imagine, agora, que repetimos um ensaio de Bernoulli n vezes, ou, como se diz também, obtemos uma *amostra de tamanho* n de uma distribuição de Bernoulli. Suponha, ainda, que as repetições sejam *independentes*, isto é, o resultado de um ensaio não tem influência nenhuma no resultado de outro qualquer ensaio. Uma amostra particular será constituída de uma seqüência de 0 e 1, tal como (0, 1, 1, 0, 1); aqui, $n=5$. A probabilidade de uma tal amostra será

$$(1-p)p \cdot p \cdot (1-p)p = p^3(1-p)^2.$$

O número de sucessos nesta amostra é igual a 3, sendo 2 o número de fracassos.

Podemos, considerar, pois as situações:

- (1') Uma moeda é lançada três vezes; qual a probabilidade de se obter exatamente duas caras?
- (2') Um dado é lançado cinco vezes; qual a probabilidade de se obter face 5 no máximo 3 vezes?
- (3') 10 peças são extraídas ao acaso, com reposição, de um lote contendo 500 peças idênticas; qual a probabilidade que todas sejam defeituosas, sabendo-se que 10% das peças são defeituosas?
- (4') Qual a probabilidade que, dentre 5 pessoas escolhidas ao acaso dentre 1.000 pessoas, duas sejam do sexo masculino?
- (5') Escolhemos ao acaso 3 livros de uma biblioteca contendo 10.000 volumes; qual a probabilidade de que 2 sejam de Matemática, sabendo-se que a biblioteca possui 1.000 livros de Matemática?

Observe que nos exemplos (4') e (5'), o fato de estarmos extraíndo os objetos de um conjunto muito grande, implica que podemos supor que as extrações sejam praticamente independentes.

Vamos resolver o problema (1'), supondo-se que a moeda é "honesta", isto é, $P(\text{sucesso}) = P(\text{cara}) = \frac{1}{2}$; indiquemos sucesso (cara) por S e fracasso (coroa) por F. Então,

estamos interessados na probabilidade do evento

$$A = \{SSF, SFS, FSS\},$$

ou, em termos da notação anterior, na probabilidade de obter as amostras (1, 1, 0), (1, 0, 1) ou (0, 1, 1). É claro que $P(A) = P(SSF) + P(SSF) + P(SFS) + P(FSS)$ e, devido à independência,

$$P(SSF) = \frac{1}{2} \times \frac{1}{2} \times \frac{1}{2} = \frac{1}{8} = P(SFS) = P(FSS).$$

Portanto, $P(A) = 3/8$.

Se a moeda não tiver $P(S) = \frac{1}{2}$ e esta for igual a p , $0 < p < 1$, então, sendo $q = 1-p = P(F)$,

$$P(SSF) = p \cdot p \cdot q = p^2 \cdot q,$$

$$P(SFS) = p \cdot q \cdot p = p^2 \cdot q,$$

$$P(FSS) = q \cdot p \cdot p = p^2 \cdot q, \text{ de modo que}$$

$$P(A) = 3p^2 \cdot q.$$

Uma característica importante dos experimentos que estamos considerando é que estamos interessados apenas no *número total* de sucessos, e não na ordem em que eles ocorrem. Podemos construir a tabela que segue, para $n=3$ lançamentos da moeda. (Vide tabela na página seguinte).

Vamos designar por $b(k;n,p)$ a probabilidade de se obter k sucessos em n provas de Bernoulli, sendo p a probabilidade de sucesso em cada uma delas. No exemplo dado,

$$b(2;3,\frac{1}{2}) = \frac{3}{8}.$$

NÚMERO DE SUCESSOS	PROBABILIDADE	$p=1/2$
0	q^3	1/8
1	$3pq^2$	3/8
2	$3p^2q$	3/8
3	p^3	1/8

enquanto que

$$b(2;3,p) = 3p^2q.$$

Note que $q^3+3pq^2+3p^2q+p^3 = (q+p)^3 = 1$, pois $p+q = 1$.

Em termos de v.a., se S_n indica o número total de sucessos em n provas de Bernoulli, então $P(S_n=k) = b(k;n,p)$. É claro que os possíveis valores de S_n são $0,1,2,\dots,n$ e os pares $(k;b(k;n,p))$ constituem a chamada *distribuição binomial*. Para o exemplo (1'), com $p=\frac{1}{2}$, obtemos o gráfico da figura 3.1.




Figura 3.1

Em uma seqüência de n provas, uma seqüência qualquer com k sucessos e $n-k$ fracassos, ou, o que é o mesmo, uma seqüência de k uns e $n-k$ zeros, terá probabilidade

$$p^k \cdot q^{n-k}. \quad (3.1)$$

Esta função, para esta seqüência de resultados, encarada como função de p , é chamada *função de verossimilhança*.

Ainda no exemplo (1'),

$$P(S_3=1) = b(1,3,p) = 3pq^2 = \binom{3}{1} pq^2.$$

Para $n=3$, podemos escrever, pois,

$$P(S_3=k) = b(k,3,p) = \binom{3}{k} p^k q^{3-k}, \quad (3.2)$$

para $k=0, 1, 2, 3$.

Para se obter uma fórmula geral, basta saber quantas seqüências com k sucessos e $n-k$ fracassos podemos formar, cada uma tendo probabilidade dada por (3.1). É fácil ver que existem $\frac{n!}{k!(n-k)!} = \binom{n}{k}$ tais seqüências, de modo que

$$b(k;n,p) = \binom{n}{k} p^k q^{n-k}, \quad (3.3)$$

$k=0, 1, 2, \dots, n$.

Vamos considerar, agora, o problema (3'). Aqui, temos $n=10$ provas de Bernoulli, cada uma com $P(\text{sucesso}) = 1 - P(\text{peça defeituosa}) = p = 0,1$. Queremos

$$P(S_{10}=10) = b(10;10, \frac{1}{10}).$$

Utilizando (3.3),

$$b(10;10, \frac{1}{10}) = \binom{10}{10} \cdot \left(\frac{1}{10}\right)^{10} \cdot \left(\frac{9}{10}\right)^0 = \left(\frac{1}{10}\right)^{10}$$

A variável aleatória S_n pode ser pensada como a soma de n variáveis aleatórias, definidas do seguinte modo:

$$X_1 = \begin{cases} 1, & \text{se na primeira prova ocorre sucesso} \\ 0, & \text{se na primeira prova ocorre fracasso} \end{cases}$$

$$X_2 = \begin{cases} 1, & \text{se na segunda prova ocorre sucesso} \\ 0, & \text{se na segunda prova ocorre fracasso} \end{cases}$$

⋮

$$X_i = \begin{cases} 1, & \text{se na } i\text{-ésima prova ocorre sucesso} \\ 0, & \text{se na } i\text{-ésima prova ocorre fracasso} \end{cases}$$

⋮

$$X_n = \begin{cases} 1, & \text{se na } n\text{-ésima prova ocorre sucesso} \\ 0, & \text{se na } n\text{-ésima prova ocorre fracasso} \end{cases}$$

Portanto, $S_n = X_1 + X_2 + \dots + X_n$. Observe que todas as variáveis X_1, X_2, \dots, X_n têm os mesmos valores (0 ou 1), com as mesmas probabilidades, isto é, $P(X_i=1) = p$, $P(X_i=0) = q = 1-p$. Devido à independência das provas, as v.a. X_1, \dots, X_n são inpendentes. Dizemos que elas são independentes e identicamente distribuídas (i.i.d.).

É imediato que

$$E(X_1) = 1 \times p + 0 \times q = p, \quad (3.4)$$

ao passo que

$$E(X_1^2) = 1^2 \times p + 0^2 \times q = p,$$

do que decorre

$$\text{Var}(X_1) = p - p^2 = p(1-p) = pq. \quad (3.5)$$

Daf, pela generalização da propriedade (2.12),

$$E(S_n) = np, \quad (3.6)$$

enquanto que, pela independência e usando uma generalização imediata de (2.15),

$$\text{Var}(S_n) = npq. \quad (3.7)$$

Para o exemplo (3'),

$$E(S_{10}) = 10 \times \frac{1}{10} = 1, \quad \text{Var}(S_{10}) = 10 \times \frac{1}{10} \times \frac{9}{10} = \frac{9}{10}.$$

Enquanto foi relativamente fácil obter $b(2, 3, \frac{1}{2})$ para o exemplo (1'), não seria imediato obter, por exemplo,

$$b(20; 17; 0,9) = \binom{20}{17} (0,9)^{17} \cdot (0,1)^3.$$

Felizmente, existem tabelas que dão as probabilidades (3.3) para um grande número de valores de n e p . Utilizando a tabela 1 do Apêndice 1, vemos que a probabilidade acima é dada por 0,19.

Para n grande (maiores que 10, se p não está muito próximo de 0 ou 1) veremos uma maneira de aproximar $b(k; n, p)$.

Se n grande e p está próximo de 0, podemos usar a aproximação

$$b(k;n,p) \approx \frac{e^{-np} (np)^k}{k!}, \quad (3.8)$$

e uma tabela da função do segundo membro de (3.8) encontra-se no Apêndice 1 (tabela 4).

Por exemplo,

$$b(2;1.000;0,0001) = \frac{e^{-0,1} \cdot (0,1)^2}{2!} = 0,0045.$$

3.2 - A DISTRIBUIÇÃO HIPERGEOMÉTRICA

Este modelo é adequado quando consideramos extrações casuais feitas de uma população, considerada dividida em dois atributos, e estas extrações são feitas *sem reposição*. Para ilustrar, considere uma população de N objetos, r dos quais são defeituosos e $N-r$ são não defeituosos. Um grupo de n elementos é escolhido ao acaso. Vamos calcular a probabilidade de que este grupo contenha k defeituosos. Observe que $0 \leq k \leq \min(r,n)$. É fácil ver que esta probabilidade é dada por

$$p_k = \frac{\binom{r}{k} \binom{N-r}{n-k}}{\binom{N}{n}}. \quad (3.9)$$

Os pares (k, p_k) constituem a *distribuição hipergeométrica*.

Se definimos a v.a. X igual ao número de defeituo-

tos na amostra, então $P(X=k)$ é dada por (3.9).

Exemplo 3.1 - Em problemas de controle de qualidade, lotes com N elementos são examinados. O número de elementos com defeito, r , é desconhecido. Colhemos uma amostra de n elementos e determinamos k . Somente para ilustrar, suponha que num lote de $N=100$ peças, $r=10$ são defeituosas. Escolhendo-se $n=5$ peças ao acaso, a probabilidade de não se obter peças defeituosas é

$$p_0 = \frac{\binom{10}{0} \binom{90}{5}}{\binom{100}{5}} = \frac{\binom{90}{5}}{\binom{100}{5}},$$

enquanto que a probabilidade de se obter pelo menos uma defeituosa é

$$p_1 + p_2 + \dots + p_5 = 1 - p_0 = 1 - \frac{\binom{90}{5}}{\binom{100}{5}}$$

Pode ser demonstrado que a v.a. X definida acima tem média e variância dadas por

$$E(X) = np, \quad (3.10)$$

$$\text{Var}(X) = np(1-p) \cdot \frac{N-n}{N-1}, \quad (3.11)$$

onde $p = \frac{r}{N}$ é a probabilidade de se obter uma peça defeituosa em uma única extração. Se N é grande quando comparado com n , então extrações com ou sem reposição serão praticamente e-

quivalentes, de modo que as probabilidades dadas por (3.9) serão quase iguais as dadas pela fórmula (3.3), isto é, $p_k \approx b(k;n,p)$. Do mesmo modo, os resultados (3.10) e (3.11) serão praticamente iguais aos valores correspondentes da distribuição binomial (*).

3.3 - A DISTRIBUIÇÃO NORMAL

Vamos considerar a distribuição binomial para $p = \frac{1}{2}$ e n variável, digamos $n=5, 10$ e 20 . Obtemos os histogramas da figura 3.2.




Figura 3.2

(*) Formalmente, considere limites para $N \rightarrow \infty$, com $\frac{r}{N} = p$ fixo.

Dado que $p=1/2$, as distribuições serão simétricas ao redor das respectivas médias, $\frac{5}{2}$, 5 e 10.

Vejamos, agora, os histogramas para o caso $p = \frac{1}{4}$ e os mesmos valores de n acima, isto é, 5, 10 e 20 (Fig. 3.3).




Figura 3.3

As médias agora são 1,25; 2,5 e 5 e as distribuições não são simétricas ao redor destas médias.

Observando as figuras podemos observar os seguintes fatos:

- para $p=\frac{1}{2}$, por exemplo, à medida que n cresce, a distribuição move-se para a direita, torna-se mais acha

tada e mais espalhada;

b) para $p=\frac{1}{4}$, quando n cresce, a distribuição vai "perdendo a sua assimetria" (observe o histograma para $n=20$

Vimos que, quando n é grande, é difícil calcular as probabilidades $b(k;n,p)$. A idéia é obtermos aproximações para estas probabilidades. Observando os histogramas acima, vemos que uma sugestão é aproximar a área do histograma pela área sob uma curva contínua. Tal curva é chamada *curva normal*. E aproximaremos probabilidades relativas a uma binomial por probabilidades relativas a uma *distribuição normal*. (Veja figura 3.4, para $n=10$, $p=\frac{1}{2}$).




Figura 3.4

A distribuição normal difere das distribuições apresentadas até agora no sentido que é uma distribuição variável contínua, ou seja, através desta distribuição associamos probabilidades a intervalos de números reais. Por exemplo, se escolhemos ao acaso um indivíduo de uma população e medimos sua altura, podemos supor que ao resultado do

experimento associamos uma v.a. X que assume valores em um certo intervalo de números reais, $[0,3]$, por exemplo, tomando o metro como unidade. É claro que esta é uma aproximação conveniente da realidade, pois a medida da altura do indivíduo dependerá da precisão do instrumento de medida. Assim, se dizemos que a altura encontrada é 1,75 m, na realidade esta será um valor qualquer entre 1,745 m e 1,755 m.

Na seção seguinte daremos algumas idéias sobre distribuições de variáveis contínuas; para uma tal v.a. X a probabilidade de X estar num certo intervalo, $[a,b]$ digamos, é calculada como sendo a área, entre a e b , sob uma curva, que é chamada função de densidade de X . Tal função será sempre não negativa e a área total sob a curva será igual à unidade. Compare com um histograma, cuja área total também é unitária. (Ver figura 3.5).

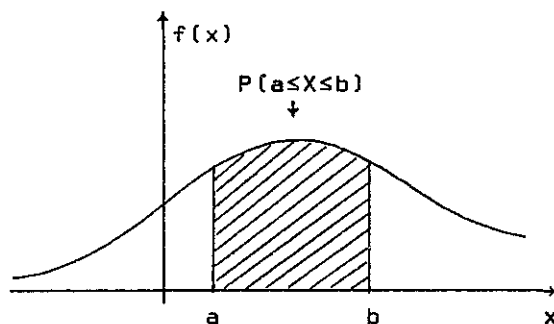


Figura 3.5

A distribuição normal é caracterizada por uma função densidade, e o gráfico desta função tem a forma vista

na figura 3.4.

Na realidade, não temos *uma* distribuição normal, mas uma *família* de distribuições normais, que são caracterizadas por dois parâmetros, que chamaremos μ e σ , $-\infty < \mu < \infty$ e $\sigma > 0$. Variando μ e σ teremos os diversos membros da família.

Nos gráficos da figura 3.6 temos três exemplos:

- a) curva normal com $\mu=0$ e $\sigma=1$;
- b) curva normal com $\mu=0$ e $\sigma=2$;
- c) curva normal com $\mu=2$ e $\sigma=1$.

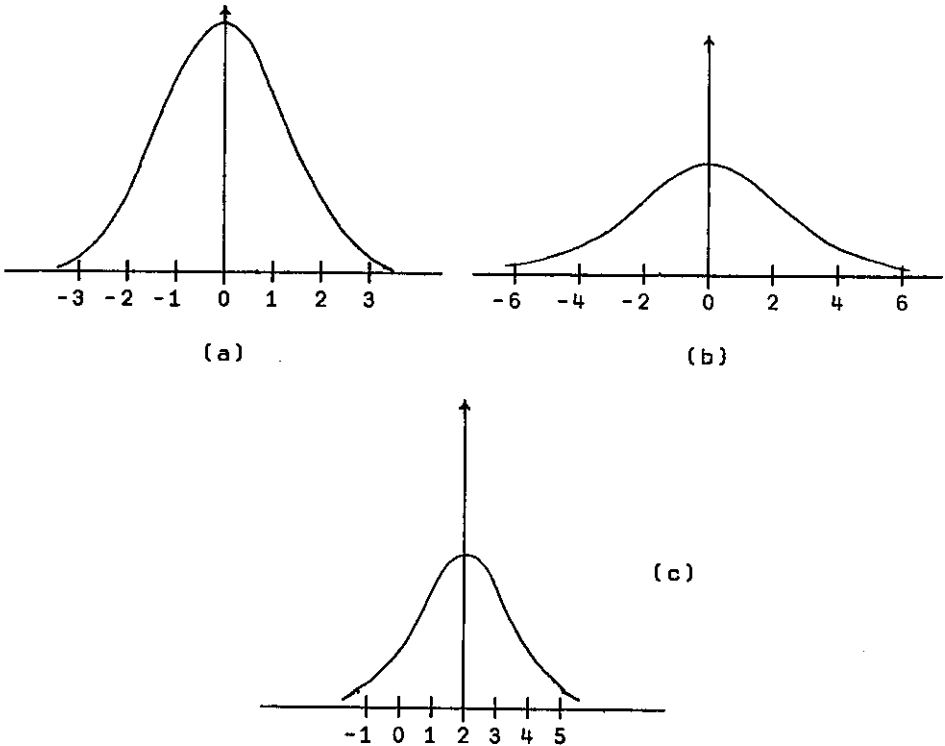


Figura 3.6

Algumas observações sobre as curvas:

- a) Para um mesmo μ ($\mu=0$), a curva é mais achatada e mais espalhada para um σ maior;
- b) as curvas são simétricas em relação ao ponto μ ;
- c) praticamente toda a área está concentrada entre os pontos $\mu-3\sigma$ e $\mu+3\sigma$.

O que pode ser demonstrado é que os parâmetros μ e σ correspondem à média e ao desvio padrão da distribuição; portanto σ^2 é a variância da v.a. em questão.

Para calcularmos probabilidades sob uma curva normal é necessário, antes, sabermos calcular probabilidades sob uma particular normal, chamada *normal reduzida* ou *normal padrão*, que é caracterizada pelos valores $\mu=0$ e $\sigma=1$. Dizemos, também, que temos uma "normal 0,1" e escrevemos: $N(0,1)$. Ver figura 3.6 (a). A tabela 2 do Apêndice 1 dá as probabilidades sob uma curva normal padrão, que nada mais




Figura 3.7

são do que as correspondentes áreas sob a curva. A tabela em questão fornece a probabilidade de que a variável Z , normal padrão, esteja entre 0 e um valor, z_c : $P(0 \leq Z \leq z_c)$. (Fig.3.7).

Assim, se $z_c = 1,73$, $P(0 \leq Z \leq 1,73) = 0,4582$.

Observe que (figura 3.8):

- 1) $P(-1,73 \leq Z \leq 0) = P(0 \leq Z \leq 1,73) = 0,4582$, devido à simetria da curva.
- 2) $P(Z \geq 1,73) = 0,5 - P(0 \leq Z \leq 1,73) = 0,5 - 0,4582 = 0,0418$, pois $P(Z \geq 0) = 0,5 = P(Z \leq 0)$.
- 3) $P(Z < -1,73) = P(Z \geq 1,73) = 0,0418$.
- 4) $P(0,47 \leq Z \leq 1,73) = P(0 \leq Z \leq 1,73) - P(0 \leq Z \leq 0,47) = 0,4582 - 0,1808 = 0,2774$.




Figura 3.8

Suponha, agora, que X seja uma v.a. com distribuição normal de média μ e variância σ^2 , que indicaremos $N(\mu, \sigma^2)$. Então, a v.a. Z , tal que

$$Z = \frac{X - \mu}{\sigma} \quad (3.12)$$

terá distribuição normal com média 0 e variância 1, como é fácil ver (O fato que Z é normal não será provado aqui).

De fato,

$$E(Z) = E\left(\frac{X - \mu}{\sigma}\right) = \frac{1}{\sigma} E(X - \mu) = \frac{1}{\sigma} E(X) - \frac{1}{\sigma} E(\mu) = \frac{\mu}{\sigma} - \frac{\mu}{\sigma} = 0,$$

$$\text{Var}(Z) = \text{Var}\left(\frac{X - \mu}{\sigma}\right) = \frac{1}{\sigma^2} \text{Var}(X - \mu) = \frac{1}{\sigma^2} \text{Var}(X) = \frac{\sigma^2}{\sigma^2} = 1$$

Por exemplo, calculemos $P(2 \leq X \leq 5)$ se X é $N(3, 16)$, isto é, $\mu=3$, $\sigma^2=16$. Utilizando (3.12),

$$P(2 \leq X \leq 5) = P\left(\frac{2 - \mu}{\sigma} \leq \frac{X - \mu}{\sigma} \leq \frac{5 - \mu}{\sigma}\right) = P\left(\frac{2 - 3}{4} \leq Z \leq \frac{5 - 3}{4}\right) = P\left(-\frac{1}{4} \leq Z \leq \frac{1}{2}\right).$$




Figura 3.9

Portanto, a probabilidade que X esteja entre 2 e 5 é igual à probabilidade que Z esteja entre -0,25 e 0,5, e

utilizando a tabela 2, vemos que

$$P(-0,25 \leq Z \leq 0,5) = 0,0987 + 0,1915 = 0,2902$$

ou seja,

$$P(2 \leq X \leq 5) = 0,2902.$$

Vejamos, agora, como podemos aproximar probabilidades binomiais através da normal.

Suponha que a v.a. Y tem distribuição binomial com $n=10$ e $p=\frac{1}{2}$ e queremos calcular $P(Y \geq 7)$. Vemos que (fig.3.10)




Figura 3.10

$P(Y=7)$ = área do retângulo de base unitária e altura igual à $P(Y=7)$, e assim por diante, logo $P(Y \geq 7)$ é a soma das áreas dos retângulos hachurados na figura 3.10. A idéia é aproximar tal área pela área, sob a curva normal, à direita de 6,5. Qual curva normal? Aquela de média

$$\mu = np = 10 \times \frac{1}{2} = 5 \text{ e variância } \sigma^2 = np(1-p) = 10 \times \frac{1}{2} \times \frac{1}{2} = 2,5.$$

Ver figura 3.11.

Suponha, agora, que X seja uma v.a. com distribuição normal de média μ e variância σ^2 , que indicaremos $N(\mu, \sigma^2)$. Então, a v.a. Z , tal que

$$Z = \frac{X - \mu}{\sigma} \quad (3.12)$$

terá distribuição normal com média 0 e variância 1, como é fácil ver (O fato que Z é normal não será provado aqui).

De fato,

$$E(Z) = E\left(\frac{X - \mu}{\sigma}\right) = \frac{1}{\sigma} E(X - \mu) = \frac{1}{\sigma} E(X) - \frac{1}{\sigma} E(\mu) = \frac{\mu}{\sigma} - \frac{\mu}{\sigma} = 0,$$

$$\text{Var}(Z) = \text{Var}\left(\frac{X - \mu}{\sigma}\right) = \frac{1}{\sigma^2} \text{Var}(X - \mu) = \frac{1}{\sigma^2} \text{Var}(X) = \frac{\sigma^2}{\sigma^2} = 1$$

Por exemplo, calculemos $P(2 \leq X \leq 5)$ se X é $N(3, 16)$, isto é, $\mu=3$, $\sigma^2=16$. Utilizando (3.12),

$$P(2 \leq X \leq 5) = P\left(\frac{2 - \mu}{\sigma} \leq \frac{X - \mu}{\sigma} \leq \frac{5 - \mu}{\sigma}\right) = P\left(\frac{2 - 3}{4} \leq Z \leq \frac{5 - 3}{4}\right) = P\left(-\frac{1}{4} \leq Z \leq \frac{1}{2}\right).$$




Figura 3.9

Portanto, a probabilidade que X esteja entre 2 e 5 é igual à probabilidade que Z esteja entre $-0,25$ e $0,5$, e

utilizando a tabela 2, vemos que

$$P(-0,25 \leq Z \leq 0,5) = 0,0987 + 0,1915 = 0,2902$$

ou seja,

$$P(2 \leq X \leq 5) = 0,2902.$$

Vejamos, agora, como podemos aproximar probabilidades binomiais através da normal.

Suponha que a v.a. Y tem distribuição binomial com $n=10$ e $p=\frac{1}{2}$ e queremos calcular $P(Y \geq 7)$. Vemos que (fig.3.10)




Figura 3.10

$P(Y=7)$ = área do retângulo de base unitária e altura igual à $P(Y=7)$, e assim por diante, logo $P(Y \geq 7)$ é a soma das áreas dos retângulos hachurados na figura 3.10. A idéia é aproximar tal área pela área, sob a curva normal, à direita de 6,5. Qual curva normal? Aquela de média

$$\mu = np = 10 \times \frac{1}{2} = 5 \text{ e variância } \sigma^2 = np(1-p) = 10 \times \frac{1}{2} \times \frac{1}{2} = 2,5.$$

Ver figura 3.11.




Figura 3.11

Chamando X tal v.a. normal,

$$\begin{aligned} P(Y \geq 7) &\approx P(X \geq 6,5) = P\left(\frac{X - \mu}{\sigma} \geq \frac{6,5 - \mu}{\sigma}\right) = P\left(\frac{X - 5}{\sqrt{2,5}} \geq \frac{6,5 - 5}{\sqrt{2,5}}\right) = \\ &= P\left(Z \geq \frac{1,5}{1,58}\right) \approx P(Z \geq 0,94) = 0,1736. \end{aligned}$$

A verdadeira probabilidade é 0,172.

Vamos calcular $P(3 < Y \leq 6) = P(Y=4) + P(Y=5) + P(Y=6)$.




Figura 3.12

Vemos, através da figura 3.12, que a aproximação a ser feita deve ser

$$P(3 < Y \leq 6) \approx P(3,5 \leq X \leq 6,5) = P\left(\frac{3,5 - 5}{1,58} \leq Z \leq \frac{6,5 - 5}{1,58}\right) =$$

$$= P(-0,94 \leq Z \leq 0,94) = 0,6528,$$

ao passo que a probabilidade verdadeira é 0,656.

A justificativa formal de tal aproximação é dada pelo chamado Teorema de De Moivre-Laplace, que é caso particular do chamado Teorema do Limite Central. Ver Apêndice 2.

3.4 - VARIÁVEIS ALEATÓRIAS CONTÍNUAS

Vimos até agora, com exceção da normal, variáveis aleatórias que têm distribuições discretas, ou seja, os valores da v.a. pertencem a um conjunto enumerável (finito ou infinito) de números.

Quando isto não acontece, necessitamos de variáveis que podem tomar valores em um contínuo de pontos, de tal sorte que a "massa" em um particular ponto seja 0. Só terá sentido, para uma variável aleatória contínua X , falar na probabilidade de X pertencer a um certo intervalo $[a,b]$. Para uma v.a. discreta Y falamos na probabilidade de Y assumir um valor y_j , isto é, $P(Y=y_j)$.

A maneira de caracterizar uma v.a. contínua X é através de uma função $f(\cdot)$, que seja não negativa e de tal modo que a área total sob a curva representativa de $f(\cdot)$ seja unitária. Deste modo, definimos (figura 3.13)

$$P(a \leq X \leq b) = \text{área sob } f(\cdot) \quad (3.13)$$

desde a até b




Figura 3.11

Chamando X tal v.a. normal,

$$\begin{aligned} P(Y \geq 7) &= P(X \geq 6,5) = P\left(\frac{X - \mu}{\sigma} \geq \frac{6,5 - \mu}{\sigma}\right) = P\left(\frac{X - 5}{\sqrt{2,5}} \geq \frac{6,5 - 5}{\sqrt{2,5}}\right) = \\ &= P\left(Z \geq \frac{1,5}{1,58}\right) = P(Z \geq 0,94) = 0,1736. \end{aligned}$$

A verdadeira probabilidade é 0,172.

Vamos calcular $P(3 < Y \leq 6) = P(Y=4) + P(Y=5) + P(Y=6)$.




Figura 3.12

Vemos, através da figura 3.12, que a aproximação a ser feita deve ser

$$P(3 < Y \leq 6) = P(3,5 \leq X \leq 6,5) = P\left(\frac{3,5 - 5}{1,58} \leq Z \leq \frac{6,5 - 5}{1,58}\right) =$$

$$= P(-0,94 \leq Z \leq 0,94) = 0,6528,$$

ao passo que a probabilidade verdadeira é 0,656.

A justificativa formal de tal aproximação é dada pelo chamado Teorema de De Moivre-Laplace, que é caso particular do chamado Teorema do Limite Central. Ver Apêndice 2.

3.4 - VARIÁVEIS ALEATÓRIAS CONTÍNUAS

Vimos até agora, com exceção da normal, variáveis aleatórias que têm distribuições discretas, ou seja, os valores da v.a. pertencem a um conjunto enumerável (finito ou infinito) de números.

Quando isto não acontece, necessitamos de variáveis que podem tomar valores em um contínuo de pontos, de tal sorte que a "massa" em um particular ponto seja 0. Só terá sentido, para uma variável aleatória contínua X , falar na probabilidade de X pertencer a um certo intervalo $[a, b]$. Para uma v.a. discreta Y falamos na probabilidade de Y assumir um valor y_j , isto é, $P(Y=y_j)$.

A maneira de caracterizar uma v.a. contínua X é através de uma função $f(\cdot)$, que seja não negativa e de tal modo que a área total sob a curva representativa de $f(\cdot)$ seja unitária. Deste modo, definimos (figura 3.13)

$$P(a \leq X \leq b) = \text{área sob } f(\cdot) \quad (3.13)$$

desde a até b




Figura 3.13

A função $f(\cdot)$ é chamada *função densidade* de X .

Exemplo 3.2 - Se $f(x) = 2x$, para $0 \leq x \leq 1$ e zero fora deste intervalo, vemos que $f(x) \geq 0, \forall x$ e a área sob $f(\cdot)$ é unitária. (Figura 3.14).




Figura 3.14

Se queremos calcular $P(0 \leq X \leq \frac{1}{2})$, vemos que esta probabilidade é igual a área do triângulo de base $\frac{1}{2}$ e altura 1 hachurado na figura 3.14, logo a probabilidade em questão é $\frac{1/2 \times 1}{2} = 1/4$.

Exemplo 3.3 - A chamada *distribuição uniforme* sobre o intervalo $[0,1]$ é aquela cuja função densidade é dada por:

$$f(x) = \begin{cases} 1, & x \in [0,1] \\ 0, & x \notin [0,1]. \end{cases} \quad (3.14)$$




Figura 3.15

Observe que $P\left(\frac{1}{4} \leq X \leq \frac{3}{4}\right) = \frac{1}{2}$, que é a área do retângulo de lados 1 e $\frac{3}{4} - \frac{1}{4} = \frac{2}{4} = \frac{1}{2}$ da figura 3.15.

Formalmente,

$$P(a \leq X \leq b) = \int_a^b f(x) dx. \quad (3.15)$$

Se queremos calcular a média de uma v.a. X com função densidade $f(x)$, podemos pensar da seguinte maneira. Primeiramente, observe que $f(x)$ não é uma probabilidade, mas se h é pequeno, (figura 3.16).

$$P(x \leq X \leq x+h) = h \cdot f(x). \quad (3.16)$$




Figura 3.16




Figura 3.13

A função $f(\cdot)$ é chamada *função densidade* de X .

Exemplo 3.2 - Se $f(x) = 2x$, para $0 \leq x \leq 1$ e zero fora deste intervalo, vemos que $f(x) \geq 0, \forall x$ e a área sob $f(\cdot)$ é unitária. (Figura 3.14).




Figura 3.14

Se queremos calcular $P(0 \leq X \leq \frac{1}{2})$, vemos que esta probabilidade é igual a área do triângulo de base $\frac{1}{2}$ e altura 1 hachurado na figura 3.14, logo a probabilidade em questão é $\frac{1/2 \times 1}{2} = 1/4$.

Exemplo 3.3 - A chamada *distribuição uniforme* sobre o intervalo $[0,1]$ é aquela cuja função densidade é dada por:

$$f(x) = \begin{cases} 1, & x \in [0,1] \\ 0, & x \notin [0,1]. \end{cases} \quad (3.14)$$




Figura 3.15

Observe que $P\left(\frac{1}{4} \leq X \leq \frac{3}{4}\right) = \frac{1}{2}$, que é a área do retângulo de lados 1 e $\frac{3}{4} - \frac{1}{4} = \frac{2}{4} = \frac{1}{2}$ da figura 3.15.

Formalmente,

$$P(a \leq X \leq b) = \int_a^b f(x)dx. \quad (3.15)$$

Se queremos calcular a média de uma v.a. X com função densidade $f(x)$, podemos pensar da seguinte maneira. Primeiramente, observe que $f(x)$ não é uma probabilidade, mas se h é pequeno, (figura 3.16)..

$$P(x \leq X \leq x+h) \approx h \cdot f(x). \quad (3.16)$$




Figura 3.16

Portanto, dividamos o intervalo $[a,b]$ onde $f(x) > 0$ em n partes de amplitudes iguais a $h = \frac{b-a}{n}$ (figura 3.17).




Figura 3.17

Defina a v.a. Y que assume os valores x_1, x_2, \dots . Por (3.16), temos, por exemplo,

$$P(Y=x_3) = P(x_3 \leq Y \leq x_3+h) = f(x_3) \cdot h.$$

Desta maneira,

$$E(Y) = \sum_{i=1}^n x_i f(x_i) h. \quad (3.17)$$

Defina, então,

$$E(X) = \lim_{n \rightarrow \infty} E(Y). \quad (3.18)$$

Para o exemplo 3.2, cada intervalo terá amplitude $1/n$ e $x_i = i/n$, $i=0, \dots, n-1$, portanto,

$$E(Y) = \sum_{i=0}^{n-1} \frac{1}{n} \cdot \frac{2i}{n} \cdot \frac{1}{n} = \frac{2}{n^3} \sum_{i=0}^{n-1} i^2 = \frac{2}{6} \left(1 - \frac{1}{n}\right) \left(2 - \frac{1}{n}\right) \rightarrow \frac{4}{6},$$

quando $n \rightarrow \infty$.

É claro que, da definição de integral, de (3.17)

vem

$$E(X) = \int_a^b x f(x) dx. \quad (3.19)$$

Exemplo 3.4 - A função de densidade normal é dada por

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad -\infty < x < \infty, \quad (3.20)$$

com $-\infty < \mu < \infty$ e $\sigma > 0$.

Para uma v.a. com densidade (3.20) temos:

- a) $E(X) = \mu$ e $\text{Var}(X) = \sigma^2$;
- b) $\mu \pm \sigma$ são dois pontos de inflexão da curva;
- c) $\frac{1}{\sigma\sqrt{2\pi}}$ é o ponto máximo de $f(x)$;
- d) $\lim_{x \rightarrow \pm\infty} f(x) = 0$.




Figura 3.18

Temos, na realidade, uma família $f(x; \mu, \sigma)$ de densidades normais, variando μ e σ .

Exempo 3.5 - Dizemos que X tem *distribuição exponencial* se

Portanto, dividamos o intervalo $[a,b]$ onde $f(x) > 0$ em n partes de amplitudes iguais a $h = \frac{b-a}{n}$ (figura 3.17).




Figura 3.17

Defina a v.a. Y que assume os valores x_1, x_2, \dots . Por (3.16), temos, por exemplo,

$$P(Y=x_3) = P(x_3 \leq Y \leq x_3+h) = f(x_3) \cdot h.$$

Desta maneira,

$$E(Y) = \sum_{i=1}^n x_i f(x_i)h. \quad (3.17)$$

Defina, então,

$$E(X) = \lim_{n \rightarrow \infty} E(Y). \quad (3.18)$$

Para o exemplo 3.2, cada intervalo terá amplitude $1/n$ e $x_i = i/n$, $i=0, \dots, n-1$, portanto,

$$E(Y) = \sum_{i=0}^{n-1} \frac{i}{n} \cdot \frac{2i}{n} \cdot \frac{1}{n} = \frac{2}{n^3} \sum_{i=0}^{n-1} i^2 = \frac{2}{6} \left(1 - \frac{1}{n}\right) \left(2 - \frac{1}{n}\right) \rightarrow \frac{4}{6},$$

quando $n \rightarrow \infty$.

É claro que, da definição de integral, de (3.17)

vem

$$E(X) = \int_a^b x f(x) dx. \quad (3.19)$$

Exemplo 3.4 - A função de densidade normal é dada por

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad -\infty < x < \infty, \quad (3.20)$$

com $-\infty < \mu < \infty$ e $\sigma > 0$.

Para uma v.a. com densidade (3.20) temos:

- a) $E(X) = \mu$ e $\text{Var}(X) = \sigma^2$;
- b) $\mu \pm \sigma$ são dois pontos de inflexão da curva;
- c) $\frac{1}{\sigma\sqrt{2\pi}}$ é o ponto máximo de $f(x)$;
- d) $\lim_{x \rightarrow \pm\infty} f(x) = 0$.




Figura 3.18

Temos, na realidade, uma família $f(x; \mu, \sigma)$ de densidades normais, variando μ e σ .

Exempo 3.5 - Dizemos que X tem *distribuição exponencial* se

a densidade de X é dada por

$$f(x) = \begin{cases} \alpha e^{-\alpha x}, & x \geq 0 \\ 0 & , x < 0 \end{cases} \quad (3.21)$$




Figura 3.19

É fácil ver que $E(X) = \frac{1}{\alpha}$ e $\text{Var}(X) = \frac{1}{\alpha^2}$. (Ver exercícios).

PROBLEMAS PARA O CAPÍTULO 3

3.1 - Obtenha $b(k; n, p)$ para:

- a) $n=10, p=0,4, k=3$;
- b) $n=10, p=0,4, k=9$;
- c) $n=15, p=0,5, k=10$.

3.2 - Se X é uma v.à. binomial com parâmetro $n=5$ e $p=\frac{1}{2}$, obtenha:

- a) $P(X=0 \text{ ou } X=1)$
- b) $P(X \geq 2)$
- c) $P(X \leq 4)$
- d) $P(2 < X \leq 5)$.

3.3 - Num teste tipo certo-errado, com 50 questões, qual é a probabilidade que um aluno acerte 80% das questões, supondo que ele as responde ao acaso?

3.4 - Mesmo problema, com 5 alternativas para cada questão.

3.5 - Numa partida de 20 rádios foram escolhidas, ao acaso, 5 unidades para serem inspecionadas. Sabe-se que há 20% de rádios defeituosos. Calcular as probabilidades abaixo, nos dois casos:

a) extração com reposição;

b) extração sem reposição:

1) probabilidade que a amostra seja formada só por rádios com defeito;

2) probabilidade que haja apenas um com defeito;

3) probabilidade que todos sejam bons.

3.6 - Em um experimento binomial com 3 provas, a probabilidade de exatamente 2 sucessos é 12 vezes a probabilidade de 3 sucessos. Encontre p.

3.7 - Em uma pesquisa de opinião pública, 3 dentre 4 pessoas entrevistadas são favoráveis a uma certa proposição. Em uma amostra de 10 pessoas entrevistadas, qual a probabilidade que pelo menos 3 sejam favoráveis?

3.8 - Prove que

$$b(k+1; n, p) = \frac{(n-k)p}{(k+1)(1-p)} b(k; n, p).$$

3.9 - Y é uma v.a. binomial com $n=10$ e $p=0,4$. Determine a aproximação normal para:

a) $P(3 < Y < 8)$

b) $P(Y \geq 7)$

c) $P(Y < 5)$.

3.10- Se uma moeda é lançada 500 vezes, e $P(\text{cara}) = 0,6$, obter a probabilidade de ocorrerem 285 caras.

3.11- Vimos que, para n grande e p pequeno, as probabilidades binomiais $b(k; n, p)$ podem ser aproximadas pelas pro

habilidades de Poisson

$$P_k = \frac{e^{-np} \cdot (np)^k}{k!} .$$

Suponha que um processo de fabricação produza itens dos quais 2 em 1.000 são defeituosos. Em um lote de 500 itens, qual a probabilidade que nenhum dos itens seja defeituoso?

- 3.12- Seja X com distribuição normal com média $\mu=10$ e variância $\sigma^2=4$. Calcular:
- a) $P(8 < X < 10)$
 - b) $P(9 \leq X \leq 12)$
 - c) $P(X > 10)$
 - d) $P(X < 8 \text{ ou } X > 11)$.
- 3.13- As vendas de um determinado produto têm distribuição aproximadamente normal com média 500 e desvio padrão 50. Se a empresa decide fabricar 600 unidades no mês em estudo, qual é a probabilidade que não possa atender a todos os pedidos deste mês, por estar com a produção esgotada?
- 3.14- Encontre a média e a variância das v.a. cujas densidades são:
- a) $f(x) = 6x(1-x), 0 < x < 1$.
 - b) $f(x) = e^{-x}, x > 0$.
 - c) $f(x) = 2x^{-3}, x > 1$.
- 3.15- Obtenha $E(X)$ e $Var(X)$ para X com distribuição normal dada por (3.2) do texto.
- 3.16- Idem, para X com distribuição exponencial dada por (3.21) do texto.

4 - INTRODUÇÃO À INFERÊNCIA ESTATÍSTICA

"O cidadão comum pensa em "estatísticas" como sendo colunas de números em páginas de esportes ou em seções econômicas de jornais, ilustradas com gráficos em zig-zag, pilhas de moedas e linhas de pessoas. Mas o estatístico de hoje não compila tabelas de dados e os ilustra graficamente. Ele trabalha em tarefas científicas e profissionais que são interessantes e complicadas. Seu trabalho é o de ajudar a planejar experimentos, interpretar dados obtidos de observações e apresentar os resultados de maneira a facilitar a tomada de decisões razoáveis."

4.1 - PROBABILIDADE E ESTATÍSTICA

O trecho acima, extraído do folheto "Carreiras em Estatística", publicado pelo Comitê de Presidentes das Sociedades Estatísticas Americanas, pode tentar descrever o campo de ação da Estatística.

O objetivo da Teoria das Probabilidades é constituir um modelo matemático para uma situação física e, a partir deste modelo, *deduzir* propriedades da situação.

A matéria prima da Estatística é um conjunto de da
dos. A grosso modo, podemos dizer que a Estatística se preo
cupa em coletar, analisar e fazer inferências a partir de
dados.

Portanto, a Inferência Estatística, que se baseia
na Teoria das Probabilidades, é uma parte apenas do campo
de ação da Estatística. O objetivo da Inferência Estatísti-
ca é o de *inferir* propriedades de um agregado maior (a *po-*
pulação) a partir de um conjunto menor (a *amostra*).

A tomada de decisões "razoáveis", mencionada acima,
será feita, pois, a partir de dados, que fornecem informa-
ção a respeito de uma dada característica da população, na
qual estamos interessados. Esta característica pode ser re-
presentada por uma variável aleatória, e os dados são, en-
tão, valores desta variável. Se tivéssemos informação com-
pleta a respeito da distribuição de X , isto é, se conheces-
semos os pares de valores $(x_i, P(X=x_i))$, bem como os parâme-
tros da distribuição (n e p , no caso da binomial, por exem-
plo), então não haveria necessidade de colher uma amostra
de X . Normalmente, nossa informação a respeito de X é par-
cial, ou mesmo nada conhecemos. Podemos, por exemplo, saber
que a distribuição de X é binomial, mas desconhecemos os pa-
râmetros que a caracterizam, ou podemos ter uma idé
ia e da variância de uma distribuição e não sabemos qual a
sua forma.

4.2 - MODELOS ESTATÍSTICOS

Vamos apresentar alguns exemplos simples, que nos darão uma idéia do tipo de problemas com os quais um estatístico pode lidar.

Exemplo 4.1 - No exemplo (1') do capítulo 3, tínhamos um experimento envolvendo uma distribuição binomial, na qual supomos que $p = \frac{1}{2}$. Conhecendo-se n , podemos calcular $b(k; n, p)$, para qualquer $k = 0, 1, \dots, n$. Suponha, agora, que lançamos uma moeda $n = 50$ vezes e obtemos 40 "caras" (sucessos). Com esta informação (número de sucessos) queremos *estimar* o valor de $p = P$ (sucesso). Temos, aqui, um problema estatístico. Qual seria um bom *estimador* de p ? Por outro lado, observando-se o número de caras obtidas, 40, podemos suspeitar da "honestidade" da moeda usada, isto é, podemos querer *testar a hipótese* que $p = \frac{1}{2}$. Com os dados obtidos, podemos ser levados a aceitar ou rejeitar a hipótese formulada. Temos, então, dois problemas básicos da Estatística: o primeiro diz-se um *problema de estimação*, enquanto que o segundo é um *problema de teste de hipóteses*. Os dois capítulos seguintes tratarão com pormenores estes problemas para o caso específico do parâmetro p de uma binomial.

Exemplo 4.2 - Consideremos, novamente, o problema da inspeção de qualidade do capítulo anterior. Lotes de N objetos são sujeitos ao controle de qualidade, mas suponha que o nú

mero de peças defeituosas, r , seja desconhecido. Uma amostra de tamanho n é escolhida ao acaso e o número de peças defeituosas, k , é determinado. O modelo para a situação será

$$P(X=k) = \frac{\binom{r}{k} \binom{N-r}{n-k}}{\binom{N}{n}}, \quad (4.1)$$

onde X = número de defeituosos na amostra. A diferença entre esta situação e a descrita no capítulo 3, é que agora r é desconhecido.

Suponha que um comprador tem que tomar uma decisão sobre um lote com N peças. Ele pode, como no exemplo 4.1, estar interessado em estimar r , baseado no valor observado de X . Ou então, pode tomar a decisão de comprar o lote, se k é menor ou igual a um determinado valor e devolver o lote se k é maior que este valor.

Exemplo 4.3 - Suponha que temos uma esfera de aço e medimos o seu diâmetro, obtendo-se o valor d . Se D representa o verdadeiro valor do diâmetro, então podemos estabelecer o modelo

$$d = D + e, \quad (4.2)$$

onde e representa o erro de mensuração. Se efetuarmos várias medidas, d_1, d_2, \dots, d_m do diâmetro, podemos escrever, do mesmo modo,

$$d_i = D + e_i, \quad i=1,2,\dots,m. \quad (4.3)$$

Aqui, d_i é uma v.a., porque e_i será uma v.a. O problema que se apresenta é o de estimar D , ou testar hipóteses a respeito de D , baseando-nos nas m observações d_1, d_2, \dots, d_m . Normalmente, várias suposições são feitas a respeito da distribuição das variáveis aleatórias e_i . Ver capítulo 8 para a solução deste problema.

Exemplo 4.4 - Um dado é lançado 300 vezes, com os seguintes resultados:

OCORRÊNCIA	1	2	3	4	5	6
FREQUÊNCIA	43	49	56	45	66	41

Com estes dados, queremos saber se o dado é "honesto", isto é, a probabilidade de ocorrência de qualquer face seja $1/6$. Isto é, queremos testar a hipótese que $p_1=p_2=\dots=p_6=1/6$, onde $p_i=P(\text{face } i)$, $i=1,\dots,6$. Este é um tipo de teste bastante comum na prática, chamado *teste de aderência* ou *ajustamento*.

Exemplo 4.5 - Podemos estar interessados em mais de uma categoria em um teste de aderência.

Considere a tabela abaixo, em que 1.000 indivíduos foram classificados de acordo com o sexo e de acordo com o fato de serem ou não daltônicos:

	HOMENS	MULHERES
NORMAIS	442	514
DALTÔNICOS	38	6

Temos, pois, duas categorias (ou atributos). De acordo com um modelo genético, estes números deveriam ser consistentes com

$$\begin{array}{c|c} p/2 & p^2/2 + pq \\ \hline q/2 & q^2/2 \end{array}$$

onde $q = 1-p$ é a proporção de gens que causam daltonismo na população.

O objetivo, pois, é testar se os dados obtidos são consistentes com o modelo genético proposto. Ver problema 4.5.

Outras vezes, podemos querer testar a independência entre dois atributos, dada uma tabela do tipo acima.

Tais tabelas são chamadas *tabelas de contingência*.

Nos exemplos 4.4 e 4.5, temos casos em que o experimento tem mais de dois resultados possíveis. A distribuição apropriada para descrever tais experimentos é chamada *distribuição multinomial* (ver exercícios), que tem papel relevante na obtenção dos testes mencionados nos dois exemplos anteriores (os chamados *testes do qui-quadrado*).

PROBLEMAS PARA O CAPÍTULO 4

4.1 - Suponha que temos n provas de Bernoulli com

$$P(\text{sucesso}) = p$$

e seja X igual ao número de sucessos obtidos. Qual é um estimador razoável de p ?

4.2 - Obtenha $E(\hat{p})$ e $\text{Var}(\hat{p})$, onde \hat{p} é o estimador que você encontrou em 4.1.

4.3 - Suponha que capturamos, marcamos e depois soltamos r animais de uma população com N animais, sendo N desconhecido. Depois de algum tempo, capturamos n animais, dos quais constatamos que k são marcados. Descreva um modelo para a situação em dois casos:

a) supondo que n é suficientemente pequeno, comparado com N , de modo que a amostragem pode ser considerada com reposição;

b) amostragem sem reposição.

No caso b, qual um limite inferior para o valor de N ?

4.4 - Suponha que quando realizamos um experimento, um e somente um dos eventos A_1, \dots, A_k ocorre. Ou seja, A_1, \dots, A_k constituem uma *partição* do espaço amostral Ω . Seja $p_i = P(A_i)$ e suponha que p_i permaneça constante durante as repetições do experimento. Defina as v.a. X_1, \dots, X_k como segue:


X_i = número de vezes que A_i ocorre dentre as n repetições do experimento, $i=1, \dots, k$.

Prove que

$$P(X_1=n_1, \dots, X_k=n_k) = \frac{n!}{n_1!n_2!\dots n_k!} p_1^{n_1} p_2^{n_2} \dots p_k^{n_k},$$

onde $\sum_{i=1}^k n_i = n$. Esta é chamada *distribuição multinomial* de probabilidades.

- 4.5 - Justifique as probabilidades teóricas dadas no exemplo 4.5 tendo em vista o seguinte. O daltonismo é uma característica genética ligada ao sexo. Cada pessoa apresenta um par de cromossomas sexuais, sendo que no homem este par é denominado XY e, na mulher, XX. O daltonismo é caracterizado por um par de gens, que chamemos D e d, sendo que, no homem, D ou d só podem estar localizados no cromossoma X, ao passo que na mulher podem estar localizados nos dois cromossomas X.



A situação é a esquematizada acima e, no exemplo 4.5, $q = P(d)$, $0 < q < 1$, isto é, d é o gen que ocasiona o daltonismo. Vemos que se, na mulher, aparece o par DD ou Dd, a pessoa é normal, ao passo que se aparece dd, a pessoa é daltônica. Suponha que a probabilidade de homem ou mulher na população seja 1/2. Em genética, q é chamado *freqüência gênica* do gen para daltonismo.

5 - ESTIMAÇÃO: PRIMEIRAS IDEIAS

Neste capítulo vamos considerar tão somente o problema de estimar o parâmetro desconhecido, p , de uma distribuição binomial. Este caso particular servirá para introduzir alguns conceitos importantes.

5.1 - UM ESTIMADOR POR PONTO DE p

Vamos considerar o seguinte

Exemplo 5.1 - Uma amostra de $n = 500$ pessoas de uma cidade é escolhida e a cada pessoa da amostra é feita uma pergunta a respeito de um dado problema municipal, para o qual foi apresentada uma solução pela Prefeitura. A resposta à pergunta poderá ser "SIM" (favorável à solução) ou "NÃO" (contrário à solução). Deseja-se estimar a proporção de pessoas na cidade favorável à solução apresentada.

Como no capítulo 3, definimos as v.a. $X_1, X_2, \dots, \dots, X_n$ onde

$$X_i = \begin{cases} 1, & \text{se a } i\text{-ésima pessoa na amostra responde "SIM",} \\ 0, & \text{se a } i\text{-ésima pessoa na amostra responde "NÃO",} \end{cases}$$

e seja $p = P(\text{sucesso})$, onde aqui "sucesso" significa que a pessoa responde SIM à questão formulada.

Logo, se $S_n = \sum_{i=1}^n X_i$, S_n tem distribuição binomial com parâmetros n e p e o problema consiste em estimar p , a probabilidade de uma pessoa escolhida ao acaso da população, responder "SIM". É claro que S_n representa o número de pessoas da amostra que responderam "SIM", logo um possível *estimador* de p é

$$\hat{p} = \frac{S_n}{n} = \frac{\sum_{i=1}^n X_i}{n}. \quad (5.1)$$

Então, se $S_n = k$, isto é, observamos o valor k da v.a. S_n , obtemos $\hat{p} = k/n$ como uma *estimativa* de p . Embora não vamos enfatizar esta diferença, observe que \hat{p} dado por (5.1) é uma v.a., ao passo que k/n é um número, isto é, um valor da v.a. Por exemplo, se 300 pessoas responderam "SIM" à pergunta, então $\hat{p} = \frac{300}{500} = 0,6$ e dizemos que 0,6 é uma estimativa da proporção de pessoas na população favorável à iniciativa da Prefeitura.

Vejamos algumas propriedades de \hat{p} . Como $E(S_n) = np$ e $\text{Var}(S_n) = npq$, $q = 1-p$, segue-se que

$$E(\hat{p}) = p, \quad (5.2)$$

e

$$\text{Var}(\hat{p}) = \frac{npq}{n^2} = \frac{pq}{n}. \quad (5.3)$$

Para n fixo, a função $\frac{pq}{n} = \frac{p(1-p)}{n}$ atinge seu máximo para $p = 1/2$, logo

$$\text{Var}(\hat{p}) \leq \frac{1}{4n}. \quad (5.4)$$




Figura 5.1

No exemplo dado, $\text{var}(\hat{p}) \leq \frac{1}{2.000} = 0,0005$; é claro que $\text{Var}(\hat{p})$ tende a decrescer quando n aumenta. Em particular, devido a (5.3), $\text{Var}(\hat{p}) \rightarrow 0$ quando $n \rightarrow \infty$. Esta propriedade, juntamente com (5.2) nos diz que \hat{p} é um *estimador consistente* de p .

O estimador \hat{p} é também chamado *não viciado*, pelo fato de (5.2) ser válida; ela nos diz que, em média, \hat{p} "acerta p ", ou seja, se escolhermos várias amostras, e para cada uma calculamos \hat{p} , a média destes valores estará próxima de p . Esta qualidade de um estimador é desejável, mas não é suficiente, como veremos depois. Pode acontecer que para uma particular amostra \hat{p} esteja bem distante de p .

O estimador dado por (5.1) é chamada *estimador por ponto*, pois obtemos um único número que escolhemos como re-

presentante do verdadeiro valor de p , que é desconhecido.

Exemplo 5.2 - Somente a título de ilustração, vejamos a distribuição de \hat{p} num caso particular, no qual supomos p conhecido e igual a $1/2$. Considere $n = 3$. Portanto, S_3 assume os valores 0, 1, e 3 com probabilidades $1/8$, $3/8$, $3/8$, e $1/8$, respectivamente (ver capítulo 3).

Os valores possíveis de $\hat{p} = \frac{S_n}{n} = \frac{S_3}{3}$ são 0, $1/3$, $2/3$ e 1, com probabilidades $1/8$, $3/8$, $3/8$ e $1/8$, respectivamente. De fato,

$$P(\hat{p}=2/3) = P(S_3/3=2/3) = P(S_3=2) = 3/8, \text{ etc.}$$




Figura 5.2

Temos que

$$E(S_3) = 3 \times \frac{1}{2} = 1,5$$

e

$$E(\hat{p}) = 0 \times \frac{1}{8} + \frac{1}{3} \times \frac{3}{8} + \frac{2}{3} \times \frac{3}{8} + 1 \times \frac{1}{8} = \frac{1}{2} = p.$$

Ver figura 5.2.

5.2 - A LEI DOS GRANDES NÚMEROS

No capítulo 1 mencionamos que uma maneira de olhar para a probabilidade de um evento A de maneira intuitiva é repetir o experimento que dá origem a A um certo número n de vezes e contar quantas vezes, k, o evento A ocorre nestas n repetições. Para n grande, $\frac{k}{n} = P(A)$.

Podemos formalizar esta idéia intuitiva para o caso em que temos n provas de Bernoulli com probabilidade p de sucesso. O fato de, para n grande, $\frac{k}{n}$ estar suficientemente próximo de p é posto nos seguintes termos: para qualquer número $\epsilon > 0$,

$$P\left\{\left|\frac{k}{n} - p\right| \geq \epsilon\right\} \leq \frac{p(1-p)}{n \cdot \epsilon^2}, \quad (5.5)$$

ou, de modo equivalente,

$$P\left\{\left|\frac{k}{n} - p\right| < \epsilon\right\} \geq 1 - \frac{p(1-p)}{n \epsilon^2} \quad (5.6)$$

O resultado (5.5) (ou (5.6)) é chamado *lei dos grandes números* para provas de Bernoulli. A prova deste resultado, embora simples, será omitida. (Ver Apêndice 2).

A relação (5.6) implica que, para todo número $\epsilon > 0$, a $P\left\{\left|\frac{k}{n} - p\right| < \epsilon\right\} \rightarrow 1$, quando $n \rightarrow \infty$.

Podemos formular a seguinte questão: quantas repetições do experimento, n, devemos realizar a fim de que k/n difira de p de menos de ϵ , com probabilidade maior ou igual

a γ ? Isto é, qual deve ser o valor de n para que tenhamos

$$P\left\{\left|\frac{k}{n} - p\right| < \epsilon\right\} \geq \gamma? \quad (5.7)$$

Portanto,

$$1 - \frac{p(1-p)}{n\epsilon^2} = \gamma \implies n = \frac{p(1-p)}{\delta \cdot \epsilon^2},$$

onde $\delta = 1-\gamma$. Como não conhecemos p , usamos o fato que $p(1-p) \leq 1/4$, logo, basta tomar o número de provas n tal que

$$n \leq \frac{1}{4\delta\epsilon^2}. \quad (5.8)$$

Exemplo 5.3 - Quantos ensaios com probabilidade p de sucesso devemos realizar se queremos $\epsilon = 0,01$ e $\gamma = 0,95$? Portanto, queremos n tal que

$$P\left\{\left|\frac{k}{n} - p\right| < 0,01\right\} \geq 0,95.$$

$\delta = 1-\gamma = 0,05$ portanto basta tomar $n = \frac{1}{4 \cdot (0,05)(0,01)^2} = 50.000$.

Para alguns valores de ϵ os respectivos valores de n estão dados na tabela abaixo, para $\gamma = 0,95$.

ϵ	0,01	0,05	0,1	0,2
n	50.000	2.000	500	125

Estes valores de n são desnecessariamente grandes. Utilizando a aproximação normal, sabemos que

$$P\{-2\sqrt{npq} \leq k - np \leq 2\sqrt{npq}\} = 0,95, \quad (5.9)$$

lembrando que o número esperado de sucessos é np e o desvio padrão é \sqrt{npq} .

Portanto,

$$P\{|k/n - p| \leq 2\sqrt{(pq)/n}\} \approx 0,95$$

e chamando $\epsilon = 2\sqrt{(pq)/n}$, vemos que $n = \frac{4pq}{\epsilon^2}$. Novamente, como $pq \leq 1/4$, basta tomar $n = 1/\epsilon^2$, no máximo. Obtemos a nova tabela abaixo.

ϵ	0,01	0,05	0,1	0,2
n	10.000	400	100	25

Exemplo 5.4 - A proporção de fumantes de uma dada população é p , desconhecida. Queremos determinar p com um erro de, no máximo, 0,05. Qual deveria ser o tamanho da amostra n , a ser escolhida com reposição, se $\gamma = 0,95$? Devemos ter

$$P\left\{\left|\frac{k}{n} - p\right| \leq 0,05\right\} = P\{|S_n - np| \leq 0,05n\} \geq \gamma.$$

onde S_n = número de fumantes na amostra. Portanto, devemos ter $n = 400$.

5.3 - ESTIMAÇÃO DE p POR INTERVALO

Vamos considerar, agora, o caso em que queremos construir um *intervalo de confiança* para p , isto é, um intervalo $[p, \bar{p}]$ que contenha p com uma dada probabilidade, cha

mada *coeficiente de confiança*. Fixado este coeficiente, γ , devemos ter que a $P\{\underline{p} \leq p \leq \bar{p}\} = \gamma$.

Sabemos que $\frac{S_n/n - np}{\sqrt{npq}}$ tem distribuição aproximadamente normal padrão. Chamando Y este quociente, temos que

$$Y = \frac{S_n/n - p}{\sqrt{(pq)/n}} = \frac{\hat{p} - p}{\sqrt{(pq)/n}} \sim N(0,1) \quad (5.10)$$

Assim, se $\gamma = 0,95$, temos, consultando a tabela 2

$$P\{-1,96 \leq Y \leq 1,96\} = 0,95,$$

ou seja,

$$P\{-1,96 \leq \frac{\hat{p} - p}{\sqrt{(pq)/n}} \leq 1,96\} = 0,95.$$

Portanto, com probabilidade 0,95 temos que

$$-1,96\sqrt{(pq)/n} \leq \hat{p} - p \leq 1,96\sqrt{(pq)/n},$$

do que segue

$$\hat{p} - 1,96\sqrt{(pq)/n} \leq p \leq \hat{p} + 1,96\sqrt{(pq)/n}. \quad (5.11)$$

Novamente, como não conhecemos p , usamos o fato que $pq \leq 1/4$, logo $\sqrt{(pq)/n} \leq 1/\sqrt{4n}$, obtendo-se

$$\hat{p} - 1,96/\sqrt{4n} \leq p \leq \hat{p} + 1,96/\sqrt{4n}. \quad (5.12)$$

Dizemos que $[\hat{p} - 1,96/\sqrt{4n}, \hat{p} + 1,96/\sqrt{4n}]$ é um intervalo de confiança para p com coeficiente de confiança de 95%.

Exemplo 5.5 - Numa pesquisa de mercado, $n = 400$ pessoas foram entrevistadas sobre um determinado produto e 60% destas pessoas preferiram a marca A. Aqui, $\hat{p} = 0,6$, e um intervalo de confiança para p , com $\gamma = 0,95$ será

$$0,6 \pm (1,96) \cdot \frac{1}{\sqrt{1.600}} = 0,6 \pm 0,049,$$

ou seja, $[\underline{p}, \bar{p}] = [0,551; 0,649]$.

Para um coeficiente de confiança qualquer γ , temos que (5.12) fica

$$\hat{p} - y_0/\sqrt{4n} \leq p \leq \hat{p} + y_0/\sqrt{4n}, \quad (5.13)$$

onde y_0 é obtido da tabela 2 tal que $P\{-y_0 \leq Y \leq y_0\} = \gamma$. Este intervalo é chamado pelos estatísticos de *conservativo*, pois se p não for igual a $1/2$ e estiver próximo de 0 ou de 1, então (5.13) fornece um intervalo de amplitude desnecessariamente grande, pois substituímos pq pelo valor máximo $1/4$. A menos que $\hat{p} = 1/2$, podemos usar o intervalo do exemplo a seguir.

Exemplo 5.6 - ("Enfoque otimista"). Suponha que em $n = 400$ provas obtemos $k = 80$ sucessos. Vamos obter um intervalo de confiança para p com $\gamma = 0,90$. Para tanto, usamos $\hat{p}\hat{q}$ como estimador de pq e então (5.11) fica (com y_0 no lugar de 1,96)

$$\hat{p} - y_0\sqrt{(\hat{p}\hat{q})/n} \leq p \leq \hat{p} + y_0\sqrt{(\hat{p}\hat{q})/n}. \quad (5.14)$$

No nosso caso, $\hat{p} = k/n = 80/400 = 0,2$ e $\hat{q} = 1 - k/n = 0,8$.

Portanto, o intervalo será

$$0,2 \pm (1,645)\sqrt{((0,2)(0,8))/400} = 0,2 \pm 0,033,$$

isto é,

$$[p, \bar{p}] = [0,167; 0,233].$$

Usando (5.13) obtemos

$$0,2 \pm (1,645)/40 = 0,2 \pm 0,041.$$

ou seja, $[p, \bar{p}] = [0,159; 0,241].$

Observe que o primeiro intervalo tem amplitude menor que o segundo.

Outra observação importante é a seguinte. Usando (5.13), para um γ fixo, os intervalos que podemos obter em sucessivas amostras terão todos a *mesma* amplitude, dada por $2y_0/\sqrt{4n}$. Por outro lado, usando-se (5.14), a amplitude do intervalo será $2y_0\sqrt{(\hat{p}\hat{q})}/n$, que é *variável* de amostra para a amostra, pois \hat{p} (e conseqüentemente \hat{q}) variará de amostra para amostra.

Em qualquer caso, a interpretação do que seja um intervalo de confiança para p com coeficiente de confiança γ é a seguinte: construindo 100 intervalos, correspondentes a 100 amostras de tamanho n , $100\gamma\%$ deles conterão o valor p .

Graficamente, teríamos a situação da figura 5.3, supondo intervalos dados por (5.13), isto é, de amplitudes constantes.




Figura 5.3

PROBLEMAS PARA O CAPÍTULO 5

- 5.1 - Obtenha a distribuição de $\hat{p} = S_n/n$, quando $p = 0,2$ e $n = 5$. Obtenha $E(\hat{p})$ e $Var(\hat{p})$.
- 5.2 - Deseja-se usar \hat{p} como estimador de p , com probabilidade de 0,975, ou mais, que \hat{p} difira 0,05 de p . Quão grande deve ser n ?
- 5.3 - Encontre o máximo para $Var(\hat{p})$ quando $n = 10, 25, 100$ e 400.
- 5.4 - Encontre os intervalos de confiança para p se $k/n = 0,3$ com coeficiente de confiança 95%. Utilize os dois enfoques, conservativo e otimista.
- 5.5 - Utilizando a relação (5.13) do texto, encontre um intervalo de confiança para p , sabendo-se que $n = 100$, $\hat{p} = 0,6$ e que a amplitude do intervalo deve ser igual a $d = 0,096$.

- 5.6 - Dê uma interpretação gráfica análoga à da figura 5.3, para intervalos dados por (5.14).
- 5.7 - Uma amostra casual de 625 donas de casa revela que 70 por cento delas preferem a marca X de detergente. Construir um intervalo de confiança para p , a proporção da população de donas de casa que preferem a marca X, com coeficiente de confiança de 95%.
- 5.8 - Suponha que X seja uma v.a. com média μ e variância σ^2 , finitas. Se c é um número positivo, então

$$P(|X-\mu|>c\sigma) \leq 1/c^2. \quad (*)$$

Utilizando esta desigualdade, prove a Lei dos Grandes Números (5.5). A desigualdade (*) é chamada *Desigualdade de Chebyshev*.

- 5.9 - Suponha que X tenha distribuição

x	0	1	2	3
p	1/8	1/4	1/2	1/8

Obtenha $P(|X-\mu|>3\sigma)$ e compare com o limite superior dada pela desigualdade (*) de (5.8).

6 - TESTES DE HIPÓTESES: PRIMEIRAS IDÉIAS

Como no capítulo anterior, vamos considerar aqui somente o caso de testes de hipóteses a respeito do parâmetro p de uma distribuição binomial. Em particular, veremos a conexão entre intervalos de confiança e testes de hipóteses.

6.1 - HIPÓTESE ESTATÍSTICA

Consideremos uma *população* cujos elementos podem ser classificados segundo dois atributos somente, que chamaremos "sucesso" e "fracasso". Por exemplo, podemos ter N objetos, dos quais alguns são defeituosos e os restantes não defeituosos. Se designarmos por p a proporção de sucessos na população, então o objetivo é fazer algum tipo de inferência sobre p . Vimos, no capítulo 5, como estimar p . Neste capítulo, estamos interessados em testar alguma hipótese sobre p . Entenderemos por *hipótese estatística* a qualquer afirmação que se faça sobre o parâmetro desconhecido p . Baseados em uma *amostra* da população vamos estabelecer uma *regra de decisão*, segundo a qual *rejeitaremos* ou *aceitaremos*

a hipótese proposta. Uma tal regra de decisão é chamada teste.

Acima usamos vagamente os termos população e amostra, se bem que no capítulo 1 (ver exercícios) introduzimos já algumas noções sobre amostras.

Entenderemos por população a qualquer conjunto de observações, enquanto que uma amostra é qualquer subconjunto próprio da população. Por exemplo:

- 1) todos os possíveis lançamentos de uma moeda constituem uma população, enquanto que cinco lançamentos desta moeda constituem uma amostra;
- 2) as alturas de todos os estudantes de uma escola constituem uma população; as alturas dos estudantes de uma particular classe da escola constituem uma amostra;
- 3) os artigos produzidos por uma certa máquina em um dia constituem uma população; se escolhermos dez desses artigos para inspeção, teremos uma amostra de tamanho dez.

Somente consideraremos *amostras aleatórias*, tal como foi definida no capítulo 1 (problema 1.13). Note que no exemplo 2 acima não temos uma amostra aleatória.

Escolhida uma amostra de tamanho n , definimos a v. a. X = número de sucessos na amostra e consideramos

$$\hat{p} = \frac{X}{n}, \quad (6.1)$$

que será a proporção de sucessos na amostra.

Basicamente, nossa regra de decisão utilizará \hat{p} para decidir sobre a rejeição ou não rejeição da hipótese estipulada para p .

6.2 - TESTE DE UMA HIPÓTESE PARA p

Exemplo 6.1 - Um professor aplica um teste envolvendo 10 questões do tipo certo-errado. Ele quer testar a hipótese "o estudante está adivinhando."

Vamos designar por p a probabilidade do estudante responder corretamente a uma questão. Então, a hipótese a ser testada pode ser expressa na forma $p = \frac{1}{2}$. É comum designar-se a hipótese formulada por H . Então queremos por à prova

$$H: p = \frac{1}{2}. \quad (6.2)$$

O teste de H será baseado no "número de sucessos nas n repetições independentes do experimento". Aqui, temos $n = 10$ repetições do experimento e independência significa que acertar uma questão não tem influência na resposta dada a uma outra questão qualquer. O número de sucessos será o número de acertos. É claro que, se H for verdadeira, o núme

ro de sucessos deverá estar próximo de $np = 10 \times \frac{1}{2} = 5$.


Suponha que o professor adote a seguinte *regra de decisão*:

"Se oito ou mais resposta estão corretas, o estudante não está adivinhando, enquanto que se menos do que oito questões estão corretas, o estudante está adivinhando."

Vamos indicar por X o número de respostas certas e por S o espaço amostral dos valores de X . Neste caso,

$$S = \{0, 1, 2, 3, \dots, 9, 10\}.$$

A hipótese H será *rejeitada* se observamos os valores $X = 8$, $X = 9$ ou $X = 10$. Estes valores constituem a chamada *região crítica* ou *região de rejeição* do teste, que será indicada por S_0 : $S_0 = \{8, 9, 10\}$. A região de *aceitação* (ou de *não rejeição*) do teste será S_1 : $S - S_0 = \{0, 1, 2, \dots, 7\}$. Um gráfico ilustrativo é o que segue, onde indicamos por pontos cheios os valores de X que pertencem à região crítica.



O professor sabe, no entanto, que é possível que um estudante esteja adivinhando e ainda assim ele acerta 8 ou mais questões. Isto é, H é verdadeira, mas será rejeitada. O professor quer, certamente, que a probabilidade deste evento seja pequena. É fácil calculá-la:

$$\begin{aligned} P(X=8 \text{ ou } X=9 \text{ ou } X=10 \mid p=\frac{1}{2}) &= \\ &= \binom{10}{8} \left(\frac{1}{2}\right)^{10} + \binom{10}{9} \left(\frac{1}{2}\right)^{10} + \binom{10}{10} \left(\frac{1}{2}\right)^{10} = \\ &= \frac{56}{1.024} = \frac{7}{128} \approx 0,054. \end{aligned}$$

O significado desta probabilidade é o seguinte: se o teste pudesse ser aplicado 128 vezes, o professor esperaria rejeitar H ("o aluno está adivinhando"), 7 vezes. A probabilidade $\frac{7}{128}$ é chamada *nível de significância do teste* e será indicada por α . Temos, acima, um teste do tipo *unilateral* (à direita, no caso) porque só valores "de um lado do espaço amostral" foram usados como pontos críticos.


Podemos ter testes *bi-laterais*, como ilustramos a seguir.

Exemplo 6.2 - Dois quadros de futebol estão aguardando o juiz lançar uma moeda para ver quem dará a saída. Um dos capitães dá ao juiz uma moeda. Como o árbitro tem conhecimentos de testes de hipóteses e quer saber se a moeda é honesta, ele vai lançá-la 5 vezes; ele decide que a moeda é considerada viciada se sair 5 caras ou 5 coroas. Nos outros casos a moeda será considerada "honesta".

Se $p = P(\text{cara})$, queremos testar

$$H: p = 1/2.$$

Aqui, $S = \{0, 1, 2, 3, 4, 5\}$, $S_0 = \{0, 5\}$ e $S_1 = \{1, 2, 3, 4\}$, sendo, novamente, $X =$ número de caras nos 5 lançamentos.



O nível de significância do teste é

$$\alpha = P(X=0 \text{ ou } X=5 \mid p=\frac{1}{2}) = \left(\frac{1}{2}\right)^5 + \left(\frac{1}{2}\right)^5 = \frac{1}{16}.$$

Exemplo 6.3 - Um praticante de tiro ao alvo vai comprar um lote muito grande de munição e o vendedor garante que a porcentagem de projéteis em bom estado é 90%. No entanto, o comprador decide fazer uma experiência para testar a veracidade da afirmação do vendedor. Ele escolheu 10 projéteis e vai verificar quantos são bons. Ele decide *não* comprar o lote se X = número de sucessos na amostra (número de bons) é muito pequeno. A hipótese a ser testada é

$$H: p = 0,9,$$

onde p = proporção de bons projéteis no lote. Suponha que ele decide manter α abaixo de 2,5%, isto é, $\alpha < 0,025$. Então, para obter os valores críticos (que levarão à rejeição de H) ele calcula algumas probabilidades:

Dado que $p = 0,9$, temos (ver tabelas):

$$P(X=0) = P(X=1) = P(X=2) = P(X=3) = P(X=4) \approx 0$$

$$P(X=5) = 0,001$$

$$P(X=6) = 0,011$$

$$P(X=7) = 0,057.$$

Portanto,

$$P(X=0 \text{ ou } X=1 \text{ ou } \dots \text{ ou } X=5 \mid p=0,9) = 0,001,$$


$$P(X=0 \text{ ou } X=1 \text{ ou } \dots \text{ ou } X=6 \mid p=0,9) = 0,012,$$

$$P(X=0 \text{ ou } X=1 \text{ ou } \dots \text{ ou } X=7 \mid p=0,9) = 0,069.$$

Portanto, a região crítica escolhida é

$$S_0 = \{0,1,2,3,4,5,6\}$$

pois incluindo-se o ponto 7 obtemos $\alpha > 0,025$.



Se, por exemplo, o comprador encontrou 8 projéteis bons, ele não rejeitará H .

6.3 - HIPÓTESE ALTERNATIVA - UM OUTRO TIPO DE ERRO

Exemplo 6.4 - Retomemos o exemplo 6.1, no qual estamos testando a hipótese $H: p = \frac{1}{2}$. Um valor de p maior do que $\frac{1}{2}$ indicará que o estudante não está simplesmente adivinhando. Vamos fixar α aproximadamente igual a 0,05. A hipótese H acima é comumente chamada *hipótese nula*. Vimos na seção anterior que $P(X=8 \text{ ou } X=9 \text{ ou } X=10 \mid p=\frac{1}{2}) \approx 0,054$, enquanto que $P(X=9 \text{ ou } X=10 \mid p=\frac{1}{2}) = \frac{1}{1.024} \approx 0,01$, logo decidimos usar a região crítica $S_0 = \{8,9,10\}$. A probabilidade, α , de rejeitar uma hipótese verdadeira, é também chamada *probabilidade do erro de tipo I*.

Suponha, agora, que o aluno acertou apenas 6 questões. Então, não há razão para rejeitar H e diríamos que o


aluno está adivinhando. Mas, é possível que o aluno não esteja adivinhando (isto é, $p > \frac{1}{2}$) e no entanto acertou apenas 6 questões. Portanto, há um outro erro que está envolvido neste processo decisório: *aceitar uma hipótese H , sendo ela falsa*. Suponha que na realidade, $p=0,8$. Podemos pensar o problema em termos de testar

$$H: p = 0,5$$

contra a hipótese alternativa

$$K: p = 0,8 \tag{6.3}$$

Vamos calcular a probabilidade, β , de aceitar H , quando K é verdadeira, para $\alpha = \frac{7}{128} = 0,054$, ou seja, a região crítica acima, $S_0 = \{8,9,10\}$.



Temos (ver tabela 1, $n = 10$, $p = 0,8$)

$$\beta = P(X=0 \text{ ou } X=1 \text{ ou } \dots \text{ ou } X=7 \mid p=0,8) =$$


$$= 0 + 0 + 0 + 0,001 + 0,006 + 0,026 + 0,088 + 0,201 = 0,322.$$

Este erro, aceitar uma hipótese falsa, é denominado *erro do tipo II* e β é a probabilidade do erro de tipo II.

Podemos descrever os erros que cometemos e as decisões que podemos tomar através do quadro seguinte:

DECISÃO	$p = 0,5$	$p = 0,8$
ACEITAR H	Decisão correta	erro de tipo I, probabilidade α
ACEITAR K	erro de tipo II, probabilidade β	Decisão correta

Vamos ver o que acontece quando tentamos diminuir um dos erros, digamos α . Suponha que tomamos por região crítica o conjunto $S'_0 = \{9, 10\}$. Então, vimos que $\alpha' = 0,01 < 0,054$.



O valor correspondente da probabilidade do erro de tipo II será

$$\beta' = P(X=0 \text{ ou } X=1 \text{ ou } \dots \text{ ou } X=8 \mid p=0,8) = 0,322 + 0,302 = 0,624.$$

Portanto, diminuindo α , β aumenta. Se a região crítica é $S''_0 = \{7, 8, 9, 10\}$, $\alpha'' = 0,17$ e $\beta = 0,121$ (calcule!). Podemos, pois, obter o quadro seguinte:

REGIÃO CRÍTICA	α	β
$\{7, 8, 9, 10\}$	0,17	0,121
$\{8, 9, 10\}$	0,054	0,322
$\{9, 10\}$	0,01	0,624

A situação que ocorre é que, para n fixado a prio-

ri, não é possível tomar α e β a nossa vontade; gostaríamos que α e β fossem pequenos, mas devido ao fato acima é costume fixar um valor para α ; valores comumente usados para α são 0,01 e 0,05.

Para efeito de ilustração, consideremos o caso em que $\alpha = 0,054$ e $\beta = 0,322$ (figuras 6.1 e 6.2).

região hachurada = α

$$n = 10$$

$$p = 1/2$$

$$np = 5 = \text{m\u00e9dia}$$




Fig. 6.1

região hachurada = β

$$n = 10$$

$$p = 0,8$$

$$np = \text{m\u00e9dia} = 8$$




Fig. 6.2

Utilizando "aproximações contínuas" para os gráficos das figuras 6.1 e 6.2 obtemos a figura 6.3, onde estão destacados α e β .




Figura 6.3

A justificativa de fixar α é dada pelo fato que es colhemos a hipótese nula que fornece o erro de primeira espécie mais grave. Para exemplificar, suponhamos que uma vacina contra uma doença vai ser testada em um grupo de pessoas, enquanto que um grupo de controle recebe apenas soro. Após algum tempo verificamos quais pessoas adquiriram a doença (afetados) e quais não adquiriram (não afetados). Obtemos uma tabela como aquela que segue.

	AFETADOS	NÃO AFETADOS
receberam vacina	n_{11}	n_{12}
receberam soro	n_{21}	n_{22}

Assim, n_{12} pessoas foram vacinadas e não ficaram doentes, enquanto que n_{21} pessoas receberam apenas soro e ficaram doentes, etc.

Suponha que queremos escolher uma das seguintes h_i hipóteses como hipótese nula.

H_1 : a vacina tem efeito positivo

H_2 : a vacina é inóqua.

Se $H = H_1$, o erro de tipo I consiste em rejeitar H_1 sendo ela verdadeira, isto é, a vacina é eficiente, mas a consideramos inóqua.

Se $H = H_2$, o erro de tipo I consiste em considerar a vacina eficiente, quando ela é inóqua. Tomamos H_2 como h_i hipótese nula, pois o erro de I decorrente nos parece o mais grave.

Exemplo 6.5 - Um fabricante de dois produtos similares, A e B, tem motivos para acreditar que pelo menos 70% dos consumidores preferem A. Uma pesquisa de mercado revelou que, em uma amostra de 625 pessoas, 65% dos elementos preferiam A, e o restante, B.

Se indicarmos por p a proporção (desconhecida) dos consumidores da população que preferem A, podemos pensar no problema como um teste da forma

$$H: p \geq 0,7 \quad (6.4)$$

contra a alternativa

$$K: p < 0,7 \quad (6.5)$$

Se X designa o número de consumidores na amostra que preferem A, então rejeitaremos H para "valores pequenos" de X .

Em termos de $\hat{p} = \frac{X}{n}$, podemos dizer que rejeitaremos H se o valor observado de \hat{p} for menor que um certo \hat{p}_c , tal que

$$P(\hat{p} < \hat{p}_c \mid H \text{ verdadeira}) = \alpha, \quad (6.6)$$

α sendo o nível de significância do teste.

A probabilidade $P(\hat{p} < \hat{p}_c \mid H)$ envolve o conhecimento da *distribuição de \hat{p}* . No exemplo 5.2, do capítulo anterior, vimos a distribuição de \hat{p} para o caso particular de $n = 3$ e $p = 1/2$. Aqui, não seria prático obter a distribuição de \hat{p} , quando H verdadeira, pois n é grande e p pode assumir qualquer valor maior ou igual a 0,7.

Felizmente, é possível obter um teste aproximado, utilizando-se uma aproximação para a distribuição de \hat{p} , quando n é grande.

Não teremos ocasião de tratar deste problema nestas notas, mas o exemplo serve para ilustrar a importância de obtermos o que chamamos a *distribuição amostral de um estimador*, no caso \hat{p} . Desta maneira podemos obter o valor crítico, \hat{p}_c , e conseqüentemente, a região crítica do teste. Veremos algumas noções sobre este assunto no próximo capítulo.

Os exemplos vistos até agora sugerem os seguintes tipos de testes que podemos encontrar:

$$\text{Exemplo 6.1: } \begin{cases} H: p = 1/2 \\ K: p > 1/2 \end{cases}$$

$$\text{Exemplo 6.2: } \begin{cases} H: p = 1/2 \\ K: p \neq 1/2 \end{cases}$$

$$\text{Exemplo 6.3: } \begin{cases} H: p = 0,9 \\ K: p < 0,9 \end{cases}$$

$$\text{Exemplo 6.5: } \begin{cases} H: p \geq 0,7 \\ K: p < 0,7 \end{cases}$$

De um modo bastante geral temos as 3 situações seguintes:

$$1) \begin{cases} H: p \leq p_0 \\ K: p > p_0 \end{cases} \quad (6.7)$$

$$2) \begin{cases} H: p \geq p_0 \\ K: p < p_0 \end{cases} \quad (6.8)$$

$$3) \begin{cases} H: p = p_0 \\ K: p \neq p_0 \end{cases} \quad (6.9)$$

6.4 - RELAÇÃO ENTRE INTERVALO DE CONFIANÇA E TESTE DE HIPÓTESES

Podemos testar hipóteses referentes ao parâmetro p

de uma binomial utilizando determinados gráficos já prontos, para diversos valores de p , diversos valores de n e diversos níveis de significância. Vejamos como tais gráficos são construídos.

Para fixar idéias, seja $n = 10$ e suponha que queremos testar $H: p = p_0$ contra $K: p \neq p_0$, de modo que temos um teste bilateral. Vamos fixar os níveis das regiões críticas laterais, α_1 e α_2 , menores ou iguais a 0,025 (2,5%). Vamos tomar, para valores de p_0 , 0,1; 0,2; 0,3; ...; 0,9; 1.

O gráfico da figura 6.4 ilustra, para cada p_0 , os valores críticos como pontos cheios e os restantes como círculos abertos.




Figura 6.4

Por exemplo, para $p_0 = 0,4$,

$$P(X=0) = 0,006, \text{ menor do que } 0,025,$$

enquanto que

$$P(X=0 \text{ ou } X=1) = 0,006 + 0,0403 = 0,0409,$$

que é maior que 0,025. Portanto, a região crítica à esquerda é $\{0\}$.

Analogamente,

$$P(X=8 \text{ ou } X=9 \text{ ou } X=10) = 0,0106 + 0,0016 + 0,0001 = 0,0123,$$

menor do que 0,025, mas

$$P(X=7 \text{ ou } X=8 \text{ ou } X=9 \text{ ou } X=10) = 0,0425 + 0,0123 = 0,0548.$$

que é maior do que 0,025, logo a região crítica à direita é $\{8, 9, 10\}$.

De modo análogo obtemos as demais regiões críticas.

Se obtemos $X=2$ sucessos, basta olhar a coluna correspondente a $X=2$ e a linha correspondente a $p = 0,4$; encontramos um círculo aberto, portanto aceitamos H .

Mas se queremos testar $H: p = 0,25$ versus $K: p = 0,25$, não podemos usar este quadro.

Teríamos que acrescentar novos valores de p ; mas podemos ter uma idéia do que vai acontecer; para um dado valor de X , olhando a coluna correspondente, de baixo para cima, notaremos a seqüência: pontos cheios — círculos — pontos cheios, de modo que podemos saber, aproximadamente, para

quais valores de p rejeitaremos H e para quais valores de p aceitaremos H , para aquele dado X .

Para $n = 10$ elementos amostrais obtemos o gráfico da figura 6.5, com nível de significância menor que 5%, substituindo X por $X/n = \hat{p}$.




Figura 6.5

Por exemplo, se $X/n = 0,6$, a reta vertical passando por 0,6 intercepta as duas curvas nos pontos A e B; os pontos

tos do segmento AB indicam aceitação da hipótese $p = p_0$, enquanto que pontos abaixo de A e acima de B indicam rejeição de $p = p_0$. Os pontos limites são 0,26 e 0,88, de modo que rejeitamos $H: p = p_0$ contra $K: p \neq p_0$ para $p < 0,26$ e $p > 0,88$ e aceitamos H para $0,26 \leq p \leq 0,88$.

Por outro lado, se queremos testar $H: p = 0,5$ contra $K: p \neq 0,5$, considere a reta horizontal passando por 0,5; esta intercepta as duas curvas nos pontos C e D; estes correspondem os valores 0 e 0,1, à esquerda, e 0,9 e 1, à direita, de modo que rejeitamos H para $X/n = \hat{p}$ pertencente a $\{0; 0,1; 0,9; 1\}$.

A região entre as curvas é chamada *região de confiança* e as curvas são as *curvas limites* da região.

No Apêndice 1 apresentamos regiões de confiança para alguns valores de n e para $\alpha < 5\%$ e $\alpha < 10\%$.

Voltemos ao caso $n = 10$ acima e $\alpha < 0,05$. Suponha que obtemos $\hat{p} = 0,6$. Então, o intervalo encontrado acima, $[0,26; 0,88]$ será um *intervalo de confiança* para p , com *coeficiente de confiança* de pelo menos 0,95. Este intervalo corresponde à região de aceitação da hipótese, ao nível de 0,05. Isto é, se obtemos $\hat{p} = 0,6$, nós não rejeitaremos a hipótese $H: p = p_0$, para $0,26 \leq p \leq 0,88$.

De modo geral, a região de aceitação de um teste do tipo acima, de nível α , corresponde a um intervalo de confiança para p , com coeficiente de confiança $\gamma = 1 - \alpha$.

6.5 - UMA APLICAÇÃO: TESTE DO SINAL

Exemplo 6.6 - Dois fertilizantes A e B são comparados escolhendo-se 10 pares de canteiros de testes semelhantes e aplicando-se A a um canteiro de cada par e B ao outro canteiro. As produções obtidas estão abaixo. A questão de interesse é: podemos concluir que a produção decorrente do uso de A é maior do que a produção decorrente do uso de B? (estas produções serão indicadas também por A e B).

A	20	19	23	17	18	20	24	19	21	19
B	18	16	21	20	17	18	20	18	23	20
SINAL DE A-B	+	+	+	-	+	+	+	+	-	-

Vemos que a diferença A-B é positiva para 7 dentre 10 pares de canteiros; ou seja, em 7 pares de canteiros, a produção decorrente da aplicação de A é maior do que a produção decorrente do uso de B.

Se não há diferença entre as produções de A e B podemos pensar no problema como um experimento binomial com $n = 10$ e $p = 1/2$, onde $p = P(A-B > 0)$ (justifique a independência necessária ao modelo binomial).

Se X indica o número de sinais "+", temos que

$$\hat{p} = \frac{X}{n} = \frac{7}{10} = 0,7.$$

Podemos, pois, testar


$$H: p = 0,5$$

contra

$$K: p > 0,5.$$

Estamos utilizando uma região crítica à direita por que temos alguma razão para esperar mais sinais "+" do que sinais "-".

Suponha $\alpha = 0,025$ para podermos utilizar o gráfico do Apêndice 1. A reta horizontal por $p = 0,5$ intercepta a reta vertical por $\hat{p} = 0,7$ dentro da região de confiança, portanto não rejeitamos H.



Portanto, podemos concluir que rejeitamos a idéia de uma diferença substancial na produção a favor do fertilizante A. Se não tivéssemos, baseados nos dados, razão para esperar maior número de "+" do que "-" poderíamos utilizar

um teste bi-lateral, isto é, considerar

$$H: p = 0,5$$

contra

$$K: p \neq 0,5.$$

Ainda assim não rejeitaríamos H ao nível de 5%. (Verifique).

Observe que, para o caso de região crítica à direita ($\alpha < 2,5\%$) os valores críticos são $X=9$ ou $X=10$, ao passo que para região crítica bi-lateral ($\alpha < 5\%$) os valores críticos são $X=0$ ou $X=1$ ou $X=9$ ou $X=10$.

PROBLEMAS PARA O CAPÍTULO 6

6.1 - Temos que tomar uma decisão sobre se uma moeda é viciada ou não baseados em 6 lançamentos da moeda. A moeda será considerada viciada se o resultado for:

- a) 0 ou 6 caras;
- b) 0 caras;
- c) 6 caras.

Construa os testes correspondentes, especificando: as hipóteses H e K, a região crítica, a região de aceitação, o gráfico da região crítica e o valor de α .

6.2 - Para $\alpha = 0,02$, encontre o valor de β no problema anterior.

6.3 - Utilizando a figura 6.4 resolva:

- a) encontrar os valores para os quais $H: p = 0,8$ é rejeitada, usando um teste bi-lateral;
- b) mesma questão de (a), usando um teste uni-lateral;

- c) a amostra de 10 elementos contém 4 sucessos; quais hipóteses não são rejeitadas, num teste bi-lateral?
- d) em uma amostra de tamanho 10, $X=6$; quais hipóteses são rejeitadas? Use: teste uni-lateral à esquerda; teste uni-lateral à direita; teste bi-lateral.

- 6.4 - Em uma população temos $p = 0,45$. Uma amostra com $X \leq 1$ ou $X \geq 9$ supostamente contradiz $p = 0,45$. Qual a probabilidade de rejeitar $p = 0,45$?
- 6.5 - Queremos testar $H: p = 1$. Se $n = 10$ e $X = 9$, a hipótese é rejeitada? Se $H: p = 0$, $n = 10$ e $X = 0$, a hipótese é rejeitada?
- 6.6 - Utilizando a figura 6.5, $n = 10$, resolva:
- a) qual a região crítica de um teste bi-lateral para $H: p = 0,42$? e para $H: p = 0,76$?
- b) para um teste uni-lateral à direita, quais valores de p são rejeitados se $\hat{p} = 0,3$? e se $\hat{p} = 0,8$?
- 6.7 - Um estudo é feito para determinar a proporção de famílias em uma comunidade que têm telefone. Uma amostra de 10 famílias é escolhida ao acaso e 8 têm telefone. Se $\alpha \leq 0,05$, qual a conclusão pode ser tirada sobre a população?
- 6.8 - Um médico examina aumentos na pressão sanguínea usando uma certa droga. Ele mede a pressão de 20 homens an-

HOMENS	1	2	3	4	5	6	7	8	9	10
ANTES	121	130	127	125	140	121	132	135	124	136
DEPOIS	123	127	132	132	135	122	138	176	127	138
HOMENS	11	12	13	14	15	16	17	18	19	20
ANTES	127	118	131	120	128	123	128	133	141	124
DEPOIS	135	120	129	123	127	128	122	134	142	126

tes e depois de administrar a droga. A tabela na página anterior fornece os resultados. Existe razão suficiente para concluir que a pressão sanguínea em homens aumenta com o uso da droga? $\alpha \leq 5\%$.

6.9 - Encontre o número de sucessos, em uma amostra de 10, para o qual $p = 0,2$ e $p = 0,7$ são ambos rejeitados usando um teste bi-lateral. Tome $\alpha \leq 5\%$ e $\alpha \leq 10\%$.

6.10- Suponha que estamos testando $H: p = 0,5$ contra a alternativa $K: p \neq 0,5$. Suponha que para uma amostra de tamanho $n = 10$, decidimos pela região crítica

$$S_0 = \{0,1,2,8,9,10\}.$$

Determine o nível de significância, α . Denomina-se *poder* do teste à probabilidade de rejeitar a hipótese H quando ela é falsa. Assim, para $p = 0,6$, o poder é

$$P\{X=0 \text{ ou } X=1 \text{ ou } X=2 \text{ ou } X=8 \text{ ou } X=9 \text{ ou } X=10 \mid p=0,6\}.$$

Calcule o poder para $p = 0,2$, $p = 0,4$, $p = 0,6$, $p = 0,8$.

Faça um gráfico da função obtida (chamada *função poder* do teste). Qual o poder do teste para $p = 0,5$?

6.11- Para testar se um dado é honesto, ele é lançado 1.000 vezes e é considerado viciado se números pares ocorrem mais do que 510 ou menos do que 490 vezes. Qual o nível de significância do teste? Se a probabilidade de ocorrer número par é 0,51, qual o poder do teste?

7 - DISTRIBUIÇÕES AMOSTRAIS

Frisamos, no capítulo anterior, a importância de se obter aquilo que denominamos distribuição amostral de um estimador, pois dela necessitamos para efetuar testes de hipóteses. Neste capítulo iremos introduzir algumas noções sobre este assunto. Em particular, estudaremos com algum pormenor a distribuição amostral da média amostral.

7.1 - ESTATÍSTICAS

Já temos idéia do que seja uma amostra aleatória. Suponha que X represente uma característica de interesse de uma dada população. Por exemplo, podemos estar interessados na distribuição das medidas das alturas dos indivíduos de uma dada cidade. Dizemos que a distribuição de X é a distribuição da população. Normalmente não temos conhecimento desta distribuição. Para termos uma idéia da forma desta distribuição, bem como estimarmos alguns parâmetros da mesma, extraímos uma amostra aleatória de X .

Suponha que os valores da variável X nos elementos da população sejam X_1, X_2, \dots, X_N . Escolhendo-se uma amostra de tamanho n , podemos obter valores repetidos; suponha

que obtemos n_1 valores iguais a X_1 , n_2 valores iguais a X_2 ,
 ..., n_N valores iguais a X_N , onde $n_1+n_2+\dots+n_N = n$.

Obtemos a chamada *distribuição de freqüências* dos valores observados:

FREQÜÊNCIA	n_1	n_2	...	n_i	...	n_N
VALOR DE X	X_1	X_2	...	X_i	...	X_N

Definimos, então, a *média amostral*

$$\bar{X} = \frac{\sum_{i=1}^N n_i X_i}{\sum_{i=1}^N n_i} = \frac{1}{n} \sum_{i=1}^N n_i X_i. \quad (7.1)$$

Observe a correspondência entre a distribuição de freqüências acima e a distribuição de probabilidades da v. a. X,

X	X_1	X_2	...	X_i	...	X_N
PROB.	p_1	p_2	...	p_i	...	p_N

bem como a analogia de \bar{X} com o valor esperado de X,

$$E(X) = \sum_{i=1}^N X_i p_i \quad (7.2)$$

Podemos, também, definir a *variância amostral*

$$S^2 = \frac{\sum_{i=1}^N (X_i - \bar{X})^2 \cdot n_i}{n-1}, \quad (7.3)$$

que corresponde à variância de X ,

$$\text{Var}(X) = \sum_{i=1}^N (X_i - E(X))^2 \cdot p_i. \quad (7.4)$$

Dizemos que \bar{X} e S^2 são *estatísticas*, isto é, funções dos valores amostrais. Os valores correspondentes da população são chamados *parâmetros*, como $E(X)$ e $\text{Var}(X)$.

Vamos indicar uma amostra de tamanho n por (X_1, \dots, \dots, X_n) ; como X_1, X_2, \dots, X_n são observações da mesma variável X , dizemos que X_1, \dots, X_n têm a mesma distribuição que X ; e são, além disso, independentes, devido ao fato de termos uma amostra aleatória (com reposição). Uma estatística, T , será uma função de X_1, \dots, X_n : $T = f(X_1, \dots, X_n)$. Considere \bar{X} , por exemplo. Para diversas amostras escolhidas obteremos diversos valores de \bar{X} ; esta será também uma variável aleatória. O mesmo acontece com S^2 . Outras estatísticas que podem ser consideradas são:

$W = X_n - X_1$: amplitude total da amostra

$Y_1 = \max(X_1, \dots, X_n)$: o maior valor da amostra

$Y_n = \min(X_1, \dots, X_n)$: o menor valor da amostra.

Y_1 e Y_n são duas *estatísticas de ordem*; suponha que ordenemos a amostra obtida:

$Y_1 = \min(X_1, \dots, X_n)$

$Y_2 =$ segunda maior em ordem crescente

\vdots

$Y_n = \max(X_1, \dots, X_n)$.

Então, $Y_1 \leq Y_2 \leq \dots \leq Y_n$ são as estatísticas de ordem da amostra (X_1, \dots, X_n) . Uma particular e importante estatística de ordem é a *mediana*, denotada por $Y_{1/2}$. Ordenados os valores amostrais, $Y_{1/2}$ é o valor central se n é ímpar e é a média aritmética dos dois valores centrais se n é par.

Exemplo 7.1 - Os valores obtidos em uma amostra (X_1, \dots, X_5) foram:

$x_1=7, x_2=5, x_3=8, x_4=12, x_5=5$ (lembre-se que os valores de uma v.a. são denotados por letras minúsculas).

Então:

$$\bar{x} = \frac{1}{5}(7 + 5 + 8 + 12 + 5) = 7,4,$$

$$s^2 = \frac{1}{4}(0,4^2 + 2,4^2 + 0,6^2 + 4,6^2 + 2,4^2) = 8,3.$$

As estatísticas de ordem são:

$$Y_1 = Y_2 = 5; Y_3 = Y_{1/2} = 7; Y_4 = 8; Y_5 = 12.$$

Se $Y_1=5, Y_2=8, Y_3=12, Y_4=13; Y_5=15$ e $Y_6=16$, a mediana seria

$$Y_{1/2} = \frac{12+13}{2} = 12,5.$$

Como toda estatística é uma v.a. tem sentido em considerar a *distribuição desta estatística*, bem como considerar a média ou a variância dela.

Consideremos, em especial, \bar{X} . Suponha que a "população", isto é, a v.a. X , tem média $E(X) = \mu$ e variância

$\text{Var}(X) = \sigma^2$. Quando consideramos $E(\bar{X})$ e $\text{Var}(\bar{X})$, será que há alguma relação entre estes valores e μ , σ^2 ? Isto é o que veremos na próxima secção.

7.2 - DISTRIBUIÇÕES AMOSTRAIS

Denominaremos *distribuição amostral* à distribuição de uma estatística determinada a partir de uma amostra. Para efeito de ilustração, consideremos uma população de tamanho $N = 3$ e a v.a. X tendo os valores 1, 2 e 3 sobre os elementos desta população.

A média da população é

$$\mu = E(X) = \frac{1+2+3}{3} = 2$$

e a variância da população é

$$\sigma^2 = E(X-\mu)^2 = \frac{\sum (X_i - \mu)^2}{3} = \frac{2}{3} = 0,667.$$

X	X - μ	$(X-\mu)^2$	
1	-1	1	$\mu = 2$
2	0	0	$\sigma^2 = 2/3 = 0,667$
3	1	1	$\sigma = 0,816.$
6	0	2	

Retiramos todas as possíveis amostras (com reposição) de tamanho $n = 2$. O número de amostras será $N^n = 3^2 = 9$ e

cada amostra tem a mesma probabilidade, $\frac{1}{9}$, de ser selecionada. Obtemos o quadro seguinte.

AMOSTRA	VALORES AMOSTRAIS	PROBABILIDADE	\bar{x}	s^2	s
1	(1,1)	1/9	1,0	0	0
2	(1,2)	1/9	1,5	0,5	0,71
3	(1,3)	1/9	2,0	2,0	1,41
4	(2,1)	1/9	1,5	0,5	0,71
5	(2,2)	1/9	2,0	0	0
6	(2,3)	1/9	2,5	0,5	0,71
7	(3,1)	1/9	2,0	2,0	1,41
8	(3,2)	1/9	2,5	0,5	0,71
9	(3,3)	1/9	3,0	0	0
			18,0	6,0	5,66

Por exemplo, para a amostra (1,3), $\bar{x} = \frac{1+3}{2} = 2$, enquanto $s^2 = \frac{(1-2)^2 + (3-2)^2}{1} = \frac{1+1}{1} = 2$ ($n-1 = 1$).

A distribuição amostral de \bar{X} será, então:

\bar{x}	1,0	1,5	2,0	2,5	3,0
p	1/9	2/9	3/9	2/9	1/9

Portanto,

$$E(\bar{X}) = 1 \times \frac{1}{9} + (1,5) \times \frac{2}{9} + 2 \times \frac{3}{9} + (2,5) \times \frac{2}{9} + 3 \times \frac{1}{9} = \frac{18}{9} = 2 = \mu,$$

enquanto que

$$E(X^2) = 1 \times \frac{1}{9} + (2,25) \times \frac{2}{9} + 4 \times \frac{3}{9} + (6,25) \times \frac{2}{9} + 9 \times \frac{1}{9} = 4,333,$$

do que segue

$$\text{Var}(\bar{X}) = 4,333 - 2^2 = 0,333.$$

$$\text{É fácil ver que } \text{Var}(\bar{X}) = \frac{\text{Var}(X)}{n} = \frac{0,667}{2}.$$

Então:

$$E(\bar{X}) = 2 = \mu$$

(7.5)

$$\text{Var}(\bar{X}) = 0,333 = \frac{\sigma^2}{n}$$

Da mesma forma obtemos a distribuição amostral de S^2 ,

s^2	0	0,5	2,0
p	3/9	4/9	2/9

e a distribuição amostral de S (o desvio padrão amostral),

s	0	0,71	1,41
p	3/9	4/9	2/9

É fácil ver que

$$E(S^2) = \frac{6,0}{9} = \frac{2}{3} = 0,667 = \sigma^2,$$

mas

$$E(S) = \frac{5,66}{9} = 0,629 \neq \sigma = 0,818.$$

Vamos comparar as distribuições de X e de \bar{X} ; observe que ambas possuem a mesma média, 2, mas as variâncias são

diferentes: $\text{Var}(X) = \sigma^2 = 0,667$, enquanto que $\text{Var}(\bar{X}) = \frac{\sigma^2}{n} = 0,333$ (figura 7.1).




Figura 7.1

Quanto maior for o tamanho da amostra, n , menor será a variância de \bar{X} , devido ao fato que $\text{Var}(\bar{X}) = \frac{\text{Var}(X)}{n}$. Isto indica que a distribuição de \bar{X} será mais concentrada ao redor de sua média, $E(\bar{X})$. A figura 7.2 ilustra este fato, para o caso em que X tem distribuição normal $N(\mu, \sigma^2)$.




Figura 7.2

Outra observação que podemos fazer do que foi exposto é que $E(\bar{X}) = \mu$ e $E(S^2) = \sigma^2$. Estas relações são válidas em geral e não só para o exemplo visto. Mas $E(S) \neq \sigma$. Dizemos que \bar{X} e S^2 são estimadores *não viciados* de μ e σ^2 , respectivamente, ao passo que S é um estimador *viciado* de σ . Voltaremos a este assunto no capítulo seguinte.

Para *demonstrar* que $E(\bar{X}) = \mu$ e $\text{Var}(\bar{X}) = \frac{\sigma^2}{n}$ é relativamente fácil, bastando utilizar as propriedades da média e da variância; a demonstração de que $E(S^2) = \sigma^2$ é um pouco mais trabalhosa. Ver exercícios.

Para as figuras 7.2, no caso em que X é normal, percebe-se claramente que a distribuição de \bar{X} também é normal; este é um resultado importante e decorre da seguinte *propriedade reprodutiva da normal*: se X_1 é uma v.a. $N(\mu_1, \sigma_1^2)$ e X_2 é uma v.a. $N(\mu_2, \sigma_2^2)$, com X_1 e X_2 *independentes*, então $X_1 + X_2$ será uma v.a. $N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$. Esta propriedade estende-se a um número finito de v.a. normais independentes, bem como para uma combinação linear de v.a. normais independentes. Em particular, como $\bar{X} = \frac{1}{n} X_1 + \dots + \frac{1}{n} X_n$, se X_1, X_2, \dots, X_n são normais, segue-se que \bar{X} será normal. Um fato importante é o seguinte. Mesmo que a população não seja normal, à medida que n cresce, a distribuição de \bar{X} vai-se aproximando de uma normal.

No exemplo dado, a população é uniforme sobre os inteiros 1, 2 e 3 e mesmo para $n = 2$ já vemos que a distribui-

ção de \bar{X} tem uma forma que lembra a normal (figura 7.3).




Figura 7.3

As figuras 7.4 dão uma idéia do que acontece quando n cresce, partindo de uma população que tem distribuição do tipo acima, isto é, "uniforme" num certo intervalo.




Figura 7.4

A justificativa teórica do que ocorre é baseada no que é chamado o *Teorema do Limite Central*. Quando aproxima-

mos uma distribuição binomial por uma normal, estamos utilizando um caso especial deste teorema. Este teorema afirma o seguinte: se X_1, X_2, \dots, X_n são v.a. independentes, com uma distribuição comum, de média μ e variância σ^2 , então a v. a.

$$S_n = X_1 + X_2 + \dots + X_n \quad (7.7)$$

é tal que, para cada valor fixo z e para $n \rightarrow \infty$,

$$P\left(\frac{S_n - n\mu}{\sigma\sqrt{n}} \geq z\right) \rightarrow P(Z \geq z), \quad (7.8)$$

onde Z é a v.a. $N(0,1)$. Ver Apêndice 2.

Como $\bar{X} = S_n/n$ vem

$$\frac{S_n - n\mu}{\sigma\sqrt{n}} = \frac{(S_n/n) - \mu}{\sigma/\sqrt{n}} = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$$

portanto, na prática, para n grande, $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$ tem distribuição aproximada normal padrão.

Devido a sua importância, vamos repetir o que foi dito a respeito da distribuição amostral de \bar{X} .

Fato: Seja X uma v.a. ("população") com média $E(X) = \mu$ e variância $\text{Var}(X) = \sigma^2$. Seja \bar{X} a média amostral de uma amostra aleatória de tamanho n . Então:

- (i) $E(\bar{X}) = \mu$.
- (ii) $\text{Var}(\bar{X}) = \sigma^2/n$.
- (iii) Para n grande, $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$ tem, aproximadamente, distribuição

buição $N(0,1)$.

PROBLEMAS PARA O CAPÍTULO 7

7.1 - Para o exemplo discutido na seção 7.2, obtenha a distribuição do mínimo $Y_1 = \min(X_1, X_2)$ e do máximo $Y_2 = \max(X_1, X_2)$. Calcule $E(Y_1)$ e $E(Y_2)$.

7.2 - Prove que $\text{Var}(\bar{X}) = \sigma^2/n$ se a variância de X é σ^2 .

7.3 - Prove que $E(S^2) = \sigma^2$. Para isso escreva

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

e então, $X_i - \bar{X} = (X_i - \mu) - (\bar{X} - \mu)$.

7.4 - Considere uma população de tamanho $N = 4$ e a v.a. X tendo os valores 2, 3, 5, 6 sobre os elementos desta população.

a) Calcule $E(X)$ e $\text{Var}(X)$.

b) Considere amostras de tamanho $n = 2$, com reposição, da população. Obtenha a distribuição amostral de \bar{X} , S^2 e S .

7.5 - *Correção para populações finitas.* Vimos que $\text{Var}(\bar{X}) = \sigma^2/n$, se extraímos amostras com reposição da população. Na prática, utilizamos amostragem sem reposição. Se a população é infinita, a fórmula acima ainda é válida, mas se a população é finita, então pode-se demonstrar que

$$\text{Var}(\bar{X}) = \frac{\sigma^2}{n} \cdot \frac{N-n}{N-1}, \quad (*)$$

sendo N o tamanho da população. Se $n \ll N$, $\frac{N-n}{N-1} \approx 1$.

Considere uma população de tamanho $N = 4$ e os valores $X_1 = 0$, $X_2 = 3$, $X_3 = 2$, $X_4 = 3$. Retire amostras de tamanho

$n = 2$, *sem reposição*. Obtenha a distribuição amostral de \bar{X} e calcule $E(\bar{X})$ e $\text{Var}(\bar{X})$. Verifique que $E(\bar{X}) = E(X) = \mu$ e $\text{Var}(\bar{X})$ é dada por (*).

7.6 - Dada uma população normal com média $\mu = 600$ e desvio padrão $\sigma = 16$, se uma amostra de tamanho $n = 64$ é escolhida, com reposição, desta população, calcular:

- a) $P(\bar{X} > 602)$
- b) $P(\bar{X} > 610)$
- c) $P(602 \leq \bar{X} \leq 610)$
- d) $P(|\bar{X}| > 610)$.


7.7 - Vimos que, se a população é normal com média μ e variância σ^2 , então $Z = (\bar{X} - \mu) / (\sigma / \sqrt{n})$ tem distribuição: $N(0,1)$. Suponha que σ seja desconhecido e usamos:

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

no seu lugar. Sabemos que S é um estimador viciado de σ e para valores pequenos de n , o quociente

$$\frac{\bar{X} - \mu}{S / \sqrt{n}}$$

não tem distribuição normal; para n grande a distribuição deste quociente é aproximadamente normal. De qualquer modo, para qualquer valor de n , a distribuição de $(\bar{X} - \mu) / (S / \sqrt{n})$ é conhecida como *distribuição t de Student* e se parece bastante com a $N(0,1)$, sendo que para n pequeno, ela apresenta uma maior dispersão que a $N(0,1)$.



A distribuição de $t = (\bar{X} - \mu) / (S / \sqrt{n})$ depende do valor de n e para $n > 30$ a distribuição de t é praticamente normal padrão. A tabela 3 do Apêndice 1 fornece probabilidades $P(t > t_0)$, para valores de $v = n - 1$, que é chamada do *número de graus de liberdade*.

Por exemplo, se $n = 25$, $v = n - 1 = 24$ e $P(t > 1,711) = 0,05$.
Calcular:

- a) $n = 24$, $P(t > 1,319)$
- b) $n = 25$, $P(t < -2,060)$
- c) $n = 30$, $P(|t| > 1,96)$
- d) v de tal sorte que $P(t > 2,479) = 0,01$.

7.8 - Suponha que de uma população normal com média $\mu = 100$ e variância desconhecida, uma amostra de tamanho $n = 16$ forneceu $S^2 = 2,25$. Obter:

- a) $P(\bar{X} > 105)$
- b) $P(\bar{X} < 96)$
- c) $P(|\bar{X}| > 103)$

8 - IDEIAS GERAIS SOBRE INFERÊNCIA ESTATÍSTICA

Para introduzir os conceitos de estimação e testes de hipóteses utilizamos apenas a distribuição binomial: obtivemos estimadores para p e testamos hipóteses relativas a p . Vamos, agora, ver algumas noções gerais, aplicáveis a um grande número de situações. Trataremos, em particular, do chamado princípio de máxima verossimilhança.

8.1 - PROPRIEDADES DOS ESTIMADORES

Vimos que a Inferência Estatística tem por objetivo fazer generalizações sobre uma população com base em dados de uma amostra.

Consideremos uma amostra (X_1, X_2, \dots, X_n) de uma v.a. X , que descreve uma característica de interesse da população.

Sabemos que um *estimador* é qualquer função das observações X_1, \dots, X_n . Uma estimativa é um valor particular do estimador, para uma amostra particular.

O problema da estimação é, então, com base em uma amostra, determinar uma função $T = f(X_1, \dots, X_n)$ que seja "próxima" do parâmetro populacional de interesse.

Podemos ter vários estimadores de um mesmo parâmetro θ . Necessitamos, então, ter critérios que nos permitam escolher o "melhor" estimador de θ . Por exemplo, a média amostral \bar{X} e a mediana amostral $Y_{1/2}$ são dois estimadores da média populacional $\mu = E(X)$.

Seja

$$e = T - \theta \tag{8.1}$$

o erro amostral. Ao valor

$$E(e^2) = E(T-\theta)^2 \tag{8.2}$$

denominamos *erro quadrático médio* ou *risco* do estimador T , e será indicado por $R(T, \theta)$. Poderíamos, então, tentar determinar T que minimizasse o risco (8.2), para todo θ . Isto não é possível, em geral.

Se temos dois estimadores T_1 e T_2 do parâmetro θ , se $R(T_1, \theta) < R(T_2, \theta)$, para todo θ , então T_1 seria preferível a T_2 . Ver figura 8.1.




Figura 8.1

Mas a situação pode não ser essa, como indica a fi
gura 8.2.




Figura 8.2

Para alguns valores de θ , $R(T_1, \theta) < R(T_2, \theta)$, acontecendo o oposto para outros valores de θ .

O que se faz, então, é tentar restringir a classe de estimadores a usar.

Uma possibilidade é considerar a classe dos *estimadores não viciados* de θ , isto é, se T é um membro desta classe,

$$E(T) = \theta, \quad (8.3)$$

para todo θ . Se esta condição está verificada, então

$$R(T, \theta) = E[T - E(T)]^2, \quad (8.4)$$

que é a variância de T . Escolher, pois, um estimador na classe dos estimadores não viciados do parâmetro θ , que minimiza o risco, significa escolher um estimador que minimiza a variância (8.4). Se existe tal estimador, dizemos que ele é um *estimador não viciado de variância mínima* de θ . Para al-

gumas situações é possível encontrar o estimador não viciado de variância mínima de um parâmetro θ . Mas para isso é necessário recorrer a conceitos que estão fora do alcance destas notas.

Exemplo 8.1 - \bar{X} é um estimador não viciado da média $\mu = E(X)$ de uma v.a. X . De fato,

$$E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i).$$

Como cada X_i tem a mesma distribuição que X , $E(X_i) = \mu$, logo

$$E(\bar{X}) = \frac{1}{n} \sum_{i=1}^n \mu = \frac{n\mu}{n} = \mu.$$

Do mesmo modo, num experimento binomial, se $X =$ número de sucessos, $P(\text{sucesso}) = p$, $\hat{p} = X/n$ é um estimador não viciado de p , como já vimos.

Vejamos, agora, um outro critério. Considere, por exemplo, \bar{X} calculado para diversos tamanhos de amostras; obtemos, na realidade, uma seqüência de estimadores $\{\bar{X}_n, n=1, 2, 3, \dots\}$. Suponha que a v.a. X é normal $N(\mu, \sigma^2)$. A distribuição de \bar{X}_n é $N(\mu, \frac{\sigma^2}{n})$. À medida que n cresce, a distribuição de \bar{X}_n torna-se mais concentrada ao redor de μ . Ver figura 8.3.

Dizemos que $\{\bar{X}_n\}$ é uma seqüência *consistente* de estimadores de μ . Formalmente, uma seqüência $\{T_n\}$ de estimadores de um parâmetro θ é consistente se, para todo $\epsilon > 0$,




Figura 8.3

$$P\{|T_n - \theta| > \epsilon\} \rightarrow 0, n \rightarrow \infty. \quad (8.5)$$

É fácil ver que esta condição está satisfeita para $\{\bar{X}_n\}$, utilizando-se a *desigualdade de Chebyshev*, que afirma: se X é uma v.a. com $E(X) = \mu$ e $\text{Var}(X) = \sigma^2$, então

$$P\{|X - \mu| > \epsilon\} \leq \frac{\sigma^2}{\epsilon^2}, \quad (8.6)$$

para todo número $\epsilon > 0$. Ver Apêndice 2.

Usando (8.6), vemos que

$$P\{|\bar{X}_n - \mu| > \epsilon\} \leq \frac{\text{Var}(\bar{X}_n)}{\epsilon^2} = \frac{\sigma^2}{n\epsilon^2} \rightarrow 0, \quad n \rightarrow \infty, \quad (8.7)$$

o que mostra que $\{\bar{X}_n\}$ é consistente.

8.2 - ESTIMADORES DE MÍNIMOS QUADRADOS E ESTIMADORES DE MÁXIMA VEROSSIMILHANÇA

Retomemos o exemplo 4.3, em que tínhamos o modelo

$$d_i = D + e_i, \quad i=1, \dots, n. \quad (8.8)$$

Queremos estimar D com base nas n observações d_1, \dots, d_n . O método dos mínimos quadrados consiste em escolher o estimador \hat{D} , de D , que minimiza a soma dos quadrados dos erros e_i . Como

$$e_i = d_i - D, \quad i=1, \dots, n, \quad (8.9)$$

vemos que

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (d_i - D)^2, \quad (8.10)$$

que é uma função de D , $g(D)$ digamos. Se queremos determinar o mínimo desta função, temos

$$g'(D) = \sum_{i=1}^n (d_i - \hat{D})(-2) = 0, \quad (8.11)$$

do que decorre

$$\hat{D} = \frac{\sum_{i=1}^n d_i}{n}, \quad (8.12)$$

isto é, o chamado *estimador de mínimos quadrados* de D é a média amostral dos d_i .

Se queremos obter um intervalo de confiança para D ou testar hipóteses a respeito de D é necessário fazer algumas hipóteses a respeito da distribuição dos erros e_i . Normalmente, as suposições que se fazem são:

- (i) e_i é uma v.a. com média 0, ou é simétrica ao redor de 0;
- (ii) e_i é uma v.a. normal;
- (iii) a variância de e_i é constante.

A situação geral é aquela em que queremos estimar um parâmetro vetorial $\underline{\theta} = (\theta_1, \dots, \theta_r)$ e as observações satisfazem ao modelo

$$X_i = g_i(\underline{\theta}) + e_i, \quad (8.13)$$

$i=1, \dots, n$. Escolhamos o estimar $\hat{\underline{\theta}}$ que minimiza

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (X_i - g_i(\underline{\theta}))^2. \quad (8.14)$$

Outro método de estimação que é bastante utilizado é o chamado *método de máxima verossimilhança*.

O princípio de máxima verossimilhança afirma o se-

guinte: devemos escolher aquele valor de θ que maximiza a probabilidade de obter a amostra observada, na ordem particular na qual os itens da amostra apareceram.

Exemplo 8.2 - Suponha que temos n provas de Bernoulli com $P(\text{sucesso}) = p$ e $X = \text{número de sucessos}$. Devemos tomar como estimador aquele valor de p que torna a amostra observada a mais provável de ocorrer.

Suponha que $n = 3$ e obtemos 2 sucessos e 1 fracasso. A função de verossimilhança é

$$L(p) = P(2 \text{ sucessos e } 1 \text{ fracasso}) = p^2(1-p) \quad (8.15)$$

Maximizando esta função, obtemos:

$L'(p) = 2p(1-p) - p^2 = 0 \implies p(2-3p) = 0$, do que seguem $p = 0$ e $p = 2/3$. É fácil ver que o ponto de máximo é $\hat{p} = 2/3$ que é o estimador de máxima verossimilhança de p .

De modo geral, o estimador de máxima verossimilhança do parâmetro p de uma binomial, com X sucessos em n prova é

$$\hat{p} = \frac{X}{n} . \quad (8.16)$$

Observe que este é o estimador que temos usado constantemente. Para se chegar ao resultado (8.16) observamos que a função de verossimilhança neste caso é

$$L(p) = p^X(1-p)^{n-X}, \quad (8.17)$$

e que o máximo desta função ocorre no mesmo ponto que $\log L(p)$.

Portanto, sendo

$$\ell(p) = \log L(p) = x \log p + (n-x) \log(1-p),$$

temos

$$\ell'(p) = \frac{x}{p} - \frac{n-x}{1-p} = 0 \implies \hat{p} = \frac{x}{n}.$$

Exemplo 8.3 - Em muitos problemas biológicos, tem importância o problema da estimação do tamanho de populações animais ou vegetais. Implicações práticas referem-se ao controle de insetos e manutenção de suprimentos de alimentos.

Suponha que capturamos, marcamos e depois soltamos r animais de uma população total de N animais, sendo N desconhecido. Quando os animais marcados tiverem se dispersado entre os não marcados, nós capturamos n animais (isto é, colhemos uma amostra de tamanho n da população de N animais) dos quais k são marcados. Vamos supor, primeiramente, que n é suficientemente pequeno, comparado com N , para que possamos ignorar complicações com a amostragem sem reposição.

A função de verossimilhança será

$$L(N) = \binom{n}{k} \left(\frac{r}{N}\right)^k \left(1 - \frac{r}{N}\right)^{n-k}, \quad (8.18)$$

e tomando logaritmo,

$$\ell(N) = \text{constante} + (n-k)\log(N-r) - n \log N.$$

Se bem que N seja discreto, será conveniente tratá-lo como se fosse contínuo, de modo que

$$\frac{\partial \ell}{\partial N} = \frac{N-k}{N-r} - \frac{n}{N}. \quad (8.19)$$

Donde, o estimador de máxima verossimilhança de N será

$$\hat{N} = \frac{rn}{k}. \quad (8.20)$$

Se capturamos, por exemplo, 100 animais e os marcamos e após algum tempo efetuamos nova captura de 100 animais e vemos que 10 dentre eles são marcados, então uma estimativa de N será $\hat{N} = \frac{100 \times 100}{10} = 1.000$ animais.

Utilizando a distribuição hipergeométrica, no caso em que a suposição acima feita, sobre a relação entre n e N não está satisfeita, temos que a função de verossimilhança será

$$L(N) = \frac{\binom{r}{k} \binom{N-r}{n-k}}{\binom{N}{n}} \quad (8.21)$$

Como $N-r \geq n-k$, vemos que podemos ter, de início, que

$$N \geq r + n - k.$$

No exemplo numérico acima, $N \geq 190$. Por exemplo, podemos testar a hipótese

$$H: N \leq 190$$

contra

(8.22)

$$K: N > 190.$$

É fácil ver que rejeitamos H, bastando calcular a probabilidade de se obter 10 marcados dentre os 100 escolhidos, para $N=190$. Esta probabilidade será bem pequena. Para obter o estimador de máxima verossimilhança, neste caso, o trabalho é mais complicado. Pode-se demonstrar que o estimador é dado por

$$\hat{N} = \left[\frac{rn}{k} \right], \quad (8.23)$$

onde $[y]$ indica o maior inteiro contido em y . No exemplo acima, $\hat{N} = \left[\frac{100 \times 100}{10} \right] = 1.000$, que é o mesmo estimador obtido antes. (Ver problemas).

8.3 - O PROBLEMA GERAL DO TESTE DE HIPÓTESES

No capítulo 6 introduzimos as primeiras idéias sobre teste de hipóteses e tratamos extensivamente do caso em que queremos por ã prova afirmações sobre o parâmetro p de uma distribuição binomial.

Vamos considerar os seguintes exemplos.

Exemplo 8.4 - Há uma certa variabilidade no tempo necessário para que uma máquina complete dada tarefa. Deseja-se testar a validade da afirmação:

"A máquina leva, em média, 20 minutos para efetuar a tarefa".

Exemplo 8.5 - Um gerente de vendas deseja testar dois esquemas de promoção de vendas, I e II digamos. Especificamente, ele quer testar a hipótese:

"Ambos os esquemas são semelhantes, no sentido que as quantidades do produto vendidas, decorrentes do uso de I e II, são as mesmas."

Cada afirmação acima é uma *hipótese estatística*. Para testar cada uma delas, teremos que usar algum processo ou regra de decisão que envolva:

- a) escolher uma amostra aleatória;
- b) encontrar uma estatística conveniente;
- c) usar a distribuição amostral da estatística para tomar uma decisão.

Estes três passos constituem um teste da hipótese em questão. De maneira um pouco mais formal diremos que uma hipótese estatística é uma afirmação sobre o valor de um parâmetro desconhecido da distribuição de uma variável aleatória, que representa uma característica de interesse de uma população.

Denotando por H cada afirmação dos exemplos citados, poderemos escrever, em uma notação concisa,

$$H: \mu = 20 \quad \text{e} \quad H: \mu_I = \mu_{II}, \quad (8.24)$$

para os exemplos 8.4 e 8.5, respectivamente. No primeiro caso, o tempo necessário para completar a tarefa é uma v.a.cu ja distribuição é desconhecida, totalmente ou parcialmente, e μ representa a média desta distribuição. Interpretação semelhante para o segundo caso.

Chamaremos H de *hipótese nula*, para cada hipótese nula formulada teremos uma *hipótese alternativa* e que pode tomar formas diferentes, dependendo do problema. Denotando-se por K uma hipótese alternativa, podemos ter para os exemplos dados:

$$\text{Exemplo 8.4: } \begin{cases} H: \mu = 20 \\ K: \mu \neq 20 \end{cases} \quad (8.25)$$

$$\text{Exemplo 8.5: } \begin{cases} H: \mu_I = \mu_{II} \\ K: \mu_I > \mu_{II} \end{cases} \quad (8.26)$$

Vamos analisar detidamente o exemplo 8.4. Aqui, o parâmetro que está sendo testado é uma média desconhecida.

O conjunto de todos os valores possíveis de μ é chamado o *espaço do parâmetro* e é indicado pela letra Θ . Podemos supor aqui que

$$\Theta = \{\mu: \mu \geq 0\}, \quad (8.27)$$

já que a variável em questão é tempo.

Sob a hipótese nula, $\mu = 20$ e sob a hipótese alternativa, $\mu \neq 20$. Estas duas hipóteses, H e K, definem dois subconjuntos de Θ :

$$\theta_0 = \{\mu: \mu = 20\} = \{20\} \quad (8.28)$$

e

$$\theta_1 = \theta - \theta_0 = \{\mu: \mu \neq 20\}. \quad (8.29)$$

Em termos dos conjuntos acima, a formulação (8.25) é equivalente a

$$\begin{aligned} H: \mu \in \theta_0 \\ K: \mu \in \theta_1 \end{aligned} \quad (8.30)$$

Esta formulação de um problema de teste de hipóteses é a mais geral possível e sempre pode ser feita.

Dizemos que uma hipótese H (ou K) é simples se θ_0 (ou θ_1) reduz-se a um ponto, isto é, se especificamos completamente o valor do parâmetro. No exemplo 8.4, $H: \mu = 20$ é uma hipótese simples^(*). Uma hipótese H (ou K) diz-se composta se θ_0 (ou θ_1) possui mais que um ponto. A hipótese $K: \mu \neq 20$ do mesmo exemplo é composta.

A situação mais fácil de ser estudada é quando temos uma hipótese simples contra uma alternativa simples:

$$\begin{aligned} H: \theta = \theta_0 \\ K: \theta = \theta_1 \end{aligned} \quad (8.31)$$

No exemplo 8.4, poderíamos estar interessados em testar a hipótese que a média é 20, contra a alternativa que

(*) Estamos supondo aqui que μ é o único parâmetro desconhecido.

a média é 23.

Lembremos que ao testar uma hipótese podemos tomar uma decisão errada em duas situações:

- (i) rejeitando-se H , quando ela é verdadeira: *erro de tipo I*;
- (ii) aceitando-se H , quando ela é falsa: *erro de tipo II*.

Designamos por α e β , respectivamente, as probabilidades de cada tipo de erro.

Para a situação (8.31), o quadro abaixo resume as possibilidades que podem ocorrer.

DECISÃO	"ESTADO DA NATUREZA"	
	θ_0	θ_1
ACEITAR H	decisão correta	decisão incorreta: ERRO DE TIPO I
ACEITAR K	decisão incorreta: ERRO DE TIPO II	decisão correta

Por "estado da natureza" entendemos o verdadeiro valor do parâmetro θ .

Vimos que o primeiro passo para testar H contra K é dispor de observações $\{X_1, \dots, X_n\}$ da população. Construímos, então, uma *função de decisão*, que é uma função definida no espaço de todas as amostras de tamanho n (o *espaço a-*

mostral) e com valores no que chamaremos *espaço das ações*. Designando-se estes espaços por S e A , respectivamente, e por d uma tal função de decisão, então $d: S \rightarrow A$ é uma função tal que a todo ponto $(X_1, \dots, X_n) \in S$ corresponda uma ação $a \in A$: $a = d(X_1, \dots, X_n)$.

No caso de um teste de hipóteses, o espaço A consiste apenas de duas ações, a_0 e a_1 , digamos, com:

a_0 : ação de rejeitar H (e aceitar K);

a_1 : ação de rejeitar K (e aceitar H).

Portanto, $A = \{a_0, a_1\}$. O conjunto S ficará, automaticamente, particionado em dois subconjuntos, S_0 e S_1 , disjuntos e complementares, tais que:

S_0 = conjunto de todos os pontos (X_1, \dots, X_n) tais que somos levados a tomar a ação a_0 : rejeitar H ;

S_1 = conjunto de todos os pontos (X_1, \dots, X_n) tais que somos levados a tomar a ação a_1 : rejeitar K ;

O conjunto S_0 é a *região crítica* do teste, ou o conjunto (ou região) de rejeição da hipótese nula H .

Usualmente, o conjunto S_0 é determinado em termos da estatística usada no teste. Por exemplo, suponha que vamos basear nossa decisão em aceitar ou rejeitar $H: \mu = 20$, na estatística \bar{X} , isto é, na média amostral. Então, a região crítica poderá ser da forma $S_0 = \{(x_1, \dots, x_n): \bar{x} \geq c\}$, onde c é uma constante a ser determinada convenientemente. Neste

caso, as ações a_0 e a_1 seriam:

a_0 : rejeitar H quando $\bar{x} \geq c$,

a_1 : aceitar H (rejeitar K) quando $\bar{x} < c$.

Lembremos que, sendo impossível minimizar α e β simultaneamente, fixamos um valor para α e tentamos encontrar, dentre todos os testes com nível de significância α , aquele que minimiza β .

Qualquer procedimento que utilizemos nos levará a encontrar uma estatística T , que é uma função das observações, $T(X_1, \dots, X_n)$, que será utilizada no teste. Normalmente, teremos que determinar um *valor crítico*, T_c , da estatística, que nos permite escolher entre H e K . Este valor crítico delimitará a região crítica, que será da forma

$$\{(x_1, \dots, x_n) : T(x_1, \dots, x_n) \geq T_c\} \quad (8.32)$$

ou

$$\{(x_1, \dots, x_n) : T(x_1, \dots, x_n) < T_c\} \quad (8.33)$$

Exemplo 8.6 - Suponha que queremos testar

$$H: \mu = 50$$

contra a alternativa

$$K: \mu < 50,$$

onde μ é a média de uma normal $N(\mu, 900)$. Suponha que a regra de decisão seja a seguinte:

"Extraída uma amostra de tamanho $n = 36$, rejeite H se $\bar{X} < \bar{X}_c$."

onde \bar{X}_c é o valor crítico de \bar{X} , determinado de tal sorte $\alpha = 0,025$.

A região crítica será da forma

$$S_0 = \{(x_1, \dots, x_{36}) : \bar{x} < \bar{x}_c\}. \quad (8.34)$$

Se a população é $N(\mu, 900)$, então \bar{X} tem distribuição (distribuição amostral de \bar{X}) normal, com média μ e variância $\frac{900}{n} = \frac{900}{36} = 25$. Logo,

$$\alpha = P(\bar{X} < \bar{X}_c \mid H \text{ verdadeira}) = P\left(\frac{\bar{X} - \mu}{\sigma_{\bar{X}}} < \frac{\bar{X}_c - \mu}{\sigma_{\bar{X}}} \mid H\right),$$

$\sigma_{\bar{X}} = 5$ é o desvio padrão de \bar{X} . Portanto,

$$\alpha = P\left(Y < \frac{\bar{X}_c - 50}{5}\right), \quad (8.35)$$

onde Y tem distribuição normal $N(0,1)$. Como $\alpha = 0,025$, a relação (8.35) implica (ver tabela 2 e figura 8.4)

$$\frac{\bar{X}_c - 50}{5} = 1,96,$$

ou seja, $\bar{X}_c = 40,2$. Logo, as regras de decisão a_0 e a_1 serão:

a_0 : rejeitar H se $\bar{X} < 40,2$;

a_1 : rejeitar K se $\bar{X} \geq 40,2$.

8.4 - O TESTE DA RAZÃO DE VEROSSIMILHANÇA

Vamos considerar, nesta seção, apenas o caso em que




Figura 8.4

queremos testar uma hipótese simples contra uma alternativa simples, ou seja,

$$H: \theta = \theta_0 \tag{8.36}$$

$$K: \theta = \theta_1$$

Como vimos, nós controlamos o nível de significância, α , e tentamos minimizar a probabilidade do erro de tipo II, β . Se existe uma região crítica que tenha nível α e que minimiza β dentre todas as regiões críticas de nível no máximo α , esta será a *melhor região crítica de nível α* . Obtemos, então, um *melhor teste*.

Suponha que temos uma amostra (X_1, \dots, X_n) de uma v.a. X que tenha distribuição dependendo de um parâmetro θ que pode assumir somente os valores θ_0 e θ_1 . Fixemos α , $0 < \alpha < 1$. Designemos por $L(\theta; x_1, \dots, x_n)$ a função de verossimilhança correspondente à amostra x_1, \dots, x_n , isto é, a probabilidade $P(X_1=x_1, \dots, X_n=x_n)$, sendo que destacamos a depen-

$$\alpha = P(\text{rejeitar } H | \theta = \frac{1}{3}) = P\left(\sum_{i=1}^n X_i \geq C | \theta = \frac{1}{3}\right) = \sum_{i=C}^5 \binom{5}{i} \left(\frac{1}{3}\right)^i \left(\frac{2}{3}\right)^{5-i}.$$

Se $\alpha = 0,0453$, então $C=4$ e $S_0 = \{(x_1, \dots, x_5) : \sum_{i=1}^5 X_i \geq 4\}$ e se $\alpha = 0,2099$, então $C=3$ e $S_0 = \{(x_1, \dots, x_5) : \sum_{i=1}^5 X_i \geq 3\}$, mas, se $\alpha = 0,05$, não existe constante C e região crítica S_0 satisfazendo às condições estipuladas. Na prática, mudamos o valor de α para o qual o teste pode ser encontrado, ou então usamos um procedimento chamado *aleatorização*, que permite obter um teste de nível exatamente igual ao valor α fixado. Mas este assunto não será discutido aqui.

Exemplo 8.8 - Suponha que queiramos testar

$$H: \theta = \theta_0 \tag{8.43}$$

$$K: \theta = \theta_1$$

onde $\theta_1 > \theta_0$, e θ é a média desconhecida de uma normal $N(\theta, \sigma_0^2)$, onde σ_0^2 é conhecido.

Aqui, para uma amostra de tamanho n , onde e^y será denotado por $\exp\{y\}$,

$$\begin{aligned} L(\theta; x_1, \dots, x_n) &= \prod_{i=1}^n \frac{1}{\sigma_0 \sqrt{2\pi}} \exp\left\{-\frac{1}{2} \left(\frac{x_i - \theta}{\sigma_0}\right)^2\right\} = \\ &= \left(\frac{1}{2\pi\sigma_0^2}\right)^{n/2} \exp\left\{-\frac{1}{2\sigma_0^2} \sum_{i=1}^n (x_i - \theta)^2\right\} \end{aligned} \tag{8.44}$$

Portanto,

$$\lambda = \frac{L_0}{L_1} = \frac{\exp\left\{-\frac{1}{2\sigma_0^2} \sum_{i=1}^n (x_i - \theta_0)^2\right\}}{\exp\left\{-\frac{1}{2\sigma_0^2} \sum_{i=1}^n (x_i - \theta_1)^2\right\}} = \exp\left\{-\frac{1}{2\sigma_0^2} \left[\sum (x_i - \theta_0)^2 - \sum (x_i - \theta_1)^2 \right]\right\}$$

Segue-se que $\lambda \leq k$ é equivalente a

$$\exp\left\{-\frac{1}{2\sigma_0^2} \left[2(\theta_1 - \theta_0) \sum x_i + n(\theta_0^2 - \theta_1^2) \right]\right\} \leq k,$$

ou

$$\exp\left\{\frac{\theta_0 - \theta_1}{\sigma_0^2} \sum x_i + \frac{n(\theta_1^2 - \theta_0^2)}{2\sigma_0^2}\right\} \leq k,$$

ou ainda,

$$\frac{\theta_0 - \theta_1}{\sigma_0^2} \sum x_i + \frac{n(\theta_1^2 - \theta_0^2)}{2\sigma_0^2} \leq \log k. \quad (8.45)$$

Como $\theta_0 - \theta_1 < 0$, obtemos

$$\sum x_i \geq \frac{(\log k)\sigma_0^2}{\theta_0 - \theta_1} + \frac{n \cdot (\theta_1 + \theta_0)}{2},$$

isto é,

$$\sum_{i=1}^n x_i \geq C, \quad -\infty < C < +\infty. \quad (8.46)$$

Portanto, a região crítica é

$$S_0 = \{(x_1, \dots, x_n) : \sum_{i=1}^n x_i \geq C\}$$

é não viciado e de variância mínima?

8.4 - Suponha que obtemos uma amostra (X_1, \dots, X_n) da distribuição de uma v.a. X que tem densidade

$$f(x) = \alpha e^{-\alpha x}, \quad x \geq 0.$$

Obtenha o estimador de máxima verossimilhança de α .

8.5 - A v.a. Y é observada para cada um dos n níveis X_1, \dots, X_n de uma variável fixa X , estabelecendo-se o seguinte modelo:

$$Y_i = \alpha + \beta X_i + \epsilon_i, \quad i=1, \dots, n$$

onde α e β são constantes a serem determinadas e ϵ_i são erros (variáveis aleatórias). Obtenha os estimadores de mínimos quadrados para α e β , isto é, aqueles valores $\hat{\alpha}$ e $\hat{\beta}$ que minimizam

$$\sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2.$$

8.6 - Suponha que os valores observados de Y , para os valores $X_1=0, X_2=1, X_3=2, X_4=3$ e $X_5=4$ são, respectivamente, $Y_1=-3,5, Y_2=0,5, Y_3=1,2, Y_4=2,8$ e $Y_5=5,1$. Calcule os estimadores $\hat{\alpha}$ e $\hat{\beta}$ do problema 8.5.

8.7 - No exemplo 8.3, considere o caso em que temos a função de verossimilhança dada por (8.21), isto é, o modelo é a distribuição hipergeométrica. Para se obter o estimador de máxima verossimilhança de N , \hat{N} , considere a razão

$$\frac{L(N)}{L(N-1)} = \frac{(N-n)(N-r)}{(N-n-r+k)N}.$$

Veja o que acontece quando $\frac{L(N)}{L(N-1)} \geq 1$.

8.8 - Queremos testar $H: \theta = \theta_0$ contra a alternativa $K: \theta = \theta_1$, se X é uma v.a. discreta assumindo os valores $0, 1, 2,$

3,4 e 5. Suponha que fazemos uma só observação, X_1 . Na tabela abaixo damos as distribuições de X sob H e K .

x	0	1	2	3	4	5
$P(X=x \theta_0)$	0,01	0,03	0,04	0,04	0,38	0,50
$P(X=x \theta_1)$	0,04	0,05	0,010	0,010	0,40	0,31

Fixe o nível de significância $\alpha = 0,04$. Determine as possíveis regiões críticas e o erro de tipo II, β , associado a cada uma delas. Encontre o melhor teste de nível α ,

- 8.9 - Para o exemplo 8.8, encontre o erro de tipo II, β .
- 8.10- Para o mesmo exemplo 8.8, determine o valor de n que nos dê valores fixados de α e β , precisamente, $\alpha=0,05$ e $\beta=0,10$.
- 8.11- No exemplo 8.8, vimos que o teste (8.46) é uniformemente melhor para testar $H: \theta=\theta_0$ contra $K: \theta>\theta_0$. Suponha, agora, que queremos testar $H: \theta=\theta_0$ contra $K: \theta\neq\theta_1$. Usando considerações de simetria, explique porque não esperamos obter um melhor teste, uniformemente, quando o valor alternativo de θ pode ser maior ou menor que θ_0 .
- 8.12- Determinar o teste da razão de verossimilhança para testar

$$H: \lambda = \lambda_0$$

$$K: \lambda = \lambda_1 < \lambda_0$$

onde λ é a média desconhecida de uma distribuição de Poisson,

$$P(X=k) = \frac{e^{-\lambda} \cdot \lambda^k}{k!}, \quad k=0,1,2,\dots$$

Aplique o resultado para $\lambda_0=5$, $\lambda_1=4,8$.

REFERÊNCIAS

- [1] - Bailey, N.T.J.: ON ESTIMATING THE SIZE OF MOBILE POPULATIONS FROM RECAPTURE DATA. *Biometrika*, Vol. 38, 1951, pp. 293-306.
- [2] - Blackwell D.: ESTATÍSTICA BÁSICA. Ed. McGraw-Hill do Brasil, 1973.
- [3] - Feller, W.: AN INTRODUCTION TO PROBABILITY THEORY AND ITS APPLICATIONS. J. Wiley & Sons, 3^a edição, 1968.
- [4] - Fernandez, P.J.: INTRODUÇÃO À TEORIA DAS PROBABILIDADES. Livros Técnicos e Científicos S.A., 1973.
- [5] - Lindgren, B.: ELEMENTS OF DECISION THEORY. The Mac Millan Company, 1971.
- [6] - Meyer, P.L.: INTRODUCTORY PROBABILITY AND STATISTICAL APPLICATIONS. Addison Wesley, 1965.
- [7] - Mosteller, Rourke & Thomas: PROBABILITY WITH STATISTICAL APPLICATIONS, 2^a edição, Addison Wesley, 1970.
- [8] - Noether, G.: INTRODUCTION TO STATISTICS. A FRESH APPROACH. Houghton Mifflin, 1971.

APÊNDICE 1

TABELA 1 - PROBABILIDADES BINOMIAIS

Exemplo: $b(6;10,0,3) = 0,037 = b(4;10,0,7)$


p	0,05					0,10					0,20					0,30					0,40					0,50									
	n=0	n=1	n=2	n=3	n=4	n=0	n=1	n=2	n=3	n=4	n=0	n=1	n=2	n=3	n=4	n=0	n=1	n=2	n=3	n=4	n=0	n=1	n=2	n=3	n=4	n=0	n=1	n=2	n=3	n=4					
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
26	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
27	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
28	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
29	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
30	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
31	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
n=31	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Tabelas reproduzidas de "TABUAS DE ESTATÍSTICA E MATEMÁTICA" de W.O.Bussab e J.S.C.Pereira, sob permissão da Editora Brasileira S.A. (Tabelas 1, 2, 3 e 4).

TABELA 2 - ÁREAS SOB A CURVA NORMAL PADRÃO

Exemplo: $P(Z > 1,2) =$

$0,5 - 0,38493 = 0,11507$




parte inteira e primeira decimal de Z_c	SEGUNDA DECIMAL DE Z_c										parte inteira e primeira decimal de Z_c	
	0	1	2	3	4	5	6	7	8	9		
$P = 0,$												
0,0	00000	00398	00798	01197	01595	01994	02392	02790	03188	03586	0,0	
0,1	00993	01389	01786	02182	02577	02972	03367	03762	04157	04552	0,1	
0,2	04946	05341	05736	06131	06526	06921	07316	07711	08106	08501	0,2	
0,3	08896	09291	09686	10081	10476	10871	11266	11661	12056	12451	0,3	
0,4	12846	13241	13636	14031	14426	14821	15216	15611	16006	16401	0,4	
0,5	16796	17191	17586	17981	18376	18771	19166	19561	19956	20351	0,5	
0,6	20746	21141	21536	21931	22326	22721	23116	23511	23906	24301	0,6	
0,7	24696	25091	25486	25881	26276	26671	27066	27461	27856	28251	0,7	
0,8	28646	29041	29436	29831	30226	30621	31016	31411	31806	32201	0,8	
0,9	32596	32991	33386	33781	34176	34571	34966	35361	35756	36151	0,9	
1,0	36546	36941	37336	37731	38126	38521	38916	39311	39706	40101	1,0	
1,1	40496	40891	41286	41681	42076	42471	42866	43261	43656	44051	1,1	
1,2	44446	44841	45236	45631	46026	46421	46816	47211	47606	48001	1,2	
1,3	48396	48791	49186	49581	49976	50371	50766	51161	51556	51951	1,3	
1,4	52346	52741	53136	53531	53926	54321	54716	55111	55506	55901	1,4	
1,5	56296	56691	57086	57481	57876	58271	58666	59061	59456	59851	1,5	
1,6	60246	60641	61036	61431	61826	62221	62616	63011	63406	63801	1,6	
1,7	64196	64591	64986	65381	65776	66171	66566	66961	67356	67751	1,7	
1,8	68146	68541	68936	69331	69726	70121	70516	70911	71306	71701	1,8	
1,9	72096	72491	72886	73281	73676	74071	74466	74861	75256	75651	1,9	
2,0	76046	76441	76836	77231	77626	78021	78416	78811	79206	79601	2,0	
2,1	79996	80391	80786	81181	81576	81971	82366	82761	83156	83551	2,1	
2,2	83946	84341	84736	85131	85526	85921	86316	86711	87106	87501	2,2	
2,3	87896	88291	88686	89081	89476	89871	90266	90661	91056	91451	2,3	
2,4	91846	92241	92636	93031	93426	93821	94216	94611	95006	95401	2,4	
2,5	95796	96191	96586	96981	97376	97771	98166	98561	98956	99351	2,5	
2,6	99746										2,6	
2,7											2,7	
2,8											2,8	
2,9											2,9	
3,0											3,0	
3,1											3,1	
3,2											3,2	
3,3											3,3	
3,4											3,4	
3,5											3,5	
3,6											3,6	
3,7											3,7	
3,8											3,8	
3,9											3,9	
4,0											4,0	
4,5											4,5	

parte inteira e primeira decimal de Z_c	SEGUNDA E TERCEIRA DECIMAIS DE Z_c								parte inteira e primeira decimal de Z_c		
	05	15	25	35	45	55	65	75		85	95
$P = 0,$											
0,0	00199	00596	00997	01396	01795	02193	02591	02989	03387	03784	0,0
0,1	04181	04578	04974	05369	05764	06159	06553	06948	07343	07738	0,1
0,2	08121	08512	08901	09290	09677	10064	10450	10836	11221	11606	0,2
0,3	11982	12368	12741	13119	13495	13871	14244	14617	14988	15358	0,3
0,4	15726	16093	16453	16822	17184	17545	17903	18261	18618	18974	0,4
0,5	19322	19672	20021	20368	20712	21055	21396	21735	22073	22408	0,5
0,6	22741	23072	23401	23728	24054	24377	24697	25016	25333	25647	0,6
0,7	25959	26270	26577	26883	27186	27488	27788	28083	28377	28669	0,7
0,8	28959	29246	29531	29814	30094	30372	30649	30921	31192	31461	0,8
0,9	31727	31990	32252	32511	32767	33021	33273	33522	33769	34013	0,9
	05	15	25	35	45	55	65	75	85	95	


TABELA 3 - ÁREAS SOB A DENSIDADE t

Exemplo: $v = 24$,
 $P(t > 1,318) = 0,10$,
 $P(t < -1,318) = 0,10$




v	90%	80%	70%	60%	50%	40%	30%	20%	10%	5%	4%	2%	1%	0,5%	0,1%
1	0,158	0,325	0,510	0,727	1,000	1,376	1,863	2,578	3,614	5,051	6,964	9,581	13,121	18,466	27,654
2	0,142	0,289	0,445	0,617	0,816	1,091	1,388	1,886	2,720	3,703	4,849	6,265	8,095	10,327	14,068
3	0,137	0,277	0,424	0,584	0,785	1,058	1,355	1,753	2,587	3,570	4,716	6,132	7,962	10,194	13,935
4	0,134	0,271	0,414	0,568	0,771	1,041	1,338	1,736	2,570	3,553	4,699	6,115	7,945	10,177	13,917
5	0,132	0,267	0,406	0,562	0,767	1,030	1,326	1,724	2,558	3,541	4,687	6,103	7,935	10,165	13,909
6	0,131	0,265	0,404	0,559	0,718	0,998	1,314	1,718	2,552	3,535	4,679	6,098	7,930	10,161	13,906
7	0,130	0,263	0,402	0,549	0,711	0,988	1,311	1,715	2,550	3,533	4,677	6,096	7,928	10,160	13,905
8	0,130	0,262	0,399	0,546	0,706	0,983	1,308	1,712	2,548	3,531	4,675	6,094	7,926	10,159	13,904
9	0,129	0,261	0,398	0,543	0,703	0,980	1,306	1,710	2,546	3,529	4,673	6,092	7,924	10,158	13,903
10	0,129	0,260	0,397	0,542	0,700	0,979	1,305	1,709	2,545	3,528	4,672	6,091	7,923	10,157	13,902
11	0,128	0,260	0,396	0,540	0,697	0,976	1,303	1,707	2,543	3,526	4,670	6,089	7,921	10,156	13,901
12	0,128	0,259	0,395	0,539	0,695	0,973	1,302	1,706	2,542	3,525	4,669	6,088	7,920	10,155	13,900
13	0,128	0,259	0,394	0,538	0,694	0,970	1,301	1,705	2,541	3,524	4,668	6,087	7,919	10,154	13,899
14	0,128	0,258	0,393	0,537	0,692	0,968	1,300	1,704	2,540	3,523	4,667	6,086	7,918	10,153	13,898
15	0,128	0,258	0,393	0,536	0,691	0,966	1,299	1,703	2,539	3,522	4,666	6,085	7,917	10,152	13,897
16	0,128	0,258	0,392	0,535	0,690	0,965	1,298	1,702	2,538	3,521	4,665	6,084	7,916	10,151	13,896
17	0,128	0,257	0,392	0,534	0,689	0,963	1,297	1,701	2,537	3,520	4,664	6,083	7,915	10,150	13,895
18	0,127	0,257	0,392	0,534	0,688	0,962	1,297	1,700	2,536	3,519	4,663	6,082	7,914	10,149	13,894
19	0,127	0,257	0,391	0,533	0,687	0,961	1,296	1,699	2,535	3,518	4,662	6,081	7,913	10,148	13,893
20	0,127	0,257	0,391	0,533	0,687	0,960	1,295	1,698	2,534	3,517	4,661	6,080	7,912	10,147	13,892
21	0,127	0,257	0,391	0,532	0,686	0,959	1,294	1,697	2,533	3,516	4,660	6,079	7,911	10,146	13,891
22	0,127	0,256	0,390	0,532	0,686	0,958	1,293	1,696	2,532	3,515	4,659	6,078	7,910	10,145	13,890
23	0,127	0,256	0,390	0,531	0,685	0,957	1,292	1,695	2,531	3,514	4,658	6,077	7,909	10,144	13,889
24	0,127	0,256	0,390	0,531	0,684	0,956	1,291	1,694	2,530	3,513	4,657	6,076	7,908	10,143	13,888
25	0,127	0,256	0,390	0,531	0,684	0,955	1,290	1,693	2,529	3,512	4,656	6,075	7,907	10,142	13,887
26	0,127	0,256	0,389	0,531	0,684	0,955	1,289	1,692	2,528	3,511	4,655	6,074	7,906	10,141	13,886
27	0,127	0,256	0,389	0,531	0,684	0,955	1,289	1,691	2,527	3,510	4,654	6,073	7,905	10,140	13,885
28	0,127	0,256	0,389	0,530	0,684	0,955	1,288	1,690	2,526	3,509	4,653	6,072	7,904	10,139	13,884
29	0,127	0,256	0,389	0,530	0,684	0,955	1,288	1,689	2,525	3,508	4,652	6,071	7,903	10,138	13,883
30	0,127	0,256	0,388	0,530	0,683	0,954	1,287	1,688	2,524	3,507	4,651	6,070	7,902	10,137	13,882
35	0,126	0,255	0,388	0,529	0,682	0,952	1,285	1,686	2,522	3,505	4,649	6,068	7,900	10,135	13,880
40	0,126	0,255	0,388	0,529	0,681	0,951	1,284	1,685	2,521	3,504	4,648	6,067	7,899	10,134	13,879
50	0,126	0,254	0,387	0,528	0,679	0,949	1,282	1,683	2,519	3,502	4,646	6,065	7,897	10,132	13,877
60	0,126	0,254	0,387	0,528	0,678	0,948	1,281	1,682	2,518	3,501	4,645	6,064	7,896	10,131	13,876
80	0,126	0,254	0,386	0,528	0,677	0,946	1,279	1,680	2,516	3,499	4,643	6,062	7,894	10,129	13,874
100	0,126	0,253	0,385	0,527	0,676	0,945	1,278	1,679	2,515	3,498	4,642	6,061	7,893	10,128	13,873
∞	0,126	0,253	0,385	0,527	0,674	0,942	1,276	1,677	2,513	3,496	4,640	6,059	7,891	10,126	13,871

REGIÕES DE CONFIANÇA PARA $p(\alpha \leq 0,05)$



REGIÕES DE CONFIANÇA PARA $p(\alpha \leq 0,10)$



APÊNDICE 2

A.2.1 - DESIGUALDADE DE CHEBYSHEV

Seja X uma v.a. com $E(X) = \mu$ e $\text{Var}(X) = \sigma^2$ finita. Então, para todo $k > 0$, temos

$$P(|X - \mu| \geq k) \leq \frac{\text{Var}(X)}{k^2} \quad (\text{A.2.1})$$

DEMONSTRAÇÃO:

$$P(|X - \mu| \geq k) = \sum_{|x_j - \mu| \geq k} p(x_j),$$

onde $p(x_j) = P(X = x_j)$ e a soma é estendida a todos os x_j tais que $|x_j - \mu| \geq k$. Como $|x_j - \mu| \geq k$ se e somente se $(x_j - \mu)^2 \geq k^2$, temos que

$$\begin{aligned} \sum_{|x_j - \mu| \geq k} p(x_j) &= \sum_{(x_j - \mu)^2 \geq k^2} p(x_j) \leq k^{-2} \sum_{(x_j - \mu)^2 \geq k^2} (x_j - \mu)^2 p(x_j) \\ &\leq k^{-2} \sum_j (x_j - \mu)^2 p(x_j) = k^{-2} \cdot \text{Var}(X), \end{aligned}$$

o que prova (A.2.1).

Em particular, (A.2.1) é equivalente a

$$P(|X - \mu| \geq c\sigma) \leq \frac{1}{c^2} \quad (\text{A.2.2})$$

onde $c > 0$. Basta tomar $k = c\sigma$. Ou ainda,

$$P(|X-\mu| < c\sigma) \geq 1 - \frac{1}{c^2}. \quad (\text{A.2.3})$$

Para $c = 2$, (A.2.3) nos diz que

$$P(|X-\mu| < 2\sigma) \geq \frac{3}{4},$$

ou seja,

$$P(\mu - 2\sigma < X < \mu + 2\sigma) \geq \frac{3}{4}. \quad (\text{A.2.4})$$

Isto é, para qualquer v.a. X , com variância finita, pelo menos 3/4 da massa está compreendida no intervalo $[\mu - 2\sigma, \mu + 2\sigma]$.

Se X é normal, com média μ e variância σ^2 , sabemos que $P(\mu - 2\sigma < X < \mu + 2\sigma) \approx 0,95$, portanto o limite inferior dado por (A.2.4) é bastante impreciso. Todavia, como nada se pressupõe a respeito da distribuição de X , a não ser que tenha variância finita, a desigualdade (A.2.1) é bastante útil.

A.2.2 - LEI DOS GRANDES NÚMEROS

Consideremos n provas de Bernoulli com $p = P(\text{sucesso})$ e seja k o número de sucessos nas n provas. Então, a Lei dos Grandes Números afirma que, para todo $\epsilon > 0$,

$$P\left(\left|\frac{k}{n} - p\right| \geq \epsilon\right) \leq \frac{p(1-p)}{n\epsilon^2}. \quad (\text{A.2.5})$$

DEMONSTRAÇÃO: Utilizando (A.2.1) para a v.a. k/n ,

$$P\left(\left|\frac{k}{n} - p\right| \geq \epsilon\right) \leq \frac{\text{Var}(k/n)}{\epsilon^2}.$$

Mas, sabemos que $\text{Var}(k/n) = \frac{p(1-p)}{n}$, do que decorre (A.2.5).

Vemos que (A.2.5) é equivalente a

$$P\left(\left|\frac{k}{n} - p\right| < \epsilon\right) \geq 1 - \frac{p(1-p)}{n\epsilon^2}. \quad (\text{A.2.6})$$

É claro que (A.2.5) também implica

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{k}{n} - p\right| \geq \epsilon\right) = 0, \quad \forall \epsilon > 0. \quad (\text{A.2.7})$$

A Lei dos Grandes Números afirma que, para n grande, a proporção de sucessos k/n está próxima de $p = P(\text{sucesso})$.

No caso geral, se X_1, X_2, \dots é uma seqüência de v. a. independentes com uma distribuição comum, e se $E(X_i) = \mu$ existe, então, para todo $\epsilon > 0$,

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{X_1 + \dots + X_n}{n} - \mu\right| \geq \epsilon\right) = 0. \quad (\text{A.2.8})$$

A.2.3 - TEOREMA DO LIMITE CENTRAL

No Capítulo 3 discutimos a aproximação de uma binomial por uma normal. A justificativa teórica é dada pelo chamado *Teorema de De Moivre-Laplace*, que afirma o seguinte.

Sejam X_1, X_2, \dots, X_n variáveis binomiais, isto é, X_n é o número de sucessos em n provas de Bernoulli, $P(\text{sucesso}) = p$. Seja:

$$Y_n = \frac{X_n - np}{\sqrt{npq}}.$$

Então, quando $n \rightarrow \infty$,

$$P(Y_n \geq z) \rightarrow P(Z \geq z),$$

onde Z é a v.a. $N(0,1)$ e z é constante.

Ou seja, para n grande, a distribuição de Y_n pode ser aproximada por uma distribuição normal padrão.

Este teorema, para X_n binomial, é um caso especial de um resultado mais geral, chamado *Teorema do Limite Central*, que apresentamos na forma seguinte.

Seja $\{X_n\}$ uma seqüência de v.a. independentes e com a mesma distribuição, $E(X_n) = \mu$ e $\text{Var}(X_n) = \sigma^2$. Seja

$$Y_n = X_1 + X_2 + \dots + X_n.$$

Então, para z fixo, quando $n \rightarrow \infty$,

$$P\left(\frac{Y_n - n\mu}{\sigma\sqrt{n}} \geq z\right) \rightarrow P(Z \geq z),$$

onde Z é a v.a. $N(0,1)$.

O teorema pode ser generalizado, por exemplo, para o caso em que $\{X_n\}$ são independentes, mas não têm a mesma distribuição.

A.2.4 - HIPÓTESES COMPOSTAS

No Capítulo 8 vimos como testar uma hipótese simples contra uma alternativa simples. Vimos, também, para um caso especial, como testar uma hipótese composta contra uma alternativa composta. Para outros casos mais gerais temos que usar o *teste da razão de verossimilhança generalizado*, que passamos a discutir.

Suponhamos o teste

$$H: \theta \in \Theta_0$$

$$K: \theta \in \Theta_1,$$

como apresentado no Capítulo 8, $\Theta_0 \cup \Theta_1 = \Theta$. Seja $L(\theta; x_1, \dots, x_n)$ a função de verossimilhança para uma amostra (X_1, \dots, X_n) . A razão de verossimilhança generalizada é definida por

$$\lambda = \frac{\sup_{\theta \in \Theta_0} L(\theta; x_1, \dots, x_n)}{\sup_{\theta \in \Theta} L(\theta; x_1, \dots, x_n)} \quad (\text{A.2.9})$$

O princípio do teste da razão de verossimilhança generalizado afirma que rejeitamos H se $\lambda \leq \lambda_0$, onde λ_0 é uma constante a ser determinada de modo que o teste tenha nível α , $0 \leq \lambda_0 \leq 1$.

Se, em (A.2.9) substituirmos as observações (x_1, \dots, x_n) pelas v.a. correspondentes, escrevemos Λ para λ , pois a razão será uma v.a.

EXEMPLO - Vamos testar

$$H: \mu = \mu_0$$

$$K: \mu \neq \mu_0,$$


se (X_1, \dots, X_n) é uma amostra aleatória de uma distribuição normal $N(\mu, \sigma^2)$, onde μ e σ^2 são desconhecidos.

O espaço do parâmetro é

$$\Theta = \{(\mu, \sigma^2) : -\infty < \mu < \infty, \sigma^2 > 0\}$$

$$\Theta_0 = \{(\mu_0, \sigma^2) : 0 < \sigma^2 < \infty\}.$$

$$\Theta_1 = \{(\mu, \sigma^2) : \mu \neq \mu_0, \sigma^2 > 0\}.$$



A função de verossimilhança é

$$L(\mu, \sigma^2; x_1, \dots, x_n) = \left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right\}.$$

Vamos determinar $\sup L$ para $(\mu, \sigma^2) \in \Theta$. Tomando o $\log L$ e derivando em relação a μ e a σ^2 obtemos

$$\frac{1}{2\sigma^2} \sum (x_i - \mu) = 0$$

$$\frac{-n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum (x_i - \mu)^2 = 0,$$

do que decorrem

$$\hat{\mu} = \bar{x},$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2. \quad (\text{A.2.10})$$

Logo, as estatísticas que maximizam L são os estimadores de máxima verossimilhança de μ e σ^2 . Portanto, chamando L^* o $\sup_{(\mu, \sigma^2) \in \Theta} L$, temos que

$$\begin{aligned} L^*(x_1, \dots, x_n) &= \left(\frac{1}{2\pi\hat{\sigma}^2} \right)^{n/2} \exp\left\{ -\frac{1}{2\hat{\sigma}^2} \cdot n\hat{\sigma}^2 \right\} = \\ &= \left(\frac{1}{2\pi\hat{\sigma}^2} \right)^{n/2} \exp\left\{ -\frac{n}{2} \right\} \end{aligned} \quad (\text{A.2.11})$$

Agora, vamos determinar $\sup L$ para $(\mu, \sigma^2) \in \Theta_0$, isto é, $\mu = \mu_0$ e $\sigma^2 > 0$. Portanto, temos que maximizar

$$L(\mu_0, \sigma^2; x_1, \dots, x_n) = \left(\frac{1}{2\pi\sigma^2} \right)^{n/2} \exp\left\{ -\frac{1}{2\sigma^2} \sum (x_i - \mu_0)^2 \right\}.$$

Derivando $\log L$ em relação a σ^2 obtemos

$$\frac{\partial}{\partial \sigma^2} \log L = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu_0)^2, \quad (\text{A.2.12})$$

portanto, sendo L_* o $\sup_{(\mu, \sigma^2) \in \Theta_0} L$, vem que

$$L_* = \left(\frac{1}{2\pi\hat{\sigma}^2} \right)^{n/2} \exp\left\{ -\frac{n}{2} \right\}. \quad (\text{A.2.13})$$

A razão de verossimilhança (A.2.9) fica

$$\lambda = \frac{L^*}{L^*} = \frac{\left(\frac{1}{2\pi\hat{\sigma}^2}\right)^{n/2}}{\left(\frac{1}{2\pi\sigma^2}\right)^{n/2}} = \left(\frac{\hat{\sigma}^2}{\sigma^2}\right)^{n/2}. \quad (\text{A.2.14})$$

Como $x_i - \mu_0 = x_i - \bar{x} + \bar{x} - \mu_0$, vemos facilmente que

$$(x_i - \mu_0)^2 = n\hat{\sigma}^2 + n(\bar{x} - \mu_0)^2,$$

isto é,

$$\hat{\sigma}^2 = \sigma^2 + (\bar{x} - \mu_0)^2. \quad (\text{A.2.15})$$

Substituindo (A.2.15) em (A.2.14), obtemos:

$$\lambda = \left[\frac{1}{1 + \left(\frac{\bar{x} - \mu_0}{\sigma}\right)^2} \right]^{n/2}. \quad (\text{A.2.16})$$

Portanto,

$$\lambda \leq \lambda_0 \iff \left| \frac{\bar{x} - \mu_0}{\sigma} \right| > k \quad (\text{A.2.17})$$

O que pode ser demonstrado é que a v.a.


$$\frac{\bar{X} - \mu_0}{\hat{\sigma}/\sqrt{n-1}} \quad (\text{A.2.18})$$

tem uma distribuição t com n-1 graus de liberdade.

Como (A.2.17) é equivalente a

$$\left| \frac{\bar{x} - \mu_0}{\hat{\sigma} / \sqrt{n-1}} \right| > c, \quad (\text{A.2.19})$$

a constante c é determinada pela condição que $P(|t| > c) = \alpha =$ nível do teste, usando a tabela 3.



Por exemplo, se queremos testar

$$H: \mu = 10$$

$$K: \mu \neq 10,$$

ao nível $\alpha = 0,05$, e obtemos $\bar{X} = 9,8$, $\hat{\sigma}^2 = 2,25$ a partir de \underline{u} ma amostra de tamanho $n = 17$, então o valor de

$$\frac{\bar{x} - \mu_0}{\hat{\sigma} / \sqrt{n-1}} \text{ é } \frac{9,8 - 10}{(1,5)/4} = -0,33.$$

Como, para $\alpha = 0,05$, $c = 2,120$, vemos que a região de rejeição é $|t| > 2,120$. No caso, aceitamos H .

Nem sempre é possível obter de maneira fácil a distribuição da estatística a ser usada no teste. Sob determinadas condições, pode-se demonstrar que $-2 \log \Lambda$ tem uma distribuição limite, que é chamada *distribuição do qui-quadrado*. Esta distribuição, como a distribuição t , é caracterizada por um parâmetro, chamado também *número de graus de*


liberdade. No caso em questão, a distribuição limite tem $v = v_1 - v_2$ graus de liberdade, onde $v_1 =$ número de parâmetros independentes em θ e $v_2 =$ número de parâmetros independentes em θ_0 . No exemplo da normal acima, $v_1 = 2$ e $v_2 = 1$, e a distribuição limite é uma distribuição do qui-quadrado com 1 grau de liberdade, que denotamos χ_1^2 . De modo geral, uma distribuição qui-quadrado com v graus de liberdade tem função densidade

$$f(x;v) = \frac{1}{\Gamma(v/2)} \left(\frac{1}{2}\right)^{v/2} \cdot x^{(v/2)-1} \exp\left[-\frac{x}{2}\right], \quad x > 0 \quad (\text{A.2.20})$$
$$= 0, \quad x < 0$$

Aqui, $\Gamma(\cdot)$ é a função gama, definida por

$$\Gamma(p) = \int_0^{\infty} x^{p-1} e^{-x} dx,$$

para $p > 0$ real. O gráfico de (A.2.20) tem a forma da figura abaixo, para $v > 2$.



Esta distribuição é tabelada para diferentes valores de v , mas não apresentamos uma tal tabela no apêndice.

Quando falamos em distribuição limite, estamos considerando n grande. Portanto, a aproximação $-2 \log \Lambda \approx \chi^2_{\nu}$ só é razoável para amostras grandes. Não discutiremos, aqui, pormenores sobre esta aproximação, bem como a utilização da mesma em alguns testes (os chamados *testes do qui-quadrado*).

- • -

