

**Um estudo sobre suficiência,
ancilaridade, independência estatística
e os teoremas de Basu**

Márcia D'Elia Branco

DISSERTAÇÃO APRESENTADA
AO
INSTITUTO DE MATEMÁTICA E ESTATÍSTICA
DA
UNIVERSIDADE DE SÃO PAULO
PARA OBTENÇÃO DO GRAU DE MESTRE
EM
ESTATÍSTICA

Área de Concentração: **Estatística**
Orientador: **Prof. Dr. Carlos Alberto de Bragança Pereira**

–São Paulo, abril de 1991–

Dedico este trabalho a,

Carlota e Alcides

que possibilitaram minha formação .

E as pessoas que pelo apoio e acolhida, tornaram mais leve minha adaptação a esta cidade

Iara, Chico, Jana, Letícia, Leandro

em especial

a Társis

Agradeço ao meu orientador **Carlos Alberto de Bragança Pereira** e aos colegas **Victor Salinas e Carlos Daniel Paulino** pelo conjunto de idéias que possibilitaram a realização deste trabalho.

Agradeço aos meus amigos

Adilson Simonis

Fábio Machado

Giovani da Silva

Maria Paula Ferreira

pelo apoio em inúmeros momentos, antes e durante o trabalho.

NOTAÇÕES

$$\overline{\mathbb{R}} = \mathbb{R} \cup \{-\infty, +\infty\}$$

$$\{0, 1\}^2 = \{0, 1\} \times \{0, 1\} = \{(0, 0), (0, 1), (1, 0), (1, 1)\}$$

$$[a, b]^n = [a, b] \times [a, b] \times \dots \times [a, b]$$

$\mathcal{P}(\mathcal{X})$: conjunto das partes de \mathcal{X}

\mathcal{B} : sigma álgebra de Borel do \mathbb{R}

\mathcal{B}_n : sigma álgebra de Borel do \mathbb{R}^n

$\mathcal{B}_{[0,1]}$: sigma álgebra de Borel do $[0, 1]$

$$I_A(x) = \begin{cases} 1, & \text{se } x \in A; \\ 0, & \text{caso contrário.} \end{cases} \quad (\text{função indicadora})$$

$$\Gamma(a) = \int_0^{\infty} x^{a-1} e^{-x} dx, \quad a > 0 \quad (\text{função gama})$$

$$Be(a, b) = \int_0^1 x^{a-1} (1-x)^{b-1} dx, \quad a > 0, b > 0 \quad (\text{função beta})$$

ÍNDICE

INTRODUÇÃO	1
CAPÍTULO 1. Abordagem Clássica	3
1.1. Preliminares	3
1.2. Conceitos Fundamentais	5
1.3. Os Teoremas de Basu sob a Perspectiva Clássica	29
CAPÍTULO 2. Abordagem Bayesiana	37
2.1. Construção do Modelo Bayesiano	37
2.2. Conceitos Fundamentais	48
2.3. Os Teoremas de Basu sob a Perspectiva Bayesiana	58
CAPÍTULO 3. Aplicações	60
3.1. Caracterização da Distribuição de Dirichlet através da Distribuição Gama	60
3.2. O Resultado de Durbin	63
APÊNDICE A. Conceitos Básicos de Teoria da Medida	67
APÊNDICE B. Sistemas Dynkin	67
APÊNDICE C. Famílias Dominadas	70
APÊNDICE D. Ancilaridade e Invariância	73
Referências Bibliográficas	76

INTRODUÇÃO

Os conceitos de Suficiência, Ancilaridade e Independência Estatística são de grande importância na Teoria Estatística. Nossa intenção, neste trabalho, é apresentá-los numa abordagem matemática da Teoria da Medida, explorando cada um deles de maneira diferente daquela normalmente apresentada nos textos básicos de Teoria Estatística. Posteriormente, pretendemos relacioná-los através de três teoremas, apresentados por D.Basu. Usualmente, somente o primeiro teorema, conhecido como Teorema de Basu, é estudado.

Os conceitos básicos aqui trabalhados foram, a princípio, abordados em artigos segundo uma perspectiva Clássica e, nesta visão, construímos o Capítulo 1. Posteriormente, o próprio Basu reescreveu seus teoremas sob um ponto de vista bayesiano, deixando de considerar o parâmetro como um ente fixo mas tratando-o como um objeto aleatório. Nesta perspectiva, a independência estatística é uma forma de independência condicional e os demais conceitos podem ser reconstruídos de modo análogo, utilizando-se a esperança e a

independência condicional. Além disso, os Teoremas de Basu têm suas provas simplificadas e a relação dos conceitos de ancilaridade e suficiência com a idéia de informação torna-se mais clara. Nesta abordagem, apresentada no Capítulo 2, trabalha-se num universo matemático mais complexo, o que é possível perceber na unidade 2.1 onde construímos o modelo bayesiano.

Ao longo do trabalho procuramos apresentar, sempre que possível, exemplos. Nosso objetivo foi tornar mais claras as definições e proposições ou colocar em xeque algum senso comum. D.Basu parece gostar muito de contra-exemplos, procuramos apresentar aqui alguns de seus favoritos nesta área. No último capítulo destacamos dois exemplos. O primeiro, mais conhecido, devido sua importância na literatura e o segundo, devido sua utilização em problemas mais aplicados. Além disso, a respeito deste segundo exemplo, destacamos o modo como foi refeita a demonstração do Teorema de Durbin utilizando-se os argumentos estatísticos apresentados neste trabalho.

CAPITULO 1: ABORDAGEM CLÁSSICA

1.1. PRELIMINARES

Sejam \mathcal{X} um conjunto qualquer observável, \mathcal{A} uma sigma álgebra de subconjuntos de \mathcal{X} e \mathcal{P} uma família de medidas de probabilidade em $(\mathcal{X}, \mathcal{A})$. A trinca $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ será denominada neste trabalho de espaço estatístico. Considerando uma estrutura paramétrica, a família \mathcal{P} é indexada por um parâmetro θ , $\mathcal{P} = \{P_\theta : \theta \in \Theta\}$. Como na maioria das situações esta representação pode ser adotada, vamos utilizá-la.

Definição 1.1 : O modelo $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ é dominado se existe uma medida λ , σ -finita, tal que, se $N \in \mathcal{A}$ e $\lambda(N) = 0$, então $P_\theta(N) = 0$, $\forall P_\theta \in \mathcal{P}$. A notação usada será $\mathcal{P} \ll \lambda$.

Seja \mathcal{P}^* uma outra família de medidas de probabilidade em $(\mathcal{X}, \mathcal{A})$. Se $\forall N \in \mathcal{A}$ tal que $P_\theta(N) = 0$, $\forall P_\theta \in \mathcal{P}$, tivermos que $P_\theta^*(N) = 0$, $\forall P_\theta^* \in \mathcal{P}^*$, dizemos que $\mathcal{P}^* \ll \mathcal{P}$. As duas famílias são equivalentes se $\mathcal{P}^* \ll \mathcal{P}$ e $\mathcal{P} \ll \mathcal{P}^*$. Neste caso a notação é $\mathcal{P} \equiv \mathcal{P}^*$.

Teorema de Radon-Nikodym : Sejam λ e μ duas medidas sigma finitas no espaço mensurável $(\mathcal{X}, \mathcal{A})$, tais que $\mu \ll \lambda$. Nestas condições, existe uma função Borel mensurável $g : \mathcal{X} \rightarrow \overline{\mathbb{R}}$, tal que

$$\mu(A) = \int_A g d\lambda \quad \forall A \in \mathcal{A}.$$

Além disso, g é λ -essencialmente única. A função g é denominada derivada de Radon-Nikodym de μ em relação a λ e denotada por $\frac{d\mu}{d\lambda}$.

Se $\mathcal{P} \ll \lambda$, pelo teorema de Radon-Nikodym, existe $\frac{dP_\theta}{d\lambda}$, também denominada função densidade (f_θ). Usualmente, apenas são denominadas densidades as derivadas obtidas em relação a medida de Lebesgue.

Definição 1.2 : Considere dois espaços mensuráveis $(\mathcal{X}, \mathcal{A})$ e $(\mathcal{Y}, \mathcal{T})$. Uma estatística T é uma função mensurável de $(\mathcal{X}, \mathcal{A})$ em $(\mathcal{Y}, \mathcal{T})$. Se \mathcal{Y} é o \mathbb{R}^n , $n \in \mathbb{N}$, e \mathcal{T} a sigma álgebra de Borel, então T é uma variável (ou vetor) aleatória (o).

A toda estatística T está associada uma sigma álgebra no espaço de partida $(\mathcal{X}, \mathcal{A})$ que é gerada pelo conjunto $\{T^{-1}(B) : B \in \mathcal{T}\}$. Vamos denominá-la de sigma álgebra gerada por T e denotá-la por $\sigma(T)$.

Teorema 1.1: Seja $(\mathcal{X}, \mathcal{A}, P_\theta)$ um espaço de probabilidade. Seja f uma função \mathcal{A} -mensurável tal que, $\int_{\mathcal{X}} f dP_\theta < \infty$ e \mathcal{D} uma sub-sigma álgebra de \mathcal{A} . Nestas condições, existe uma função f^* , \mathcal{D} -mensurável, tal que

$$\int_D f dP_\theta = \int_D f^* dP_\theta \quad \forall D \in \mathcal{D}.$$

A notação usada será $f^* = E[f/\mathcal{D}]$, a esperança condicional de f dado \mathcal{D} .

No caso de \mathcal{D} ser gerada por uma estatística T ($\mathcal{D} = \sigma(T)$) usaremos, alternativamente, a notação $E[f/T]$. Além disso, se $f = I_A$ (função indicadora), temos

$$E[I_A/T] = P_\theta(A/T), \quad \forall A \in \mathcal{A},$$

a probabilidade condicional de A dado T .

Em muitas situações no decorrer deste trabalho, utilizaremos a probabilidade e a esperança condicionais, alternativamente, com o objetivo de simplificar . Entretanto, em todas elas poderíamos ter usado qualquer um dos dois operadores.

1.2. CONCEITOS FUNDAMENTAIS

Independência Estatística

A independência estatística difere da probabilística pelo fato de sua referência ser um espaço estatístico. Neste caso, trabalha-se com uma família de medidas de probabilidade e devemos garantir a independência para todo $P_\theta \in \mathcal{P}$.

Definição 1.3: Um evento $A \in \mathcal{A}$ é estatisticamente independente de uma estatística T se $P_\theta(A/T) = P_\theta(A)$ $\mathcal{P} - q.c..$ Uma estatística Y é estatisticamente independente de uma outra estatística T , se todo $A \in \sigma(Y)$ é estatisticamente independente de T .

Proposição 1.1: Duas estatísticas Y e T são independentes estatisticamente se, e somente se, para todo $A \in \sigma(Y)$ e todo $B \in \sigma(T)$,

$$P_\theta(A \cap B) = P_\theta(A)P_\theta(B) \quad \mathcal{P} - q.c..$$

Prova: (\Rightarrow) Seja $B \in \sigma(T)$ e $A \in \sigma(Y)$ então,

$$P_\theta(A \cap B) = \int_B I_A dP_\theta = \int_B P_\theta(A/T) dP_\theta = \int_B P_\theta(A) dP_\theta = P_\theta(A)P_\theta(B) , \forall \theta \in \Theta.$$

(\Leftarrow) Seja $A \in \sigma(Y)$ então,

$$\int_B I_A dP_\theta = P_\theta(A \cap B) = P_\theta(A)P_\theta(B) = \int_B P_\theta(A) dP_\theta , \forall B \in \sigma(T).$$

Logo $P_\theta(A)$ é uma versão da probabilidade condicional de A dado T . ◇

Exemplo 1.1: Seja $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ um espaço estatístico onde $\mathcal{P} = \{P_1, P_2\}$ e existe um $A \in \mathcal{A}$ tal que $P_1(A) = P_2(A^c) = 1$. Considere $Y = I_A$. Observe que $A = \{x \in \mathcal{X} : Y = 1\}$ e $A^c = \{x \in \mathcal{X} : Y = 0\}$.

Seja $B \in \mathcal{A}$, temos que,

$$P_\theta(B \cap A) = P_\theta(B)I_{\{1\}}(\theta) = P_\theta(B)P_\theta(A), \quad \forall \theta \in \{1, 2\}.$$

Similarmente, temos que

$$P_\theta(B \cap A^c) = P_\theta(B)P_\theta(A^c) \quad \forall \theta \in \{1, 2\}.$$

Como A e A^c geram $\sigma(Y)$, $\forall D \in \sigma(Y)$ e $\forall B \in \mathcal{A}$, temos

$$P_\theta(B \cap D) = P_\theta(B)P_\theta(D) \quad \forall \theta \in \{1, 2\}.$$

Portanto, Y é estatisticamente independente de X .

Exemplo 1.2: Seja $(\mathbb{R}, \mathcal{B}, \mathcal{P})$ um espaço estatístico onde $\mathcal{P} = \{P_\theta : \theta \in \mathbb{Z}\}$, tal que $P_\theta(x) = I_{[\theta, \theta+1[}(x)$. Considere $Y(x) = [x]$, onde $[x]$ é o maior inteiro de x .

Se $A \in \mathcal{B}$, $y \in \mathbb{Z}$ e $D_y = \{x \in \mathbb{R} : Y(x) = y\}$, então

$$P_\theta(A \cap D_y) = P_\theta(A)I_{\{\theta=y\}} = P_\theta(A)P_\theta(D_y).$$

Como $\{D_y : y \in \mathbb{Z}\}$ gera $\sigma(Y)$, a igualdade acima é válida $\forall D \in \sigma(Y)$ e $\forall \theta \in \mathbb{Z}$. Portanto, Y e X são estatisticamente independentes.

Suponha agora que observamos $X = 3, 2$. Podemos afirmar algo sobre Y ?

Claramente $Y = 3$. Mas, X e Y não são independentes ?

A idéia de independência, quando trabalha-se num espaço probabilístico, é de que se X e Y são variáveis independentes, o conhecimento da variável Y não altera a distribuição de probabilidade da variável X e vice versa. O que ocorre no caso da independência estatística, é que o conhecimento de X não altera o de Y dada a medida P_θ , isto é, supondo θ fixo.

No contexto Bayesiano fica mais fácil entender este conceito . Como naquele contexto θ tem uma distribuição de probabilidade, podemos pensar na probabilidade condicional (em relação a θ) , isto é, X e Y são condicionalmente independentes dado θ .

Exemplo 1.3: Considere $(\mathbb{R}, \mathcal{B}, \mathcal{P})$ onde $\mathcal{P} = \{P_\theta : \theta \in \mathbb{Z}\}$ e P_θ é uniforme em $[\theta-1, \theta+1]$.

Sejam X_1 e X_2 duas observações estatisticamente independentes. A princípio, X_1 e X_2 podem assumir quaisquer valores em \mathbb{R} . Entretanto, se observamos $X_1 = 3$ o que poderíamos dizer sobre X_2 ?

Evidentemente, após o conhecimento do valor de X_1 o conjunto de valores possíveis para X_2 fica reduzido, isto é,

$$\theta - 1 \leq X_1 \leq \theta + 1 \Leftrightarrow X_1 - 1 \leq \theta \leq X_1 + 1 \Leftrightarrow 2 \leq \theta \leq 4.$$

Logo, $1 \leq X_2 \leq 5$ com probabilidade um .

No entanto, se estivessemos trabalhando com o modelo de probabilidade $(\mathbb{R}, \mathcal{B}, P_1)$, onde P_1 é uniforme em $[0, 2]$, teríamos que $P_1(X_2 = x | X_1) = P_1(X_2 = x)$, $x \in [0, 2]$, isto é, o conhecimento sobre o valor de X_1 não altera a distribuição de X_2 .

Estatística Suficiente

O conceito de estatística suficiente é crucial quando discute-se a redução do que se observa, sem prejuízo da informação sobre o parâmetro. Os teoremas de Basu abordam justamente este tipo de redução.

Definição 1.5: T é uma estatística suficiente para $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ se para toda f , \mathcal{A} -mensurável, onde $\int_{\mathcal{X}} f dP_\theta < \infty$, $\forall \theta \in \Theta$, existe uma função f^* (livre de θ), $\sigma(T)$ -mensuravel, tal que,

$$f^*(T) = E_\theta[f | T] , \quad \forall \theta \in \Theta.$$

Em particular se $f = I_A$, onde $A \in \mathcal{A}$, então

$$f^*(T) = P_\theta(A | T) \quad \forall \theta \in \Theta.$$

Exemplo 1.4: Seja $(\mathbb{R}^n, \mathcal{B}_n, \mathcal{P})$ um espaço estatístico onde P_θ é uma medida de probabilidade Uniforme em $[0, \theta]^n$, $\forall \theta \in \Theta$. A função densidade neste caso é

$$f_\theta(x_1, x_2, \dots, x_n) = \theta^{-n} I_{[0, \theta]^n}(x_1, x_2, \dots, x_n).$$

A estatística $T(x_1, \dots, x_n) = \max(x_1, \dots, x_n)$ é suficiente para o modelo. De fato, definindo

$$A_t = \{\omega \in \mathcal{X} : T(\omega) \leq t\},$$

$$B_u = \{\omega \in \mathcal{X} : X_1(\omega) > u_1, X_2(\omega) > u_2, \dots, X_n(\omega) > u_n\}$$

e trabalhando com a função indicadora temos

$$\begin{aligned} \int_{A_t} I_{B_u} dP_\theta &= P_\theta(B_u \cap A_t) = P_\theta(T \leq t, X_1 > u_1, \dots, X_n > u_n) = \\ &= P_\theta(u_1 \leq X_1 \leq t, u_2 \leq X_2 \leq t, \dots, u_n \leq X_n \leq t) = \prod_{i=1}^n (t - u_i) \theta^{-n} = \\ &= \prod_{i=1}^n (t - u_i) t^{-n} P_\theta(T \leq t) = \int_{A_t} h dP_\theta, \end{aligned}$$

onde $h = \prod_{i=1}^n (t - u_i) t^{-n}$ é uma função livre de θ .

Como $\{A_t : t \in \mathbb{R}\}$ e $\{B_u : u \in \mathbb{R}^n\}$ são geradores de $\sigma(T)$ e \mathbb{R}^n respectivamente, temos que, para todo $A \in \sigma(T)$ e $B \in \mathbb{R}^n$,

$$\int_A I_B dP_\theta = \int_A h dP_\theta \quad \forall \theta \in \Theta.$$

Como h é uma função $\sigma(T)$ -mensurável e livre de θ , T é suficiente.

Em geral não é fácil verificar a suficiência pela definição. A seguir apresentamos um teorema, conhecido como Teorema da Fatoração (ou Halmos-Savage), que resolve este problema em muitos casos.

Teorema da Fatoração : Se o modelo estatístico $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ é dominado pela medida λ , uma condição necessária e suficiente para T ser uma estatística suficiente é que a derivada de Radon-Nikodym de P_θ com respeito a λ , $dP_\theta/d\lambda = f_\theta$, tenha a seguinte versão

$$f_\theta = g_\theta h,$$

onde g_θ é uma função $\sigma(T)$ -mensurável e h é uma função livre de θ .

Prova: (\Rightarrow) Como o modelo é dominado, existe um conjunto enumerável $\mathcal{P}_0 = \{P_1, P_2, P_3, \dots\}$ tal que $\mathcal{P} \equiv \mathcal{P}_0$ (apêndice C).

Seja λ_0 uma probabilidade em $(\mathcal{X}, \mathcal{A})$, tal que

$$\lambda_0(A) = \sum_{i=1}^{\infty} a_i P_i(A) \quad \forall A \in \mathcal{A},$$

onde $a_i = \frac{1}{2^i}$, $i = 1, 2, 3, \dots$. Então, $\lambda_0 \equiv \mathcal{P}_0 \Rightarrow \lambda_0 \equiv \mathcal{P}$.

Além disso, usando o fato de T ser suficiente, $\forall A \in \mathcal{A}$ e $\forall B \in \sigma(T)$, temos

$$\lambda_0(A \cap B) = \sum_{i=1}^{\infty} a_i P_i(A \cap B) = \sum_{i=1}^{\infty} a_i \int_B f(T) dP_i = \int_B f(T) d\lambda_0.$$

Portanto, $f(T)$ é também uma versão da probabilidade condicional para λ_0 .

Vamos mostrar agora que $\frac{dP_\theta}{dP_{\lambda_0}} = g_\theta$ é uma função $\sigma(T)$ -mensurável, $\forall P_\theta \in \mathcal{P}$.

Seja $A \in \mathcal{A}$ e $P_\theta \in \mathcal{P}$, então

$$\begin{aligned} \int_A g_\theta d\lambda_0 &= P_\theta(A) = \int_{\mathcal{X}} f(T) dP_\theta = \int_{\mathcal{X}} f(T) g_\theta d\lambda_0 = \\ &= \int_{\mathcal{X}} f(T) E_{\lambda_0}(g_\theta | T) d\lambda_0 = \int_{\mathcal{X}} E_{\lambda_0}(I_A g_\theta | T) d\lambda_0 = \\ &= \int_A E_{\lambda_0}(g_\theta | T) d\lambda_0 \quad \forall A \in \mathcal{A}. \end{aligned}$$

Logo, $g_\theta = E_{\lambda_0}(g_\theta | T)$ λ_0 -q.c.. Portanto, g_θ é $\sigma(T)$ -mensurável.

Podemos escrever $f_\theta = \frac{dP_\theta}{d\lambda} = \frac{dP_\theta}{d\lambda_0} \frac{d\lambda_0}{d\lambda} = g_\theta h$, com h livre de θ .

(\Leftarrow) Por hipótese $f_\theta = g_\theta h$. Usando a medida λ_0 definida anteriormente, podemos escrever $g_\theta = \frac{dP_\theta}{d\lambda_0}$ que por hipótese é $\sigma(T)$ -mensurável.

Fixo $E \in \mathcal{A}$ e $P_\theta \in \mathcal{P}$, seja ν uma medida de probabilidade tal que

$$\nu(A) = P_\theta(A \cap E) \quad \forall A \in \mathcal{A}. \quad (1.1)$$

Então,

$$\begin{aligned} \int_A d\nu &= \int_A I_E dP_\theta = \int_A P_\theta(E | T) dP_\theta = \\ &= \int_A P_\theta(E | T) g_\theta(T) d\lambda \quad \forall A \in \mathcal{A}. \end{aligned} \quad (1.2)$$

Por outro lado, de (1.1) temos que

$$\begin{aligned} \int_A d\nu &= \int_A I_E dP_\theta = \int_A I_E g_\theta(T) d\lambda_0 = \\ &= \int_A \lambda_0(E | T) g_\theta(T) d\lambda_0 \quad \forall A \in \mathcal{A}. \end{aligned} \quad (1.3)$$

De (1.2) e (1.3) temos que

$$P_\theta(E | T) g_\theta(T) = \lambda_0(E | T) g_\theta(T) \quad \lambda_0 - q.c..$$

Como $g_\theta(T) = \frac{dP_\theta}{d\lambda_0}$, temos que $P_\theta(\{x : g_\theta \circ T(x) = 0\}) = 0$, isto é, $g_\theta(T) \neq 0 \quad P_\theta - q.c..$

Logo, $P_\theta(T) = \lambda_0(E | T) \quad P_\theta - q.c..$

Como P_θ é arbitrário, a igualdade acima vale $\forall P_\theta \in \mathcal{P}$. Portanto, $P_\theta(E | T)$ é constante em relação a θ . Logo, T é suficiente. \diamond

Um teorema análogo foi apresentado por Basu e Ghosh (1967), substituindo a condição de modelo dominado pela de modelo discreto, entendendo como modelo discreto aquele que satisfaz as seguintes condições:

- (a) todo $P_\theta \in \mathcal{P}$ é uma medida de probabilidade discreta;
- (b) \mathcal{A} é o conjunto das partes de \mathcal{X} ;
- (c) o único conjunto P_θ -nulo, $\forall \theta \in \Theta$, é o conjunto vazio.

No Exemplo 1.4 o modelo é dominado e podemos escrever

$$f_\theta(x_1, x_2, \dots, x_n) = \theta^{-n} I_{(-\infty, \theta)}(T) I_{(0, \infty)}(S),$$

onde $S(x_1, x_2, \dots, x_n) = \min(x_1, x_2, \dots, x_n)$.

Identificando $g_\theta = \theta^{-n} I_{(-\infty, \theta)}(T)$ e $h = I_{(0, \infty)}(S)$, concluímos pela suficiência de T .

Proposição 1.2 : Seja $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ um modelo dominado. Sejam T_1 e T_2 duas estatísticas tal que $\sigma(T_1) \subset \sigma(T_2)$ \mathcal{P} -q.c., isto é, T_2 é essencialmente função de T_1 . Se T_1 é suficiente, então T_2 também é suficiente para o modelo.

Utilizando o Teorema da Fatoração, a prova deste resultado é imediata.

Exemplo 1.5: Seja $(\mathbb{R}, \mathcal{B}, \mathcal{P})$ um modelo estatístico onde

$$\mathcal{P} = \{P : P(A) = P(-A), \forall A \in \mathcal{B}\}.$$

Se \mathcal{B}_0 é a σ -álgebra gerada pela estatística $Y(x) = x^2$ então,

$$\mathcal{B}_0 = \{A \in \mathcal{B} : A = -A\},$$

que é a σ -álgebra dos borelianos simétricos.

Se f é uma função \mathcal{B} -mensurável, então $g(x) = \frac{[f(x)+f(-x)]}{2}$ é \mathcal{B}_0 -mensurável, e

$$\int_A f dP = \int_A g dP, \quad \forall A \in \mathcal{B}_0, \quad \forall P \in \mathcal{P}.$$

Logo, \mathcal{B}_0 é suficiente para o modelo.

Seja $S \subset \mathbb{R}, S \notin \mathcal{B}$ e

$$\mathcal{B}_1 = \{A \cup B_0 : A \subset S, A \in \mathcal{B} \text{ e } B_0 \in \mathcal{B}_0\},$$

então \mathcal{B}_1 é uma σ -álgebra tal que, $\mathcal{B}_0 \subset \mathcal{B}_1 \subset \mathcal{B}$.

Vamos supor que \mathcal{B}_1 é suficiente. Então, $\forall f$ \mathcal{B} -mensurável, existe uma g , \mathcal{B}_1 -mensurável, tal que, $\forall B \in \mathcal{B}_1$

$$\int_B f dP = \int_B g dP \quad \forall P \in \mathcal{P}.$$

Seja $x \in S$ e $B = \{x\}$, então

$$\int_{\{x\}} f dP = \int_{\{x\}} g dP \quad \Leftrightarrow$$

$$\Leftrightarrow f(x)P(x) = g(x)P(x) \quad \forall P \in \mathcal{P}$$

Agora, seja $x \in S^c$ e considerando $B = \{-x, x\}$, temos que $B \in \mathcal{B}_0 \Rightarrow B \in \mathcal{B}_1$.

Portanto,

$$\begin{aligned} \int_{\{-x, x\}} f dP &= \int_{\{-x, x\}} g dP \quad \Leftrightarrow \\ \Leftrightarrow [f(x) + f(-x)]P(x) &= 2g(x)P(x). \end{aligned}$$

Como existe $P \in \mathcal{P}$ tal que $P(x) > 0, \forall x$, temos que

$$g(x) = \frac{f(x) + f(-x)}{2} I_{S^c}(x) + f(x) I_S(x).$$

Usando $f(x) = I_{(0, \infty)}(x) - I_{(-\infty, 0)}(x)$, temos que $g(x) = 0$ se $x \in S^c$ e $g(x) \neq 0$ se $x \in S$. Logo, $g^{-1}(0) = S^c$. Mas $S^c \notin \mathcal{B}$ e portanto $S^c \notin \mathcal{B}_1$. Isto contradiz a hipótese de que g é \mathcal{B}_1 -mensurável. Portanto, \mathcal{B}_1 não é suficiente.

Este exemplo mostra que é possível ter uma sigma álgebra que não é suficiente mas contenha uma suficiente. Este fato pode ocorrer quando a condição de dominação não esta satisfeita. A seguir vamos discutir a dominação do modelo.

Suponha que \mathcal{P} seja dominado. Então, existe uma medida μ sigma finita tal que $\mathcal{P} \ll \mu$. Em particular, considere as medidas em \mathcal{P} do tipo $P_j(j) = P_j(-j) = 1/2$ onde $j \in \mathbb{R}^+$. Temos que $\mu(j) > 0, \forall j \in \mathbb{R}$. Isto implica que μ não é sigma finita.

Com efeito, seja I um conjunto enumerável de índices e $(A_i)_{i \in I}$ uma partição de \mathbb{R} com $\mathbb{R} = \bigcup_{i \in I} A_i$, então existe $k \in I$ tal que A_k é não enumerável. Mas,

$$\mu(A_k) = \sum_{j \in A_k} \mu(j) = \infty.$$

Como a partição de \mathbb{R} é arbitrária, concluímos que μ não é σ -finita e consequentemente o modelo não é dominado. \diamond

Proposição 1.3: Sejam T_1 e T_2 duas estatísticas suficientes tal que $\sigma(T_1) \subset \sigma(T_2)$ $\mathcal{P} - q.c.$. Se T_1 é suficiente para $(\mathcal{X}, \sigma(T_2), \mathcal{P})$ e T_2 é suficiente para $(\mathcal{X}, \mathcal{A}, \mathcal{P})$, então T_1 é suficiente para $(\mathcal{X}, \mathcal{A}, \mathcal{P})$.

Prova : Seja f uma função \mathcal{A} -mensurável. Pela suficiência de T_2 existe uma função f^0 , $\sigma(T_2)$ -mensurável, tal que,

$$f^0 = E_\theta[f | T_2] \quad \forall \theta \in \Theta.$$

Da suficiência de T_1 segue que existe uma f^* , $\sigma(T_1)$ - mensurável, tal que

$$f^* = E_\theta[f^0 | T_1] \quad \forall \theta \in \Theta.$$

Mas, como $\sigma(T_1) \subset \sigma(T_2)$,

$$E_\theta[f | T_1] = E_\theta[E_\theta[f | T_2] | T_1].$$

Utilizando as igualdades anteriores temos que,

$$E_\theta[f | T_1] = E_\theta[f^0 | T_1] = f^*.$$

Logo, T_1 é suficiente para $(\mathcal{X}, \mathcal{A}, \mathcal{P})$. ◇

Como já foi dito, o objetivo do estudo da estatística suficiente é a redução das observações sem perda de informação. Assim, poderíamos nos interessar pela redução máxima. Dois conceitos relacionados a este tipo de redução são os de suficiência mínima e minimal. Prova-se que os dois conceitos são equivalentes nos modelos dominados e discreto. Contudo, nem sempre a equivalência é satisfeita. A estatística suficiente mínima sempre existe e não é necessariamente única. Em relação a estatística suficiente minimal, caso ela exista, ela é essencialmente única e também é mínima.

Definição 1.6: Uma estatística suficiente T_0 é suficiente minimal, se para toda outra estatística suficiente T , temos que $\sigma(T_0) \subset \sigma(T)$ $\mathcal{P} - q.c..$

Definição 1.7: Uma estatística suficiente T_0 é suficiente mínima, se não existe outra suficiente T , tal que $\sigma(T) \subset \sigma(T_0)$ $\mathcal{P} - q.c..$

Para o modelo dominado a existência de uma estatística suficiente minimal foi estudada por Lehmann e Scheffé (1950) e Bahadur (1955). Para o modelo discreto , definido anteriormente, foram feitos estudos por Basu e Ghosh (1967) . Posteriormente, Hasegawa e Perlman (1974) introduziram o conceito de modelos coerentes, um modelo estatístico mais geral que inclui os casos dominado e discreto. Entretanto, o modelo coerente não se limita a estes dois casos. Basu e Cheng (1979) apresentam um estudo organizado sobre tais modelos, sua relação com a estatística suficiente e, um exemplo de um modelo coerente que não é discreto nem dominado. Para o caso dos modelos coerentes a existência da estatística suficiente minimal está provada. Contudo, a condição do modelo ser coerente é uma condição suficiente mas não necessária para a existência da suficiente minimal.

Estes conceitos não serão explorados ao longo deste trabalho. Aqui trabalharemos , na maioria dos exemplos, com modelos dominados, onde nada patológico ocorre. Outro conceito de interesse, que pode facilitar o trabalho no caso dominado, é o de suficiência pareada.

Definição 1.8: Uma estatística T é suficiente pareada para $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ se, para todo $A \in \mathcal{A}$ e todo par $\theta_1, \theta_2 \in \Theta$, existe uma função f (livre de θ) , $\sigma(T)$ -mensurável, tal que

$$f(T) = P_{\theta_i}(A | T) \quad i = 1, 2.$$

Ao invés de nos referirmos a uma estatística como sendo suficiente (ou suficiente pareada) poderíamos nos referir , com esses termos, a sua sigma álgebra. Deste modo, poderíamos ter definido sigmas álgebras suficientes (minimas, minimal e pareada). No próximo exemplo trabalharemos com sigmas álgebras, sem nos referirmos a alguma estatística.

Exemplo 1.6 : Seja $(\mathbb{R}, \mathcal{A}, \mathcal{P})$ um modelo estatístico onde \mathcal{A} é a σ -álgebra de conjuntos simétricos que contêm pelo menos um conjunto não enumerável e, \mathcal{P} é a família de probabilidade discreta simétrica, isto é, aquela que concentra a massa de probabilidade em apenas dois pontos $-a$ e a , $a \in \mathbb{R}$.

Seja $\mathcal{C} \subset \mathcal{A}$ a σ -álgebra dos conjuntos simétricos enumeráveis e coenumeráveis (cujo complementar é enumerável). Vamos mostrar que \mathcal{C} é suficiente pareada mas, não é suficiente.

Seja $A \in \mathcal{A}$, $P_a, P_b \in \mathcal{P}$ onde $a \neq b$ com, $P_a(\{-a, a\}) = 1$ e $P_b(\{-b, b\}) = 1$.

Defina $C = A \cap \{-a, -b, a, b\}$. Como A é simétrico, C também é simétrico e $C \in \mathcal{C}$.

Além disso, $A = C$ P_i - q.c. $i = a, b$.

Se $D \in \mathcal{C}$, então

$$\int_D I_A dP_i = \int_D I_C dP_i, \quad i = a, b.$$

Como a e b são valores arbitrários, a igualdade acima é válida para todo $P_a, P_b \in \mathcal{P}$. Logo, \mathcal{C} é suficiente pareada para o modelo.

Vamos mostrar agora que \mathcal{C} não pode ser suficiente. Para isto observe que, $\mathcal{C} \neq \mathcal{A}$ P - q.c.. Mostraremos que nenhuma outra σ -álgebra menor que \mathcal{A} pode ser suficiente para o modelo.

Suponha que exista uma σ -álgebra $\mathcal{D} \subset \mathcal{A}$ que seja suficiente. Como $\mathcal{D} \neq \mathcal{A}$, então $\mathcal{A} - \mathcal{D} \neq \emptyset$. Seja $A \in \mathcal{A} - \mathcal{D}$ e $P_a \in \mathcal{P}$. Pela suficiência de \mathcal{D} , existe h , \mathcal{D} - mensurável, tal que

$$\int_{\mathcal{R}} I_A dP_a = \int_{\mathcal{R}} h dP_a.$$

Mas,

$$\int_{\mathcal{R}} I_A dP_a = \frac{I_A(-a) + I_A(a)}{2} = I_A(a).$$

E por outro lado,

$$\int_{\mathcal{R}} h dP_a = \frac{h(-a) + h(a)}{2} = h(a).$$

Portanto,

$$I_A(a) = h(a) \quad P_a - q.c. \quad \forall a \in \mathcal{R}.$$

Como h é \mathcal{D} - mensurável, então $A \in \mathcal{D}$, o que é uma contradição.

Lema 1.1: Uma condição necessária e suficiente para T ser uma estatística suficiente pareada para $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ é que, para todo par $\theta_1, \theta_2 \in \Theta$, $\frac{dP_{\theta_1}}{d(P_{\theta_1} + P_{\theta_2})}$ seja $\sigma(T)$ - mensurável.

Prova: Fixados $\theta_1, \theta_2 \in \Theta$, vamos considerar a seguinte família de probabilidades em $(\mathcal{X}, \mathcal{A})$,

$$\mathcal{P}^* = \{P_{\theta_1}, P_{\theta_2}\}.$$

É fácil verificar que \mathcal{P}^* é dominada pela medida $\lambda_0 = P_{\theta_1} + P_{\theta_2}$.

Usando os mesmos argumentos da prova do Teorema da Fatoração temos que, $\frac{dP_{\theta_1}}{d\lambda_0}$ é $\sigma(T)$ -mensurável, se e somente se, T é suficiente para \mathcal{P}^* . Como isto é válido para todo par θ_1, θ_2 , o lema está provado. \diamond

Lema 1.2: Se T é suficiente pareada para a família finita $\mathcal{P} = \{P_{\theta_0}, \dots, P_{\theta_n}\}$, então

$$\frac{dP_{\theta_0}}{d\left(\sum_{i=0}^n P_{\theta_i}\right)} \text{ é } \sigma(T)\text{-mensurável.}$$

Prova: Quando $n = 1$ estamos no caso do Lema 1.1.

Parte I - Vamos mostrar que a afirmação é válida para $n = 2$.

Seja $\mathcal{P} = \{P_{\theta_0}, P_{\theta_1}, P_{\theta_2}\}$. Como T é suficiente pareado, pelo lema 1.1,

$$f_1 = \frac{dP_{\theta_0}}{d(P_{\theta_0} + P_{\theta_1})} \quad \text{e} \quad f_2 = \frac{dP_{\theta_0}}{d(P_{\theta_0} + P_{\theta_2})}$$

são funções $\sigma(T)$ -mensuráveis. Temos então que,

$$(f_1 + f_2 - f_1 f_2) dP_{\theta_0} = f_1 f_2 d(P_{\theta_0} + P_{\theta_1} + P_{\theta_2}).$$

Como $0 \leq f_1 \leq 1, 0 \leq f_2 \leq 1$ então $f_1 + f_2 - f_1 f_2 = 0 \Leftrightarrow f_1 = f_2 = 0$. Mas, $P_{\theta_0}(\{x \in \mathcal{X} : f_1(x) = f_2(x) = 0\}) = 0$. Então definimos

$$f = \frac{f_1 f_2}{f_1 + f_2 - f_1 f_2} \quad P_{\theta_0}\text{-q.c.},$$

e concluímos que f é $\sigma(T)$ -mensurável.

Por outro lado,

$$f = \frac{dP_{\theta_0}}{d(P_{\theta_0} + P_{\theta_1} + P_{\theta_2})} P_{\theta_0} - q.c.$$

Parte II - Vamos mostrar, por indução, que a propriedade

$$\frac{dP_{\theta_0}}{d(\sum_{i=0}^n P_{\theta_i})} \text{ é } \sigma(T)\text{-mensurável}$$

é válida, $\forall n \in \mathbb{N}$.

Considerando que

$$\frac{dP_{\theta_0}}{d(\sum_{i=0}^{n+1} P_{\theta_i})} = \frac{dP_{\theta_0}}{d(P_{\theta_0} + \sum_{i=1}^n P_{\theta_i} + P_{\theta_{n+1}})} = \frac{dP_{\theta_0}}{d(P_{\theta_0} + \mu + P_{\theta_{n+1}})}$$

Pela suficiência pareada de T , temos que $\frac{dP_{\theta_0}}{d(P_{\theta_0} + P_{\theta_{n+1}})}$ é $\sigma(T)$ -mensurável e, pela hipótese de indução, $\frac{dP_{\theta_0}}{d(P_{\theta_0} + \mu)}$ é $\sigma(T)$ -mensurável. Portanto, T é suficiente pareada para $\{P_{\theta_0}, \mu, P_{\theta_{n+1}}\}$ e, pela parte I, concluímos a prova. \diamond

Lema 1.3: Seja T suficiente pareada para a família infinita e enumerável $\mathcal{P} = \{P_{\theta_1}, P_{\theta_2}, \dots\}$. Se $\mu(A) = \sum_{i=1}^{\infty} a_i P_{\theta_i}(A)$, $\forall A \in \mathcal{A}$, onde $\sum_{i=1}^{\infty} a_i = 1$, então,

$$(i) \lim_{n \rightarrow \infty} \frac{dP_{\theta_0}}{d(\sum_{i=0}^n a_i P_{\theta_i})} = \frac{dP_{\theta_0}}{d\mu} \mu - q.c.$$

$$(ii) \frac{dP_{\theta_0}}{d\mu} \text{ é } \sigma(T)\text{-mensurável.}$$

Prova: Temos que, $\forall n$,

$$\frac{dP_{\theta_0}}{d\mu} = \frac{dP_{\theta_0}}{d(\sum_{i=0}^n a_i P_{\theta_i})} \frac{d(\sum_{i=0}^n a_i P_{\theta_i})}{d\mu}$$

Fazendo $n \rightarrow \infty$, temos que $\frac{d(\sum_{i=0}^n a_i P_{\theta_i})}{d\mu} \rightarrow 1$. Portanto vale (i).

Para a validade de (ii) basta observar que $\frac{dP_{\theta_0}}{d(\sum_{i=0}^n a_i P_{\theta_i})}$ é $\sigma(T)$ -mensurável, então

$\forall n$, $\frac{dP_{\theta_0}}{d\mu}$ é $\sigma(T)$ -mensurável. \diamond

Proposição 1.4: Seja $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ um modelo dominado então, a estatística T é suficiente se, e somente se, ela é suficiente pareada.

Prova:

(\Rightarrow) Imediata

(\Leftarrow) Suponha que T é suficiente pareada. Como o modelo é dominado existe um conjunto $\mathcal{P}_0 = \{P_1, P_2, \dots\}$ enumerável contido em \mathcal{P} , tal que $\mathcal{P}_0 \equiv \mathcal{P}$ (apêndice C).

Seja P_θ uma medida qualquer em \mathcal{P} . Defina a medida μ , onde $\sum_{i=1}^{\infty} a_i = 1$, como

$$\mu(E) = \sum_{i=1}^{\infty} a_i P_i(E), \quad \forall E \in \mathcal{A}.$$

Pela suficiência pareada de T e pelo Lema 1.3, $\frac{dP_0}{d(P_0 + \mu)}$ é $\sigma(T)$ -mensurável. Além disso,

$$\begin{aligned} \frac{dP_0}{d\mu} &= \frac{dP_0}{d(P_0 + \mu)} \frac{d(P_0 + \mu)}{d\mu} = \\ &= \frac{dP_0}{d(P_0 + \mu)} \left[\frac{d\mu}{d(P_0 + \mu)} \right]^{-1} = \frac{dP_0}{d(P_0 + \mu)} \left[1 - \frac{dP_0}{d(P_0 + \mu)} \right]^{-1}. \end{aligned}$$

Logo, $\frac{dP_0}{d\mu}$ é $\sigma(T)$ -mensurável.

Utilizando o teorema da Fatoração, concluímos que T é suficiente. \diamond

Este último resultado simplifica bastante o trabalho no caso do modelo dominado. Neste caso, basta mostrar a suficiência pareada para garantir a suficiência.

Estatística Ancilar

Na seção anterior discutimos um conceito relacionado com informação contida na amostra a respeito do parâmetro. Nesta seção apresentamos um conceito que, a princípio, foi considerado relacionado a “ não-informação ” .

Definição 1.9: Um evento $A \in \mathcal{A}$ é ancilar em relação ao modelo estatístico se, $P_\theta(A) = P(A)$, $\forall \theta \in \Theta$, onde P é uma função \mathcal{A} -mensurável. Uma estatística Y é ancilar, para o modelo estatístico, se todo $A \in \sigma(Y)$ é ancilar.

Observe que se a família \mathcal{P} é dominada, então a estatística é ancilar se, e somente se, sua função densidade é livre de θ . Este fato é facilmente verificado utilizando-se o Teorema de Radon-Nikodym .

Exemplo 1.7 : Seja $(\mathbb{R}^2, \mathcal{B}_2, \mathcal{P})$ um modelo estatístico onde $\mathcal{P} = \{P_\theta : \theta \in \mathbb{R}^+\}$ é dominado pela medida de Lebesgue e sua densidade é

$$f_\theta(x, y) = e^{-\theta x - y/\theta} \quad x, y > 0.$$

Seja Z a estatística $Z(x, y) = x.y$. Considere $A_z \in \sigma(Z)$ tal que

$$A_z = \{(x, y) \in \mathbb{R}^2 : xy \leq z\} = \{(x, y) \in \mathbb{R}^2 : y \leq z/x\}.$$

Temos que,

$$P_\theta(A_z) = \int_{A_z} f_\theta dP_\theta = \int_0^\infty \int_0^{z/x} f_\theta(x, y) dy dx.$$

Fazendo substituição de variáveis, obtemos

$$P_\theta(A_z) = \int_0^z \int_0^\infty \frac{1}{x} f_\theta(x, v/x) dx dv.$$

A integral interna é a função densidade de Z a qual denotaremos por g_Z . Então,

$$g_Z(v) = \int_0^\infty \frac{1}{x} e^{-\theta x - v/\theta x} dx = \int_0^\infty \frac{1}{w} e^{-w - v/w} dw.$$

Portanto, Z é ancilar.

O estimador de máxima verossimilhança para θ é a estatística $T(x, y) = (y/x)^{1/2}$. Utilizando-se o Teorema da Fatoração verifica-se que T não é suficiente para o modelo, mas (T, Z) é suficiente.

Embora nosso objetivo não seja aprofundar questões sobre o conceito de informação, abriremos aqui um parêntese para entender melhor o exemplo em termos estatísticos.

Informação, segundo Fisher, é a função

$$I(\theta) = E_{\theta}\left[\frac{-\delta^2}{\delta\theta^2} \log f_{\theta}(X)\right]$$

onde $f_{\theta}(X)$ é a função de verossimilhança.

A informação de Fisher para uma estatística T é definida pela expressão

$$J(\theta) = E_{\theta}\left[\frac{-\delta^2}{\delta\theta^2} \log h_{\theta}(T)\right]$$

onde $h_{\theta}(T)$ é a função densidade de T .

Uma estatística tem a mesma informação de Fisher da amostra [$I(\theta) = J(\theta)$] se, e somente se, ela é suficiente (Basu, 1975). Isto caracteriza, em termos de Informação de Fisher, a suficiência. Por outro lado, se Y é uma estatística ancilar sua informação de Fisher é zero.

Em termos de σ -álgebra temos, no Exemplo 1.7, que $\sigma(T)$ não é suficiente e portanto, sua informação $J(\theta)$ é menor que $I(\theta)$ (a informação máxima de Fisher). Entretanto, quando acrescentamos elementos ancilares (com informação de Fisher zero), resulta que $\sigma(T) \vee \sigma(Z)$ tem informação de Fisher igual a $I(\theta)$. Este fato nos faz questionar a idéia de que uma sigma álgebra ancilar não contém informação relevante para o parâmetro. Portanto, nem sempre podemos dispensar as estatísticas ancilares quando estamos

interessados em estimar determinado parâmetro. Muitas vezes as estatísticas ancilares são de grande utilidade.

A seguir apresentamos alguns conceitos relacionados com ancilaridade.

Definição 1.10: A estatística ancilar Y é ancilar maximal, se não existe outra estatística ancilar Y^* , tal que $\sigma(Y) \subset \sigma(Y^*)$.

Definição 1.11: Uma estatística S é informativa, se existe pelo menos um conjunto $A \in \sigma(S)$, tal que A não é ancilar.

Definição 1.12: Dois conjuntos ancilares A e B se adaptam, se $A \cap B$ também é ancilar e escrevemos $A \sim B$. Caso contrário, escrevemos $A \not\sim B$. Note que $A \sim B \Rightarrow A \sim B^c$ pois,

$$P_\theta(A \cap B) + P_\theta(A \cap B^c) = P_\theta(A).$$

Exemplo 1.8: Seja $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ onde $\mathcal{X} = \{0, 1\}^2$, $\mathcal{A} = \mathcal{P}(\mathcal{X})$ e $\mathcal{P} = \{P_\theta : \theta \in [0, 1]\}$, tal que $P_\theta(x, y)$ é descrita na tabela abaixo.

TABELA 1

		Y		
X	0	1	Total	
0	$\theta/2$	$(1 - \theta)/2$	$1/2$	
1	$(1 - \theta)/2$	$\theta/2$	$1/2$	
Total	$1/2$	$1/2$	1	

Se $A = \{(0,0); (0,1)\}$ e $B = \{(0,1); (1,1)\}$, então $P_\theta(A) = P_\theta(B) = 1/2$, $\forall \theta \in [0, 1]$. Portanto, A e B são ancilares. Entretanto, $P_\theta(A \cap B) = \theta/2$, $\forall \theta \in [0, 1]$. Logo, A e B não se adaptam.

Proposição 1.5: Se A é um evento ancilar que não pertence a $\sigma(Y)$, onde Y é uma ancilar maximal, então existe pelo menos um elemento $B \in \sigma(Y)$ tal que $A \not\sim B$.

Prova : Seja \mathcal{M} uma σ -álgebra ancilar maximal e A um conjunto ancilar tal que $A \notin \mathcal{M}$. Vamos supor que $A \sim M$ para todo $M \in \mathcal{M}$. Considere

$$\mathcal{M}^* = \{(A \cap X) \cup (A^c \cap Y) : X, Y \in \mathcal{M}\}.$$

Observe que $\mathcal{M} \subset \mathcal{M}^*$ e $\mathcal{M} \neq \mathcal{M}^*$. Além disso,

$$P_\theta[(A \cap X) \cup (A^c \cap Y)] = P_\theta(A \cap X) + P_\theta(A^c \cap Y).$$

Por hipótese os dois termos à direita da equação são livres de θ , e portanto como isto é válido para todo elemento de \mathcal{M}^* , concluímos que \mathcal{M}^* é uma σ -álgebra ancilar. Mas $\mathcal{M} \subset \mathcal{M}^*$, o que contradiz a maximalidade de \mathcal{M} . \diamond

Corolário 1.1: Seja Y uma estatística ancilar maximal e S uma estatística ancilar tal que $\sigma(S) \not\subset \sigma(Y)$, então $\sigma(S) \vee \sigma(Y)$ é informativa. Isto é, (Y, S) é informativa.

Exemplo 1.9: Seja $(\mathbb{R}^2, \mathcal{B}_2, \mathcal{P})$ um espaço estatístico onde \mathcal{P} é a família da Normal bivariada com vetor de médias $\begin{pmatrix} 0 \\ 0 \end{pmatrix}$ e matriz de covariância $\begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}$. Sejam X, Y duas estatísticas, tais que $X(x, y) = x$ e $Y(x, y) = y$. Cada uma delas tem medida de probabilidade $N(0, 1)$ e portanto são ancilares. No entanto, (X, Y) é suficiente para o modelo e portanto informativa.

Família Completa

O conceito de família completa, bem como os conceitos de família conectada e conjunto separador que serão abordados a seguir, são conceitos auxiliares para estabelecermos os Teoremas de Basu. A condição de que a família seja completa é a condição exigida para que o espaço estatístico possa ser particionado, de forma independente, numa parte informativa (suficiente) e outra não informativa (ancilar).

Optamos por falar em família Completa e não estatística Completa, pelo fato deste conceito ser uma propriedade da família de medidas de Probabilidade.

Definição 1.13: Uma família de medidas de probabilidade \mathcal{P} é (limitadamente) completa se, para toda função real g (essencialmente limitada),

$$\int_{\mathcal{X}} g dP_{\theta} = 0, \quad \forall \theta \in \Theta, \quad \Rightarrow \quad g = 0 \quad \mathcal{P} - q.c.$$

Uma estatística T é (limitadamente) completa se a correspondente família de medidas induzidas por T é (limitadamente) completa.

O fato da família ser completa implica que ela é limitadamente completa. Podemos entretanto, ter uma família limitadamente completa que não é completa. Vejamos o próximo exemplo.

Exemplo 1.10: Seja $(\mathbb{R}, \mathcal{B}, \mathcal{P})$ um espaço estatístico onde $\mathcal{P} = \{P_\theta : \theta \in (0, 1)\}$ e cada P_θ tem a seguinte função densidade,

$$f_\theta(x) = (1 - \theta)^2 \theta^x I_{\mathbb{N}}(x) + \theta I_{\{-1\}}(x).$$

Seja g uma função Borel mensurável tal que $\int_{\mathbb{R}} g P_\theta = 0, \quad \forall \theta \in (0, 1)$. Então,

$$\begin{aligned} g(-1)\theta + \sum_{j=0}^{\infty} g(j)(1 - \theta)^2 \theta^j &= 0 \Rightarrow \\ \Rightarrow (1 - \theta)^2 \sum_{j=0}^{\infty} g(j)\theta^j &= -\theta g(-1) \Rightarrow \\ \Rightarrow \sum_{j=0}^{\infty} g(j)\theta^j &= -g(-1)\theta(1 - \theta)^{-2}. \end{aligned}$$

Como $0 < \theta < 1$, temos que $\theta(1 - \theta)^{-2} = \sum_{j=0}^{\infty} j\theta^j$. Portanto,

$$\sum_{j=0}^{\infty} g(j)\theta^j = \sum_{j=0}^{\infty} -g(-1)j\theta^j.$$

Então,

$$g(j) = -jg(-1) \quad j = 0, 1, 2, \dots \quad (1.4)$$

Caso I: Suponha g limitada, então $g(j) = g(-1) = 0$ para $j = 0, 1, 2, \dots$

Caso II: Suponha que a condição de g ser limitada não é imposta. Considere g_0 , tal que

$$g_0(-1) = 1, \quad g_0(0) = 0 \quad e \quad g_0(j) = -j \quad j = 1, 2, 3, \dots$$

Então, g_0 satisfaz (1.4). Logo, \mathcal{P} é limitadamente completa, mas não é completa.

Exemplo 1.11 : Seja $(\mathbb{N}, \mathcal{P}(\mathbb{N}), \mathcal{P})$ um espaço estatístico onde $\mathcal{P} = \{P_\theta : \theta \in \{\frac{1}{4}, \frac{1}{2}\}\}$ e P_θ é Binomial $(2, \theta)$.

Vamos mostrar que a família \mathcal{P} não é limitadamente completa.

Seja g uma função essencialmente limitada e \mathcal{A} -mensurável, tal que $\int_{\mathcal{X}} g dP_{\theta} = 0$ $\forall \theta \in \{\frac{1}{4}, \frac{1}{2}\}$. Então ,

$$g(0)(1 - \theta)^2 + 2g(1)\theta(1 - \theta) + g(2)\theta^2 = 0 \Rightarrow$$

$$\Rightarrow g(0)(1 - 2\theta + \theta^2) + 2g(1)(\theta - \theta^2) + g(2)\theta^2 = 0 \Rightarrow$$

$$\Rightarrow [g(0) - 2g(1) + g(2)]\theta^2 + [g(1) - g(0)]2\theta + g(0) = 0.$$

Considerando $g(0) = 1$, $g(1) = -2$ e $g(2) = 3$ de modo que as raízes da equação acima sejam $\frac{1}{4}$ e $\frac{1}{2}$, temos

$$8\theta^2 - 6\theta + 1 = 0, \quad \forall \theta \in \{\frac{1}{4}, \frac{1}{2}\} \quad (1.5)$$

Logo, a família não é limitadamente completa e portanto não é completa.

Entretanto, se completarmos o espaço paramétrico de modo que $\Theta = \{\frac{1}{2}, \frac{1}{4}, \frac{3}{4}\}$, não podemos mais garantir que vale (1.5), $\forall \theta \in \Theta$. Neste caso, não existirá uma $g \neq 0$ tal que a equação de segundo grau se anule, $\forall \theta$, pois ela possui apenas duas raízes. Então, $\mathcal{P}^* = \{P_{\theta} : \theta \in \{\frac{1}{2}, \frac{1}{4}, \frac{3}{4}\}\}$ é limitadamente completa (também completa pois, a condição de g ser limitada não é relevante no caso) e é claro que incluindo mais elementos no espaço paramétrico ela continua sendo completa.

Proposição 1.6: (Lehmann e Scheffé, 1950) Se T é uma estatística suficiente e limitadamente completa, então T é suficiente minimal.

Prova: Seja S uma estatística suficiente. Vamos mostrar que $\sigma(T) \subset \sigma(S)$ $\mathcal{P} - q.c..$

Seja $A \in \sigma(T)$. Considere g uma versão da probabilidade condicional de A dado S , livre de θ , e $h = E_{\theta}[g/T]$, também livre de θ . Temos que

$$\int_{\mathcal{X}} I_A dP_{\theta} = \int_{\mathcal{X}} g dP_{\theta} = \int_{\mathcal{X}} h dP_{\theta} \quad \forall \theta \in \Theta,$$

então

$$\int_{\mathcal{X}} (I_A - h) dP_\theta = 0 \quad \forall \theta \in \Theta.$$

Como $(I_A - h)$ é $\sigma(T)$ -mensurável e limitada, pois $I_A \leq 1$ e $h = P_\theta(A/T) \leq 1$. Utilizando o fato de T ser limitadamente completa, concluímos que

$$I_A = h \quad \mathcal{P} - q.c..$$

Mas,

$$h = E_\theta[g/T] \leq g = E_\theta[I_A/S] \leq I_A.$$

Portanto, $I_A = g$ $\mathcal{P} - q.c.$ Então, $A \in \sigma(S)$ ◇

Proposição 1.7: Seja T uma estatística suficiente e completa, então para qualquer estatística S ancilar, tal que $\sigma(T) \vee \sigma(S)$ é essencialmente igual a σ -álgebra de Borel, S é essencialmente ancilar maximal.

Vamos omitir a prova deste resultado pois com o Teorema de Basu 1, que será enunciado e demonstrado posteriormente, ela torna-se simples.

Família Conectada e Conjuntos Separadores

Definição 1.14: Duas medidas de probabilidade P_1 e P_2 em $(\mathcal{X}, \mathcal{A})$ são sobrepostas se, para cada $A \in \mathcal{A}$, tal que $P_1(A) = 1$, temos que $P_2(A) > 0$. Observe que a propriedade é simétrica.

Outro modo de definir medidas sobrepostas é dizer que seus suportes não são disjuntos.

Definição 1.15: Uma família de medidas de probabilidade é conectada, se para todo par P_θ e P_α em \mathcal{P} , existem medidas de probabilidade $P_{\theta_1}, P_{\theta_2}, \dots, P_{\theta_n}$ em \mathcal{P} , onde $\theta_1 = \theta$ e $\theta_n = \alpha$ e $n \in \mathbb{N}$, tais que P_{θ_i} e $P_{\theta_{i+1}}$ são sobrepostas para $i = 1, 2, 3, \dots, n - 1$.

Exemplo 1.12: Seja $(\mathbb{R}, \mathcal{B}, \mathcal{P})$ um espaço estatístico onde $\mathcal{P} = \{P_\theta : \theta \in \mathbb{Z}\}$ e P_θ é uniforme em $[\theta, \theta + 1)$. Considerando $A = [0, 1]$ e $\theta = 0$, temos que $P_0(A) = 1$ e para todo outro $\theta \in \mathbb{Z}$ $P_\theta(A) = 0$. Logo, não existe $\theta \in \mathbb{Z} - \{0\}$ tal que $P_\theta(A) > 0$. Portanto, P_0 não se sobrepõe a nenhuma outra medida em \mathcal{P} , então a família não é conectada.

Exemplo 1.13: Utilizando o mesmo modelo do exemplo anterior e alterando o espaço paramétrico para $\Theta = \{k/2 : k \in \mathbb{Z}\}$, temos que a família é conectada. Pois, se $\theta \in \Theta$ e $A = [\theta, \theta + 1)$, então $P_\theta(A) = 1$ e $P_{\theta+1/2}(A) > 0$, $\forall \theta \in \Theta$.

Definição 1.16: $A \in \mathcal{A}$ é um conjunto separador se, $\forall \theta \in \Theta$, $P_\theta(A) = 0$ ou $P_\theta(A) = 1$ e para pelo menos um par $\theta_1, \theta_2 \in \Theta$, temos $P_{\theta_1}(A) = P_{\theta_2}(A^c) = 1$.

Em alguns casos a condição de \mathcal{P} ser conectada é equivalente a condição da não existência de um conjunto separador. A equivalência entre as duas condições foi apresentada por Pathak (1975) nos casos do modelo dominado e do modelo discreto. Posteriormente, Basu e Cheng (1979) generalizaram este resultado para os modelos coerentes. A seguir apresentaremos os dois lemas introduzidos por Pathak.

Lema 1.4: Seja $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ um modelo discreto. A família $\mathcal{P} = \{P_\theta : \theta \in \Theta\}$ é conectada se, e somente se, não existe um conjunto separador.

Prova: Vamos mostrar que existe um A separador se, e somente se, \mathcal{P} não é conectado.

(\Rightarrow) Seja A um conjunto separador. Defina

$$\mathcal{P}_1 = \{P_\theta \in \mathcal{P} : P_\theta(A) = 1\} \quad \text{e}$$

$$\mathcal{P}_2 = \{P_\theta \in \mathcal{P} : P_\theta(A) = 0\}.$$

Como A é separador \mathcal{P}_1 e \mathcal{P}_2 são conjuntos não vazios. Além disso, todos elementos de \mathcal{P}_1 são sobrepostos e o mesmo é válido para \mathcal{P}_2 . Entretanto, para nenhum par $(P_{\theta_1}, P_{\theta_2})$, tal que $P_{\theta_1} \in \mathcal{P}_1$ e $P_{\theta_2} \in \mathcal{P}_2$, as medidas são sobrepostas.

Logo, o modelo não é conectado.

(\Leftarrow) Suponha que \mathcal{P} não é conectado.

Para cada θ_1, θ_2 defina a seguinte relação de equivalência ,

$$P_{\theta_1} \sim P_{\theta_2} \Leftrightarrow P_{\theta_1}, P_{\theta_2} \text{ são conectadas.}$$

Fixado $P_1 \in \mathcal{P}_1$. Considere $\mathcal{P}_1 = \{P_\theta \in \mathcal{P} : P_\theta \sim P_1\}$. Como \mathcal{P} não é conectado, $\mathcal{P}_2 = \mathcal{P} - \mathcal{P}_1 \neq \emptyset$. Além disso, sejam

$$\Gamma_1 = \{\theta : P_\theta \in \mathcal{P}_1\} \quad \text{e} \quad \Gamma_2 = \{\theta : P_\theta \in \mathcal{P}_2\}.$$

Se \mathcal{X}_θ é o suporte da medida de probabilidade P_θ , isto é, $P_\theta(\mathcal{X}_\theta) = 1$ e $\forall B \subset \mathcal{X}_\theta, P_\theta(B) > 0$, temos que

$$\mathcal{X}_{\theta_1} \cap \mathcal{X}_{\theta_2} = \emptyset, \quad \forall \theta_1 \in \Gamma_1, \quad \forall \theta_2 \in \Gamma_2.$$

Defina

$$A = \bigcup_{\theta_1 \in \Gamma_1} \mathcal{X}_{\theta_1}.$$

Como o modelo é discreto a σ -álgebra associada é o conjunto das partes de \mathcal{X} . Logo, A é mensurável . Além disso,

$$P_{\theta_1}(A) = 1 \quad \forall \theta_1 \in \mathcal{P}_1 \quad \text{e}$$

$$P_{\theta_2}(A) = 0 \quad \forall \theta_2 \in \mathcal{P}_2.$$

Portanto, A é um conjunto separador. ◇

Lema 1.5: Seja $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ um modelo dominado. A família \mathcal{P} é conectada se, e somente se, não existe um conjunto separador.

Prova: (\Rightarrow) A mesma prova do Lema 1.4 .

(\Leftarrow) Suponha \mathcal{P} conectada e considere $\mathcal{P}_1, \mathcal{P}_2$ definidos anteriormente no Lema 1.4 . Como \mathcal{P}_1 é dominado, segue que, existe uma família enumerável $\mathcal{P}_0 \subset \mathcal{P}_1$, tal que $\mathcal{P}_1 \equiv \mathcal{P}_0$ (apêndice C) .

Sejam

$$\Gamma_0 = \{\theta : P_\theta \in \mathcal{P}_0\}, \quad \Gamma_1 = \{\theta : P_\theta \in \mathcal{P}_1\} \quad \text{e} \quad \Gamma_2 = \{\theta : P_\theta \in \mathcal{P}_2\}.$$

Defina

$$A = \bigcup_{\theta \in \Gamma_0} \mathcal{X}_\theta.$$

Como Γ_0 é enumerável, A é mensurável. Então,

$$P_\theta(A^c) = 0, \quad \forall \theta \in \Gamma_0 \Rightarrow P_\theta(A^c) = 0, \quad \forall \theta \in \Gamma_1 \Rightarrow P_\theta(A) = 1, \quad \forall \theta \in \Gamma_1.$$

Como nenhuma medida em \mathcal{P}_2 é conectada com alguma medida em \mathcal{P}_1 , temos que $A \cap \mathcal{X}_\theta = \emptyset$, $\forall \theta \in \Gamma_2$. Portanto,

$$P_\theta(A) = 0 \quad \forall \theta \in \Gamma_2.$$

Logo, A é um conjunto separador. ◇

Exemplo 1.14: Seja $\mathcal{P} = \{P : P(x) = P(y) = 1/2, 0 \leq x < y\}$ uma família de medidas de probabilidade em $(\mathbb{R}, \mathcal{B})$ e Q a medida Normal Padrão. A família $\mathcal{P} \cup Q$ não é conectada, pois Q e P não são sobrepostas, $\forall P \in \mathcal{P}$.

Os candidatos a conjunto separador são:

i) \mathbb{R} , pois $Q(\mathbb{R}) = 1$. Contudo, $P(\mathbb{R}) = 1$, $\forall P \in \mathcal{P}$. Logo, \mathbb{R} não é um conjunto separador.

ii) \mathbb{R}^+ , pois $P(\mathbb{R}^+) = 1$, $\forall P \in \mathcal{P}$. Contudo, $Q(\mathbb{R}^+) = 1/2$. Logo, \mathbb{R}^+ também não é separador.

Portanto, o modelo não é conectado e não possui um conjunto separador.

1.3.OS TEOREMAS DE BASU SOB A PERSPECTIVA CLÁSSICA

Teorema de Basu 1 (Basu, 1955)

Seja T uma estatística limitadamente completa e suficiente para o modelo $(\mathcal{X}, \mathcal{A}, \mathcal{P})$. Se S é uma estatística ancilar, então S e T são estatisticamente independentes.

Prova : Considere $A \in \sigma(S)$. Como T é suficiente existe uma versão da probabilidade condicional de A dado T (livre de θ), $f(T)$, tal que

$$P_\theta(A) = \int_{\mathcal{X}} f(T) dP_\theta \quad \forall \theta \in \Theta.$$

Pela ancilaridade de S , temos que $P_\theta(A) = k$ (constante em relação a θ). Portanto,

$$\int_{\mathcal{X}} (f(T) - k) dP_\theta = 0 \quad \forall \theta \in \Theta,$$

onde $(f(T) - k)$ é $\sigma(T)$ - mensurável. Usando o fato de T ser limitadamente completa, temos que

$$f(T) = P_\theta(A) \quad \mathcal{P} - q.c..$$

Logo, A é estatisticamente independente de T e portanto, S e T são estatisticamente independentes . ◇

Exemplo 1.15: Seja $(\mathbb{R}^n, \mathcal{B}_n, \mathcal{P})$ um espaço estatístico onde $\mathcal{P} = \{P_\theta : \theta \in \mathbb{R}\}$ é a família de medidas de probabilidade Normal n -variada gerada por n observações independentes Normais com média θ e variância 1 .

Considere as estatísticas conhecidas como média e variância amostrais, respectivamente,

$$\begin{aligned} \bar{X}(x_1, \dots, x_n) &= \frac{\sum x_i}{n}, \\ S^2(x_1, \dots, x_n) &= \frac{\sum (x_i - \bar{x})^2}{n-1}. \end{aligned}$$

Vamos mostrar que \bar{X} é suficiente e completa para este modelo estatístico.

O modelo é dominado pela medida de Lebesgue e sua função densidade é dada por,

$$\begin{aligned} f_{\theta}(x_1, \dots, x_n) &= (2\pi)^{-n/2} e^{-\frac{\sum (x_i - \theta)^2}{2}} = \\ &= (2\pi)^{-n/2} e^{-\frac{1}{2} \left[\sum x_i^2 - 2\theta n \bar{X} - n\theta^2 \right]} = \\ &= (2\pi)^{-n/2} e^{-\frac{\sum x_i^2}{2}} e^{\frac{\theta n \bar{X} - n\theta^2}{2}} = h \cdot g(\theta, \bar{X}). \end{aligned}$$

Portanto, pelo Teorema da Fatoração, \bar{X} é suficiente.

Seja $\mathcal{P}^{\bar{X}}$ a família de medidas induzida por \bar{X} . Se $Q_{\theta} \in \mathcal{P}^{\bar{X}}$, então Q_{θ} tem distribuição $N(\theta, \frac{1}{n})$. O modelo estatístico induzido por \bar{X} é $(\mathbb{R}, \mathcal{B}, \mathcal{P}^{\bar{X}})$.

Seja f uma função Borel mensurável, tal que

$$\int_{\mathbb{R}} f dQ_{\theta} = 0 \Rightarrow \int_{-\infty}^{\infty} f(y) [2\pi n]^{-2} e^{-\frac{(y-\theta)^2}{2n}} dy = 0.$$

Fazendo transformação de variáveis e usando a unicidade da Transformada de Laplace, temos que $f = 0$ (essencialmente), $\forall Q_{\theta} \in \mathcal{P}^{\bar{X}}$. Portanto, \bar{X} é completa.

Vamos mostrar agora que S^2 é uma estatística ancilar. Temos que,

$$(n-1)S^2 = \sum_{i=1}^n (x_i - \bar{X})^2 = \sum_{i=1}^n (x_i - \theta)^2 - n(\bar{X} - \theta)^2.$$

Mas, $(x_i - \theta), \forall i$, e $(\bar{X} - \theta)$ tem distribuição $N(0, 1)$. Então, $\frac{\sum_{i=1}^n (x_i - \theta)^2}{n}$ tem distribuição Qui-quadrado com n graus de liberdade, e $(\bar{X} - \theta)^2$ tem distribuição Qui-quadrado com 1 grau de liberdade. Portanto, $\frac{(n-1)}{n} S^2$ tem distribuição Qui-quadrado com $(n-1)g.l.$, então S^2 tem distribuição livre de θ .

Utilizando o Teorema de Basu 1, concluímos que \bar{X} e S^2 são estatisticamente independentes.

Exemplo 1.16 Seja $(\mathbb{R}^n, \mathcal{B}_n, \mathcal{P})$ um espaço estatístico onde

$$\mathcal{P} = \{P_\theta : \theta = (\mu, \sigma), t.q., \mu \in \mathbb{R} \text{ e } \sigma \in \mathbb{R}^+\}$$

é a família da probabilidade Normal n-variada, com covariância zero.

Utilizando-se o Teorema de Basu 1 é possível mostrar, também neste caso, que \bar{X} e S são estatisticamente independentes. Entretanto, Basu acreditou que utilizando-se a mesma técnica seria possível mostrar a independência estatística entre $\frac{\bar{X}}{S}$ e S .

Observe que fixado $\mu = \mu_0$, o parâmetro de interesse σ é um parâmetro escala. É fácil verificar que $\frac{\bar{X}}{S}$ é invariante escala e, portanto é ancilar para σ (apêndice D). Por outro lado, sabe-se que (\bar{X}, S) é uma estatística suficiente e completa. Logo, pelo Teorema de Basu 1, $\frac{\bar{X}}{S}$ e (\bar{X}, S) são estatisticamente independentes. Deste fato resulta a independência entre $\frac{\bar{X}}{S}$ e S .

Analisando melhor a solução anterior, veja que a afirmação de que $\frac{\bar{X}}{S}$ e (\bar{X}, S) são estatisticamente independentes é absurda, pois $\frac{\bar{X}}{S}$ fica completamente determinada com o conhecimento de (\bar{X}, S) . Então, qual o problema? Será algum erro do Teorema? Não, o que ocorre é que ao analisarmos a ancilaridade de $\frac{\bar{X}}{S}$ havíamos fixado $\mu = \mu_0$ e neste caso, a estatística (\bar{X}, S) não é completa para o parâmetro de interesse σ . Pois, considerando a estatística

$$h(x) = \frac{\bar{X} - \mu_0}{S},$$

temos que

$$E[h(x)] = 0.$$

Este exemplo é interessante para salientar a importância da condição de que a família da estatística suficiente seja completa. Outra maneira de verificar que (\bar{X}, S) não é completa, no caso de μ_0 conhecido, é observar que a estatística $\sum_{i=1}^n (x_i - \mu_0)^2$ é suficiente e menor que (\bar{X}, S) . Portanto, esta última não é suficiente mínima e não poderia ser completa, pois seria uma contradição a Proposição 1.6.

Antes de enunciarmos o próximo teorema lembramos que Basu, num primeiro momento, acreditou que através da independência de uma estatística suficiente seria possível garantir a ancilaridade. Ele inclusive apresentou, incorretamente, uma prova desta afirmação (Basu, 1955). O contra-exemplo a seguir (Basu, 1958) nega a idéia de que a independência de uma estatística suficiente garante a ancilaridade.

Exemplo 1.17: Uma urna contém 10 bolas idênticas numeradas de $\theta+1, \theta+2, \dots, \theta+10$. Retira-se duas bolas aleatoriamente da urna, uma após a outra, com reposição. Seja $\Theta = \{0, 10, 20, 30, \dots\}$ o espaço paramétrico e T_i o número da i -ésima bola retirada, $i = 1, 2$. Observe que T_1 e T_2 são idênticamente distribuídas e estatisticamente independentes e cada uma é suficiente para θ . Isso contradiz a idéia de que uma estatística independente de uma suficiente é ancilar. Para que tal afirmação seja verdadeira, deve-se impor uma restrição à família de medidas de probabilidade.

Teorema de Basu 2 (Basu, 1958)

Seja \mathcal{P} uma família de medidas de probabilidade conectada. Sejam T e S estatísticas, tais que T é suficiente para $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ e estatisticamente independente de S então, S é ancilar .

Prova: Considere $A \in \sigma(S)$. Pela suficiência de T existe uma versão da probabilidade condicional de A dado T (livre de θ), $f(T)$, tal que

$$P_\theta(A \cap B) = \int_B f(T) dP_\theta, \quad \forall \theta \in \Theta \quad \forall B \in \sigma(T).$$

Por outro lado, pela independência de S e T temos que

$$P_\theta(A \cap B) = P_\theta(A)P_\theta(B) = \int_B P_\theta(A) dP_\theta, \quad \forall \theta \in \Theta.$$

Das duas igualdades anteriores, concluímos que

$$P_\theta(A) = f(T), \quad \mathcal{P} - q.c. \tag{1.6}$$

Considere $P_{\theta_1}, P_{\theta_2} \in \mathcal{P}$ medidas sobrepostas. Então, existe $x_0 \in \mathcal{X}_{\theta_1} \cap \mathcal{X}_{\theta_2}$, onde \mathcal{X}_{θ_i} é o suporte de P_{θ_i} , $i = 1, 2$. Logo, para pelo menos um ponto x_0 a igualdade (1.6) é válida para P_{θ_1} e P_{θ_2} . Portanto,

$$P_{\theta_1}(A) = P_{\theta_2}(A).$$

Considere agora que as medidas são apenas conectadas. Então, existem $P_{\theta_1}, P_{\theta_2}, \dots, P_{\theta_n}$ em \mathcal{P} , tais que $P_{\theta_i}, P_{\theta_{i+1}}$ são sobrepostas, para $i = 1, 2, \dots, n - 1$. Neste caso, $P_{\theta_i}(A) = P_{\theta_{i+1}}(A)$, $i = 1, 2, \dots, n - 1$, então $P_{\theta_1}(A) = P_{\theta_n}(A)$, para todo par θ_1 e $\theta_n \in \Theta$. Logo, A é ancilar e portanto, S é ancilar. \diamond

A condição da família ser conectada é uma condição suficiente para garantir a ancilaridade de S . Thomas e Koehn (1975) estabeleceram uma condição necessária e suficiente para a ancilaridade de S .

Teorema de Basu 2.A (Thomas e Koehn, 1975)

Seja T uma estatística suficiente para $(\mathcal{X}, \mathcal{A}, \mathcal{P})$. Toda S , estatisticamente independente de T , é ancilar se, e somente se, não existe um conjunto $A \in \mathcal{A}$, tal que A é um conjunto separador.

Prova : Vamos mostrar que existe uma S não ancilar se, e somente se, existe um A separador.

(\Leftarrow) Suponha que existe A separador.

Seja $\Phi = \{\theta \in \Theta : P_{\theta}(A) = 1\}$.

Defina a estatística $S(x) = I_A(x)$, para $x \in \mathcal{X}$. Temos que,

$$P_{\theta}(S(x) = 1) = 1, \quad \theta \in \Phi \quad e$$

$$P_{\theta}(S(x) = 0) = 1, \quad \theta \in \Phi^c.$$

Então, para θ fixo, S é essencialmente constante o que implica que S é estatisticamente independente de qualquer outra estatística. Em particular, S é independente de T . Contudo, S não é ancilar.

(\Rightarrow) Suponha que existe S não ancilar. Neste caso, existe $B \in \sigma(S)$ tal que, para algum par $\theta_1, \theta_2 \in \Theta$,

$$P_{\theta_1}(B) \neq P_{\theta_2}(B). \quad (1.7)$$

Pela suficiência de T e independência de S [lembre da prova do Teorema de Basu 2 (1.6)], temos

$$P_{\theta}(B) = f(T) \quad P_{\theta} - q.c.$$

Considere

$$A_{\theta} = \{x \in \mathcal{X} : f \circ T(x) = P_{\theta}(B)\}.$$

Então, $P_{\theta}(A_{\theta}) = 1$.

De (1.7) temos que existem $\theta_1, \theta_2 \in \Theta$, tal que $A_{\theta_1} \cap A_{\theta_2} = \emptyset$.

Seja $A = A_{\theta_1}$ e $\Phi = \{\theta \in \Theta : A_{\theta} = A\}$. Φ e Φ^c são não vazios pois, $\theta_1 \in \Phi$ e $\theta_2 \in \Phi^c$.

Temos que

$$\theta \in \Phi \Rightarrow P_{\theta}(A) = P_{\theta}(A_{\theta}) = 1 \quad e$$

$$\theta \in \Phi^c \Rightarrow P_{\theta}(A^c) \geq P_{\theta}(A_{\theta}) = 1 \Rightarrow P_{\theta}(A^c) = 1.$$

Logo, A é um conjunto separador. ◇

Pelos lemas 1.4 e 1.5 obtemos a equivalência entre as condições do Teorema de Basu 2 e Teorema de Basu 2.A . Portanto, nos casos dos modelos discreto e dominado a condição dada por Basu é uma condição necessária e suficiente para a ancilaridade de S .

Considere os três conceitos básicos apresentados,

- (a) Suficiência,
- (b) Independência Estatística e
- (c) Ancilaridade.

O Teorema de Basu 1 estabelece que sob certas condições adicionais, (a) e (c) implicam em (b) e, o Teorema de Basu 2 estabelece que, também sob certas condições, (a) e (b) implicam em (c) . Para completar, apresentamos o Teorema de Basu 3 que estabelece condições, para que (b) e (c) impliquem em (a) .

Teorema de Basu 3

Sejam S e T estatísticas, tais que S é ancilar e estatisticamente independente de T . Se (S, T) é suficiente para $(\mathcal{X}, \mathcal{A}, \mathcal{P})$, então T é suficiente para o modelo estatístico.

Prova : Considere o espaço estatístico $(\mathcal{X}, \sigma(T) \vee \sigma(S), \mathcal{P})$. Vamos mostrar que T é suficiente para este espaço.

Seja

$$\mathcal{D} = \{D \in \mathcal{A} : D = A \cup B \text{ ou } D = A \cap B, A \in \sigma(S), B \in \sigma(T)\}.$$

Então, $\mathcal{D} = \sigma(T) \vee \sigma(S)$ pois, \mathcal{D} é um \mathcal{D} -sistema que contém $\sigma(S) \cup \sigma(T)$.

Para concluir, necessitamos mostrar que para todo $D \in \mathcal{D}$ existe uma versão da probabilidade condicional de D dado T , livre de θ .

Caso 1 : Considere $D \in \mathcal{D}$ tal que $D = A \cap B$ e, $E \in \sigma(T)$, então

$$P_{\theta}(D \cap E) = P_{\theta}(A \cap B \cap E) = P_{\theta}(A \cap E^*),$$

onde $E^* = B \cap E \in \sigma(T)$. Utilizando a independência de S e T e a ancilaridade de A temos

$$\begin{aligned} P_{\theta}(D \cap E) &= P_{\theta}(A)P_{\theta}(E^*) = \\ &= \int_{E^*} P_{\theta}(A)dP_{\theta} = \int_E k I_B dP_{\theta} \quad \forall \theta \in \Theta, \end{aligned}$$

onde $k.I_B$ é $\sigma(T)$ -mensurável e livre de θ . Portanto, existe uma versão da probabilidade condicional de D dado T livre de θ .

Caso 2: Seja $D \in \mathcal{D}$, tal que $D = A \cup B$. Considere os seguintes conjuntos,

$$D_1 = A^c \cap B, \quad D_2 = A \cap B^c \quad \text{e} \quad D_3 = A \cap B.$$

Então, $D = D_1 \cup D_2 \cup D_3$ onde os D_i são disjuntos, $i = 1, 2, 3$

Se $E \in \sigma(T)$, utilizando o Caso 1, temos

$$\begin{aligned} P_\theta(D \cap E) &= P_\theta(D_1 \cap E) + P_\theta(D_2 \cap E) + P_\theta(D_3 \cap E) = \\ &= \int_E f_1(T) dP_\theta + \int_E f_2(T) dP_\theta + \int_E f_3(T) dP_\theta = \int_E (f_1(T) + f_2(T) + f_3(T)) dP_\theta. \end{aligned}$$

Logo, também existe uma versão da probabilidade condicional de D dado T , livre de θ . Portanto, T é suficiente para $(\mathcal{X}, \sigma(S) \vee \sigma(T), \mathcal{P})$.

Por hipótese, $\sigma(S) \vee \sigma(T)$ é suficiente para $(\mathcal{X}, \mathcal{A}, \mathcal{P})$. Mas $\sigma(T) \subset \sigma(S) \vee \sigma(T) \subset \mathcal{A}$. Utilizando a Proposição 1.3 concluímos que T é suficiente para $(\mathcal{X}, \mathcal{A}, \mathcal{P})$. \diamond

No Exemplo 1.9, observamos que (X, Y) é suficiente para o modelo e $X \sim N(0, 1)$ é ancilar. Mas Y não é suficiente, ao contrário, também é ancilar. O que ocorre neste caso é que a condição de independência entre X e Y não está satisfeita. Note entretanto, que a condição de independência não é uma condição necessária. Observe o Exemplo 1.8, onde $(X, X+Y)$ é suficiente e X é ancilar, pois $P_\theta(X=0) = P_\theta(X=1) = 1/2, \forall \theta \in [0, 1]$. Além disso, a distribuição de probabilidade era dada por

$$f_\theta(x, y) = \frac{\theta}{2} I_{\{x=y\}}(x, y) + \frac{1-\theta}{2} I_{\{x \neq y\}} = \frac{\theta}{2} I_{\{x+y \neq 1\}}(x, y) + \frac{1-\theta}{2} I_{\{x+y=1\}}.$$

Pelo Teorema da Fatoração, $X+Y$ é suficiente. Entretanto, X e $X+Y$ não são independentes.

CAPITULO 2 : ABORDAGEM BAYESIANA

2.1. CONSTRUÇÃO DO MODELO BAYESIANO

Na visão bayesiana além do espaço estatístico $(\mathcal{X}, \mathcal{A}, \mathcal{P})$, admite-se um espaço probabilístico $(\Theta, \mathcal{T}, \nu)$, associado ao parâmetro θ , conhecido como espaço de probabilidade a priori. O modelo Bayesiano é construído no espaço produto $(\mathcal{X} \times \Theta, \mathcal{A} \otimes \mathcal{T})$ onde define-se uma medida de probabilidade. Entretanto, para a existência desta medida é necessário que o espaço de probabilidade associado a θ satisfaça certas condições. A seguir apresentamos uma série de resultados relacionados com esta medida.

Considere um espaço mensurável $(\mathcal{X}, \mathcal{A})$ e um espaço de probabilidade $(\Theta, \mathcal{T}, \nu)$. A função $P_\theta(A)$ é uma *função de transição* de (Θ, \mathcal{T}) em $(\mathcal{X}, \mathcal{A})$ se as condições abaixo estão satisfeitas.

(a) Para cada $\theta \in \Theta$, $P_\theta(\cdot)$ é uma medida de probabilidade em $(\mathcal{X}, \mathcal{A})$ e,

(b) para cada $A \in \mathcal{A}$, $P_\theta(A)$ é uma função de θ , \mathcal{T} -mensurável.

Teorema 2.1: Existe uma única probabilidade no espaço produto (Ω, \mathcal{F}) onde, $\Omega = \mathcal{X} \times \Theta$ e $\mathcal{F} = \mathcal{A} \otimes \mathcal{T}$ (sigma álgebra gerada pelos retângulos de Ω) tal que,

$$\pi(A \times B) = \int_B P_\theta(A) d\nu(\theta) , \forall A \in \mathcal{A} , \forall B \in \mathcal{T} ,$$

onde $P_\theta(A)$ é uma função de transição.

De um modo geral, esta medida é definida como

$$\pi(F) = \int_\Theta P_\theta(F_\theta) d\nu(\theta) \quad \forall F \in \mathcal{F},$$

onde $F_\theta = \{x \in \mathcal{X} : (x, \theta) \in F\}$.

Prova:

Parte I - Vamos mostrar que se $F \in \mathcal{F}$ então, $F_\theta \in \mathcal{A}$, $\forall \theta \in \Theta$.

Seja $\mathcal{L} = \{F \in \mathcal{F} : F_\theta \in \mathcal{A}\}$. Não é difícil verificar que \mathcal{L} é uma sigma álgebra.

Sejam $A \in \mathcal{A}$ e $B \in \mathcal{T}$, então

$$(A \times B)_\theta = B, \text{ se } \theta \in A \text{ e}$$

$$(A \times B)_\theta = \emptyset, \text{ se } \theta \notin A.$$

Portanto, $(A \times B)_\theta \in \mathcal{A} \Rightarrow A \times B \in \mathcal{L}$. Então, \mathcal{L} é uma sigma álgebra que contém todos os retângulos de Ω . Logo, $\mathcal{F} \subset \mathcal{L} \Rightarrow \mathcal{F} = \mathcal{L}$.

Parte II - Vamos mostrar que se $F \in \mathcal{F}$, então $P_\theta(F_\theta)$ é \mathcal{T} -mensurável.

Seja $\mathcal{L} = \{F \in \mathcal{F} : P_\theta(F_\theta) \text{ é } \mathcal{T}\text{-mensurável}\}$. Temos que \mathcal{L} é um D-sistema, pois

i) $\Omega_\theta = \mathcal{X} \Rightarrow P_\theta(\Omega_\theta) = 1, \forall \theta \in \Theta$ e portanto, $\Omega \in \mathcal{L}$.

ii) Se $F^1, F^2 \in \mathcal{L}$ tal que $F^1 \subset F^2$, então

$$P_\theta[(F^2 - F^1)_\theta] = P_\theta(F_\theta^2 - F_\theta^1) = P_\theta(F_\theta^2) - P_\theta(F_\theta^1),$$

que é \mathcal{T} -mensurável.

iii) Se $(F^n)_{n \geq 1} \in \mathcal{L}$ é tal que $\lim_{n \rightarrow \infty} F^n = F$, então

$$P_\theta(F_\theta) = P_\theta(\lim_{n \rightarrow \infty} F_\theta^n) = \lim_{n \rightarrow \infty} P_\theta(F_\theta^n),$$

onde cada $P_\theta(F_\theta^n)$ é \mathcal{T} -mensurável. Portanto, $P_\theta(F_\theta)$ é \mathcal{T} -mensurável.

Considerando $F = A \times B$ temos que,

$$P_\theta[(A \times B)_\theta] = P_\theta(A)I_B(\theta).$$

Mas, $P_\theta(A)$ é por hipótese \mathcal{T} -mensurável e como $B \in \mathcal{T}$, $I_B(\theta)$ também é \mathcal{T} -mensurável. Logo, $P_\theta[(A \times B)_\theta]$ é \mathcal{T} -mensurável e portanto, \mathcal{L} contém os retângulos. Utilizando o teorema sobre sistemas Dynkin (apêndice B) concluímos que,

$$\mathcal{F} \subset \mathcal{L} \Rightarrow \mathcal{F} = \mathcal{L}.$$

Parte III - Seja

$$\pi(F) = \int_{\Theta} P_\theta(F_\theta) d\nu(\theta) \quad \forall F \in \mathcal{F}.$$

A integral existe pois, $P_\theta(F_\theta)$ é \mathcal{T} -mensurável. Basta mostrar que π é uma medida de probabilidade.

Seja $F = \bigcup_{n=1}^{\infty} F^n$ onde $F^n \in \mathcal{F}$ são disjuntos, $\forall n$, então

$$\begin{aligned} \pi(F) &= \int_{\Theta} P_\theta(F_\theta) d\nu(\theta) = \int_{\Theta} P_\theta\left(\bigcup_{n=1}^{\infty} F_\theta^n\right) d\nu(\theta) = \\ &= \int_{\Theta} \sum_{n=1}^{\infty} P_\theta(F_\theta^n) d\nu(\theta) = \sum_{n=1}^{\infty} \int_{\Theta} P_\theta(F_\theta^n) d\nu(\theta) = \sum_{n=1}^{\infty} \pi(F_\theta^n). \end{aligned}$$

Além disso,

$$\pi(\Omega) = \int_{\Theta} P_\theta(\mathcal{A}) d\nu(\theta) = \nu(\Theta) = 1.$$

Em particular se $F = A \times B$ temos

$$\pi(A \times B) = \int_A P_\theta(A) \nu(\theta).$$

Para verificar a unicidade utiliza-se o teorema de extensão de Carathéodory. \diamond

O Teorema 2.1 continua válido se as medidas não forem de probabilidade mas apenas, medidas sigmas finitas e, é conhecido como Teorema da Medida Produto Generalizado (Ash,1972).

Nas condições do teorema trabalharemos, a partir de agora, no espaço de medida produto $(\Omega, \mathcal{F}, \pi)$ chamado modelo bayesiano.

A restrição da probabilidade π à (Θ, \mathcal{T}) , que é $\pi(\mathcal{X} \times B), \forall B \in \mathcal{T}$, será identificada pela medida ν , pois

$$\pi(\mathcal{X} \times B) = \int_B P_\theta(\mathcal{X}) d\nu(\theta) = \nu(B) \quad \forall B \in \mathcal{T}.$$

A medida ν será denominada *probabilidade a priori*.

Por outro lado, a restrição de π à $(\mathcal{X}, \mathcal{A})$, que é $\pi(A \times \Theta), \forall A \in \mathcal{A}$, será identificada por uma medida de probabilidade P em $(\mathcal{X}, \mathcal{A})$, dada por

$$P(A) = \pi(A \times \Theta) = \int_\Theta P_\theta(A) d\nu(\theta) \quad \forall A \in \mathcal{A}.$$

A medida P será denominada *Probabilidade marginal ou preditiva*.

Exemplo 2.1 : Seja $(\mathbb{R}, \mathcal{B}, \mathcal{P})$ um espaço estatístico onde P_θ é $N(\theta, 1), \forall P_\theta \in \mathcal{P}$ e $\Theta = \{0, 1, 2, \dots, 10\}$. Considere a probabilidade a priori ν , Uniforme em Θ , isto é, $\nu(i) = 1/11, \forall i \in \Theta$. Associamos a Θ a sigma álgebra das partes, $\mathcal{P}(\Theta)$.

O objetivo aqui é saber se o modelo está bem definido.

Por definição, a condição (a) do Teorema 2.1 é satisfeita. Vamos assim, estudar a condição (b). Tal condição é facilmente verificada pois, fixado $A \in \mathcal{A}$, $P_j(A) \equiv f : \Theta \rightarrow [0,1]$ é certamente $\mathcal{P}(\Theta)$ mensurável. Logo, o modelo bayesiano está bem definido.

Exemplo 2.2 : Utilizando o mesmo espaço estatístico do exemplo anterior. Considere agora, $\Theta = [0, 10]$ com a seguinte medida de probabilidade a priori,

$$\nu([0, 2]) = \nu((8, 10]) = 1/4 \quad e,$$

$$\nu([2, 8]) = 1/2.$$

Associando a Θ a única sigma álgebra em que é possível determinar a medida ν de seus elementos, temos

$$\mathcal{T} = \sigma(\{\emptyset; [0, 10]; [0, 2]; [2, 8]; (8, 10]\}).$$

Seja $A = [0, \infty) \in \mathcal{B}$, $B = \{1/2\} \in \mathcal{B}_{[0,1]}$. Então,

$$f^{-1}(B) = \{j \in \Theta : P_j(A) = 1/2\} = \{0\} \notin \mathcal{T}.$$

Portanto, $f = P_j(A)$ não é \mathcal{T} -mensurável e não podemos definir um modelo bayesiano para essa priori.

Exemplo 2.3 : Utilizando, ainda, o mesmo espaço estatístico do exemplo anterior, seja $\Theta = [0, 10]$ e ν a probabilidade triangular com função densidade dada por,

$$g(\theta) = \frac{\theta}{25} I_{[0,5)}(\theta) + \frac{(1-\theta)}{25} I_{[5,10]}(\theta).$$

Associando a sigma álgebra de Borel do $[0, 10]$, temos o seguinte espaço de probabilidade a priori $([0, 10]; \mathcal{B}_{[0,10]}; \nu)$. Claramente, $P_j(A)$ é Borel mensurável, $\forall A \in \mathcal{A}$.

Definição 2.1: Sejam $(\Omega_1, \mathcal{F}_1)$ e $(\Omega_2, \mathcal{F}_2)$ dois espaços mensuráveis. Um objeto aleatório é uma função $f : \Omega_1 \rightarrow \Omega_2$ onde, $\forall F_2 \in \mathcal{F}_2$ temos que, $f^{-1}(F_2) \in \mathcal{F}_1$. Em particular se $\Omega_2 = \mathbb{R}^n$ e \mathcal{F}_2 é a sigma álgebra de Borel, $\forall n \in \mathbb{N}$ ou $n = \infty$, então f é uma variável (vetor) aleatória (o).

Definição 2.2: Seja f um objeto aleatório e \mathcal{D} uma sigma álgebra contida em \mathcal{F}_1 . A função $g : \Omega_1 \times \mathcal{F}_2 \rightarrow [0, 1]$ é uma probabilidade condicional regular de f dado \mathcal{D} se, e somente se,

(i) para cada $\omega \in \Omega_1$ fixado , $g(\omega, \cdot)$ é uma probabilidade em $(\Omega_2, \mathcal{F}_2)$ e,

(ii) para cada $F_2 \in \mathcal{F}_2$ fixado, $g(\cdot, F_2)$ é uma versão da probabilidade condicional de F_2 dado \mathcal{D} .

Teorema 2.2: Seja Ω_2 um espaço métrico, completo e separável (em particular o \mathbb{R}^n) e \mathcal{F}_2 a sigma álgebra de Borel, então existe uma $g : \Omega_1 \times \mathcal{F}_2 \rightarrow [0, 1]$ que é uma versão regular da probabilidade condicional de f dado \mathcal{D} .

A prova deste Teorema pode ser encontrada em Ash, 1972 .

Regularidade Bayesiana

Seja $A \times B$ um retângulo de \mathcal{F} . Pela definição da medida π , temos

$$\pi(A \times B) = \int_B P_\theta(A) d\nu(\theta) \quad \forall B \in \mathcal{T}. \quad (2.1)$$

Por outro lado, definindo $\bar{A} \equiv A \times \Theta$ e $\bar{B} \equiv \mathcal{X} \times B$. Temos que, $A \times B = \bar{A} \cap \bar{B}$ e, usando a definição de probabilidade condicional temos,

$$\pi(A \times B) = \int_{(\mathcal{X} \times B)} I_{(A \times \Theta)} d\pi = \int_B \pi(\bar{A}/\mathcal{T}) d\pi(\theta) \quad \forall B \in \mathcal{T}. \quad (2.2)$$

Lembrando que a restrição de π à (Θ, \mathcal{T}) é a probabilidade ν , segue de (2.1) e (2.2) que

$$\pi(\bar{A}/T) = P_\theta(A) \quad \nu - q.c..$$

Como $P_\theta(A)$ satisfaz a condição (i) da definição 2.2, temos que ela é uma versão regular da probabilidade condicional de A dado T , $\forall A \in \mathcal{A}$.

A medida P_θ é chamada *probabilidade amostral* e, alternativamente, podemos usar a notação $P_\theta(A) = E[I_A/T]$. De um modo geral, $\forall f$, \mathcal{A} -mensurável, $E[f/T]$ é chamada *esperança amostral*.

De forma similar, pela definição de probabilidade condicional, fazendo as identificações devidas e lembrando que a probabilidade marginal P é a restrição de π à $(\mathcal{X}, \mathcal{A})$ temos,

$$\pi(A \times B) = \int_A \pi(\bar{B}/\mathcal{A})dP(x) \quad \forall A \in \mathcal{A}.$$

Sob a hipótese de Θ ser um espaço métrico, completo e separável e T ser a sigma álgebra de Borel, existe (Teorema 2.2) uma versão regular da probabilidade condicional de B dado \mathcal{A} . A seguinte notação será adotada,

$$\nu_x(B) = \pi(\bar{B}/\mathcal{A})(x) \quad \forall x \in \mathcal{X}.$$

Como para todo $x \in \mathcal{X}$, ν_x é uma medida regular, então possui as seguintes propriedades:

- (a) $\forall B \in T$ fixado, $\nu_x(B)$ é uma função \mathcal{A} -mensurável e,
- (b) $\forall x \in \mathcal{X}$ fixado, $\nu_x(\cdot)$ é uma probabilidade em (Θ, T) .

Portanto, $\nu_x(B)$ é uma função de transição de $(\mathcal{X}, \mathcal{A})$ em (Θ, T) . E é tal que para todo retângulo $A \times B$,

$$\pi(A \times B) = \int_A \nu_x(B)dP(x).$$

Pelo Teorema 2.1, podemos escrever,

$$\pi(F) = \int_{\mathcal{X}} \nu_x(F^x)dP(x) \quad \forall F \in \mathcal{F},$$

onde $F^x = \{\theta \in \Theta : (x, \theta) \in F\}$.

A esta família de probabilidades $\{\nu_x : x \in \mathcal{X}\}$ em (Θ, \mathcal{T}) denominamos de família de *probabilidades a posteriori*.

Por construção $\pi = P_\theta \times \nu$ e agora podemos escrever $\pi = P \times \nu_x$. Esta propriedade é chamada regularidade do modelo Bayesiano, e a condição exigida é que Θ seja métrico, completo e separável e \mathcal{T} a sigma álgebra de Borel.

Ainda, podemos escrever a probabilidade a priori como,

$$\nu(B) = \int_{\mathcal{X}} \nu_x(B) dP(x) \quad \forall B \in \mathcal{T}.$$

Dominação do modelo Bayesiano

Considere os seguintes espaços de probabilidade $(\mathcal{X}, \mathcal{A}, P)$ e $(\Theta, \mathcal{T}, \nu)$. Pelo Teorema da Medida Produto (Ash, 1972), existe uma única medida produto $P \times \nu$ em (Ω, \mathcal{F}) , tal que

$$P \times \nu(A \times B) = P(A)\nu(B) \quad \forall A \in \mathcal{A}, \forall B \in \mathcal{T}.$$

Suponha que $A \times B$ é tal que $P \times \nu(A \times B) = 0$, então $P(A) = 0$ ou $\nu(B) = 0$. No primeiro caso, pela definição de P , temos que $P_\theta(A) = 0 \quad \forall \theta \in \Theta$. Mas,

$$\pi(A \times B) = \int_{\Theta} P_\theta(A) d\nu(\theta). \quad (2.3)$$

Logo $\pi(A \times B) = 0$. No caso de $\nu(B) = 0$ temos, também de (2.3), que $\pi(A \times B) = 0$.

Portanto, restrito aos retângulos de \mathcal{F} , temos a dominação de π pela medida produto $P \times \nu$. É possível estender esta dominação para toda \mathcal{F} sob a condição de Ω ser um espaço métrico, completo e separável (Picci, 1974). Neste caso,

$$\pi \ll P \times \nu$$

Além disso, sob a hipótese do modelo ser dominado, sabemos que existe uma função \mathcal{F} -mensurável, $g(x, \theta)$, tal que

$$\pi(F) = \int_F g(x, \theta) d(P \times \nu) \quad \forall F \in \mathcal{F}.$$

Se F é um retângulo, pelo Teorema de Fubini (Ash, 1972) temos,

$$\pi(A \times B) = \int_B \left[\int_A g(x, \theta) dP(x) \right] d\nu(\theta) = \int_A \left[\int_B g(x, \theta) d\nu(\theta) \right] dP(x).$$

Lembrando que

$$\pi(A \times B) = \int_B P_\theta(A) d\nu(\theta) \quad e,$$

$$\pi(A \times B) = \int_A \nu_x(B) dP(x).$$

Concluimos que

$$P_\theta(A) = \int_A g(x, \theta) dP(x) \quad \nu - q.c. \quad (2.4) \quad e$$

$$\nu_x(B) = \int_B g(x, \theta) d\nu(\theta) \quad P - q.c. \quad (2.5).$$

É possível mostrar (Teorema 3.6, Picci, 1974) que existe $N_1 \in \mathcal{T}$ ($N_2 \in \mathcal{A}$), que não depende de A (B), tal que $\nu(N_1) = 0$ [$P(N_2) = 0$] e a relação (2.4) [(2.5)] é válida para todo $\theta \in N_1^c$ ($\forall x \in N_2^c$). Daí resulta que $P_\theta \ll P$ e $\nu_x \ll \nu$. Mas, sabemos que $P \ll P_\theta$ e $\nu \ll \nu_x$ e portanto, $P \equiv P_\theta$ e $\nu \equiv \nu_x$. Assim,

$$\frac{dP_\theta}{dP}(x) = \frac{d\nu_x}{d\nu}(\theta) = g(x, \theta).$$

Suponha agora que os modelos estatístico e a priori são dominados, respectivamente, pelas medidas sigma finitas μ e λ . É claro que também é válido $P \ll \mu$ e $\nu_x \ll \lambda, \forall x$. Vamos achar uma expressão para derivada de Radon-Nykodim, $\frac{d\nu_x}{d\lambda}$, da probabilidade a posteriori. Temos que,

$$\frac{d\nu_x}{d\lambda}(\theta) = \frac{d\nu_x}{d\nu}(\theta) \cdot \frac{d\nu}{d\lambda}(\theta) = \frac{dP_\theta}{dP}(x) \cdot \frac{d\nu}{d\lambda}(\theta) = \frac{\frac{dP_\theta}{d\mu}(x)}{\frac{dP}{d\mu}(x)} \cdot \frac{d\nu}{d\lambda}(\theta).$$

Mas,

$$\frac{dP}{d\mu}(x) = \frac{dP}{d\mu}(x) \cdot \nu_x(\Theta) = \int_{\Theta} \frac{dP}{d\mu}(x) \cdot \frac{d\nu_x}{d\nu}(\theta) d\nu(\theta) = \int_{\Theta} \frac{dP}{d\mu}(x) \cdot \frac{dP_\theta}{dP}(x) d\nu(\theta) =$$

$$\int_{\Theta} \frac{dP_\theta}{d\mu}(x) d\nu(\theta) = \int_{\Theta} \frac{dP_\theta}{d\mu}(x) \cdot \frac{d\nu}{d\lambda}(\theta) \cdot d\lambda(\theta) = \int_{\Theta} f(x, \theta) \cdot g(\theta) d\lambda(\theta).$$

Considerando $g(\theta) = \frac{d\nu}{d\lambda}(\theta)$ (densidade a priori), $f(x, \theta) = \frac{dP_\theta}{d\mu}(x)$ (densidade amostral, também conhecida como verossimilhança) e $h(x, \theta) = \frac{d\nu_x}{d\lambda}(\theta)$ (densidade a posteriori), temos

$$h(x, \theta) = \frac{f(x, \theta) \cdot g(\theta)}{\int_{\Theta} f(x, \theta) \cdot g(\theta) d\lambda(\theta)}.$$

Que é a conhecida fórmula de Bayes.

Exemplo 2.4 : Seja $\mathcal{X} = \{0, 1, 2, \dots, n\}$, $\mathcal{A} = \mathcal{I}P(\mathcal{X})$ e $\mathcal{P} = \{P_\theta : \theta \in [0, 1]\}$ onde P_θ tem distribuição binomial (n, θ) . Considerando que μ é a medida de contagem, temos

$$\frac{dP_\theta}{d\mu}(x) = \binom{n}{x} \theta^x (1 - \theta)^{n-x}.$$

Além disso, seja $\Theta = [0, 1], \mathcal{T} = \mathcal{B}_{[0,1]}$ e ν a medida Beta(a , b), onde a , b $\in \mathbb{N}$.

Se λ é a medida de lebesgue, temos

$$\frac{d\nu}{d\lambda}(\theta) = \frac{\theta^{a-1} (1 - \theta)^{b-1}}{Be(a, b)}.$$

A medida marginal P em $(\mathcal{X}, \mathcal{P}(\mathcal{X}))$ é dada por,

$$P(A) = \int_{\Theta} P_{\theta}(A) d\nu(\theta) = \int_{\Theta} \left[\int_A \binom{n}{x} \theta^x (1-\theta)^{n-x} d\mu \right] d\nu(\theta) =$$

$$\int_A \left[\int_{\Theta} \binom{n}{x} \theta^x (1-\theta)^{n-x} d\nu(\theta) \right] d\mu(x) = \int_A \left[\int_0^1 \frac{\binom{n}{x} \theta^{x+a-1} (1-\theta)^{n+b-x-1}}{Be(a,b)} d\theta \right] d\mu(x).$$

Então,

$$P(A) = \int_A \binom{n}{x} \frac{Be(a+x, b+a-x)}{Be(a,b)} d\mu(x)$$

e, pela fórmula de Bayes, temos que,

$$\frac{d\nu_x}{d\lambda}(\theta) = \frac{\theta^{x+a-1} (1-\theta)^{n+b-x-1}}{Be(a+x, b+a-x)}.$$

Portanto, a medida a posteriori, $\forall x \in \mathcal{X}$, é

$$\nu_x(B) = \int_B \frac{\theta^{x+a-1} (1-\theta)^{n+b-x-1}}{Be(a+x, b+a-x)} d\lambda(\theta).$$

Note que a função do integrando é uma densidade Beta($a+x, b+n-x$).

O estatístico bayesiano usualmente tem como interesse principal determinar a probabilidade a posteriori, com objetivo de fazer inferências sobre determinado parâmetro baseando-se nas informações obtidas da amostra. De um modo geral, considerando o objeto aleatório X assumindo valores em \mathcal{X} como a amostra, o interesse está em determinar $E[f | \sigma(X)]$, onde f é uma função \mathcal{T} -mensurável.

Utilizaremos a seguinte notação

$$E[f | X] = E[f | \sigma(X)]$$

$$E[f | (Y, Z)] = E[f | \sigma(Y) \vee \sigma(Z)]$$

2.2 CONCEITOS FUNDAMENTAIS

Independência Condicional

Proposição 2.1: Sejam Y e Z objetos aleatórios, tais que $Y \subset Z$, então $\forall f$ \mathcal{F} -mensurável e integrável, temos que

$$(i) E[E(f | Y) | Z] = E[f | Y]$$

$$(ii) E[E(f | Z) | Y] = E[f | Y]$$

Prova:

(i) Pelo Teorema 1.1, $E[f | Y]$ é $\sigma(Y)$ -mensurável e integrável ($E[f | Y] \in L_\infty(Y)$). Mas $Y \subset Z$, então $E[f | Y]$ é $\sigma(Z)$ -mensurável ($E[f | Y] \in L_\infty(Z)$). Logo, ela é a própria versão de sua esperança condicional dado Z . \diamond

(ii) Utilizando o Teorema 1.1 temos que,

$$\int_A f d\pi = \int_A f^* d\pi \quad \forall A \in \sigma(Z), \quad (2.6)$$

onde $f^* = E[f | Z] \in L_\infty(Z)$. Mas, como $Y \subset Z$, em particular (2.6) é válido $\forall A \in \sigma(Y)$.

Por outro lado,

$$\int_A f d\pi = \int_A E[f | Y] d\pi \quad \forall A \in \sigma(Y)$$

e portanto, $E[f^* | Y] = E[f | Y]$. \diamond

Definição 2.3.: Sejam T, Y e Z três objetos aleatórios. T e Y são condicionalmente independentes dado Z se,

$$E[f | (Y, Z)] = E[f | Z] \quad \forall f \in L_\infty(T).$$

Notação : $T \amalg Y | Z$.

Em particular se Z é essencialmente constante, isto é, Z gera a σ -álgebra trivial [$\mathcal{F}_0 = \{\emptyset, \Omega\}$, $\pi - q.c.$], X e Y são simplesmente independentes e a notação é $X \amalg Y$.

Proposição 2.2 : Sejam T, Y e Z três objetos aleatórios. T e Y são condicionalmente independentes dado Z se, e somente se, $\forall f \in L_\infty(T)$ e $\forall g \in L_\infty(Y)$ a igualdade

$$E[f.g | Z] = E[f | Z]E[g | Z].$$

é válida.

Através desta proposição fica clara a simetria da independência condicional, isto é, $T \perp\!\!\!\perp Y | Z \Leftrightarrow Y \perp\!\!\!\perp T | Z$.

Prova: (\Rightarrow)

Seja $f \in L_\infty(T)$ e $g \in L_\infty(Y)$. Usando a Proposição 2.1 e a Definição 2.3 temos,

$$\begin{aligned} E[f.g | Z] &= E\left[E[f.g | (Y, Z)] | Z\right] = E\left[gE[f | (Y, Z)] | Z\right] = \\ &= E\left[gE[f | Z] | Z\right] = E[f | Z]E[g | Z]. \end{aligned}$$

(\Leftarrow) Seja,

$$\mathcal{D} = \left\{ D : D \in \sigma(Y) \vee \sigma(Z), \int_D f d\pi = \int_D E(f | Z) d\pi, \forall f \in L_\infty(X) \right\}$$

Vamos mostrar que \mathcal{D} é um D-sistema (apêndice B) .

i) Claramente $\Omega \in \mathcal{D}$, pois $E[f] = E[E[f | Z]]$

ii) Se $A, B \in \mathcal{D}$ com $B \subset A$, então $A - B = A \cap B^c \in (Y, Z)$.

Além disso,

$$\begin{aligned} \int_{A \cap B^c} f d\pi &= \int_A f I_{B^c} d\pi = \int_A E[f I_{B^c} | Z] d\pi = \\ &= \int_A I_{B^c} E[f | Z] d\pi = \int_{A \cap B^c} E[f | Z] d\pi. \end{aligned}$$

Logo $A - B \in \mathcal{D}$.

iii) Seja $(A_n)_{n \geq 1} \in \mathcal{D}$ tal que, $\lim_{n \rightarrow \infty} A_n = A$. Pelo teorema de convergência dominada temos

$$\begin{aligned}
\int_A f d\pi &= \int_{\Omega} f I_A d\pi = \int_{\Omega} \lim_{n \rightarrow \infty} f I_{A_n} d\pi = \\
&= \lim_{n \rightarrow \infty} \int_{\Omega} f I_{A_n} d\pi = \lim_{n \rightarrow \infty} \int_{\Omega} I_{A_n} E[f | Z] d\pi = \\
&= \int_{\Omega} I_A E[f | Z] d\pi = \int_A E[f | Z] d\pi.
\end{aligned}$$

Seja $\mathcal{E} = \{C \cap D : C \in \sigma(Y) \text{ e } D \in \sigma(Z)\}$. Vamos mostrar que $\mathcal{E} \subset \mathcal{D}$.

Seja $C \cap D \in \mathcal{E}$ e $f \in L_{\infty}(T)$, então utilizando a condição da proposição, temos

$$\begin{aligned}
\int_{C \cap D} f d\pi &= \int_D f I_C d\pi = \int_D E[f I_C | Z] d\pi = \\
&= \int_D E[f | Z] E[I_C | Z] d\pi = \int_D E[E(f | Z) I_C | Z] d\pi = \\
&= \int_D E[f | Z] I_C d\pi = \int_{D \cap C} E[f | Z] d\pi.
\end{aligned}$$

Logo $C \cap D \in \mathcal{D}$ e portanto, $\mathcal{E} \subset \mathcal{D}$.

Mas, claramente \mathcal{E} é fechado por uniões finitas e $\sigma(\mathcal{E}) = \sigma(Y) \vee \sigma(Z)$.

Utilizando o teorema sobre sistemas Dinkyn (apêndice B), temos que $\sigma(Y) \vee \sigma(Z) \subset \mathcal{D}$ logo, $\mathcal{D} = \sigma(Y) \vee \sigma(Z)$. ◇

Sejam X e θ dois objetos aleatórios com domínio em (Ω, \mathcal{F}) . Dizemos que X representa a amostra e θ o parâmetro se

$$\sigma(X) = \{A \times \Theta : A \in \mathcal{A}\}$$

$$\sigma(\theta) = \{\mathcal{X} \times B : B \in \mathcal{T}\}$$

Um objeto aleatório T é uma estatística se $T \subset X$.

T e Y são estatisticamente independentes se $\forall f \in L_{\infty}(T)$ e $\forall g \in L_{\infty}(Y)$,

$$E[f.g | \theta] = E[f | \theta]E[g | \theta], \quad \forall \theta \in \Theta.$$

Portanto, a independência estatística é uma independência condicional, $T \perp\!\!\!\perp Y \mid \theta$. Este fato não implica necessariamente que $T \perp\!\!\!\perp Y$.

Exemplo 2.5 : Sejam X_1 e X_2 observações independentes de uma Uniforme em $\{\theta, \theta + 1, \dots, \theta + 10\}$, onde θ tem distribuição Uniforme em $\{10, 20, 30, \dots\}$. Isto é, $X_1 \perp\!\!\!\perp X_2 \mid \theta$.

Suponha que $X_1 = 13$, então $\theta = 10$ e portanto $10 \leq X_2 \leq 20$. Logo, X_1 não é independente de X_2 no sentido probabilístico ($X_1 \not\perp\!\!\!\perp X_2$).

Exemplo 2.6 : (Paradoxo de Simpson)

Com o interesse de verificar o efeito de determinado tratamento na cura de uma doença realizou-se um estudo através de uma amostra . Os pacientes foram classificados segundo uma variável X , assumindo dois valores T (tratamento) e T^c (controle), conforme o paciente tenha ou não se submetido ao tratamento em estudo. A variável resposta de interesse Y , assume também somente dois valores C (curado) e C^c (doente). Além disso, uma variável auxiliar Z foi considerada no problema, o sexo do paciente. Na tabela abaixo apresentamos os resultados.

TABELA 2

	Homem		Mulher	
X	C	C^c	C	C^c
T	20	40	100	50
T^c	20	40	20	10

Observe que para os dois valores de Z (homem e mulher) $X \perp\!\!\!\perp Y$. Entretanto, desconsiderando a variável auxiliar, temos o resultado na Tabela 3 .

TABELA 3

X	C	C^c
T	120	90
T^c	40	50

Observando a Tabela 3, concluímos que não é possível afirmar que X e Y são independentes. Este fato, bastante interessante para os estatísticos é conhecido como o Paradoxo de Simpson. Em termos de independência condicional podemos dizer que $X \perp\!\!\!\perp Y \mid Z$ não implica em $X \perp\!\!\!\perp Y$. Para uma análise mais detalhada do problema, inclusive sobre qual a conclusão estatística a respeito do efeito do tratamento na cura da doença, ver Dawid (1979a).

Proposição 2.3: Sejam T_1, T, Y, Z objetos aleatórios tais que $T \perp\!\!\!\perp Y/Z$ e $T_1 \subset T$, então

$$(i) T_1 \perp\!\!\!\perp Y \mid Z \quad e,$$

$$(ii) T \perp\!\!\!\perp Y \mid (Z, T_1).$$

Prova:

$$i) \text{ Por hipótese, } \forall f \in L_\infty(T), \text{ temos que } E[f \mid (Y, Z)] = E[f \mid Z]. \quad (2.7)$$

Como $T_1 \subset T$ em particular temos que, $\forall f \in L_\infty(T_1)$, (2.7) é válido. Portanto, $T_1 \perp\!\!\!\perp Y \mid Z$.

$$ii) \text{ Por hipótese, } \forall g \in L_\infty(Y) \text{ temos que } E[g \mid (T, Z)] = E[g \mid Z]. \text{ Mas } T_1 \subset T, \text{ então } (T, Z) = (T, T_1, Z) \text{ e portanto } E[g \mid (T, T_1, Z)] = E[g \mid Z]. \quad (2.8)$$

Por outro lado, usando a proposição 2.1 temos

$$\begin{aligned} E[g \mid (T_1, Z)] &= E \left[E[g \mid (T, T_1, Z)] \mid (T_1, Z) \right] = \\ &= E \left[E[g \mid Z] \mid (T_1, Z) \right] = E[g \mid Z] \end{aligned} \quad (2.9)$$

De (2.8) e (2.9) temos

$$E[g \mid (T, T_1, Z)] = E[g \mid (T_1, Z)] \quad \forall g \in L_\infty(Y).$$

Logo, $T \amalg Y \mid (T_1, Z)$. ◇

Proposição 2.4 : Sejam T, Y, Z, W objetos aleatórios . As seguintes propriedades são equivalentes,

(i) $T \amalg Y \mid Z$ e $T \amalg W \mid (Y, Z)$

(ii) $T \amalg (Y, W) \mid Z$

Prova: (i) \Rightarrow (ii)

$$f \in L_\infty(T) \Rightarrow E[f \mid (Y, W, Z)] = E[f \mid (Y, Z)] = E[f \mid Z].$$

(ii) \Rightarrow (i)

Pela Proposição 2.3 temos

a) $T \amalg Y \mid Z$

b) $T \amalg (Y, W) \mid (Z, Y) \Rightarrow T \amalg W \mid (Y, Z)$ ◇

Corolário 2.1 : Seja T_1 um objeto aleatório tal que $T_1 \subset (T, Z, W)$. Se $T \amalg Y \mid (Z, W)$ e $T_1 \amalg W \mid Z$, então $T_1 \amalg Y \mid Z$ e $T_1 \amalg W \mid (Y, Z)$.

Proposição 2.5: Sejam T_1 e T_2 objetos aleatórios tais que $(T_1, T_2) \subset X$. Se $X \amalg Y \mid T_1$ e $X \amalg Y \mid T_2$, então $X \amalg Y \mid T_1 \wedge T_2$.

Prova :

$\forall f \in L_\infty(Y)$ temos

$$E[f \mid (X, T_1)] = E[f \mid T_1] \quad e,$$

$$E[f \mid (X, T_2)] = E[f \mid T_2].$$

Como $(T_1, T_2) \subset X$, temos que $(X, T_1) = X$ e $(X, T_2) = X$. Logo, $E[f \mid X]$ é mensurável em relação a $T_1 \wedge T_2$ e

$$E[f \mid X] = E[f \mid (X, T_1 \wedge T_2)]. \tag{2.10}$$

Por outro lado,

$$\int_A f d\pi = \int_A E[f \mid X] d\pi \quad \forall A \in X.$$

Em particular, a igualdade acima é válida $\forall A \in T_1 \wedge T_2$. Utilizando (2.10) temos que,

$$E[f | (X, T_1 \wedge T_2)] = E[f | T_1 \wedge T_2].$$

Portanto, $X \perp\!\!\!\perp Y | T_1 \wedge T_2$

◇

Corolário 2.2 : Se T, Y, Z são objetos aleatórios tais que $T \perp\!\!\!\perp Y | Z$ e $T \perp\!\!\!\perp Z | Y$, então $T \perp\!\!\!\perp (Y, Z) | Y \wedge Z$.

Neste corolário é fundamental observar que concluímos por uma independência condicional à sigma álgebra da interseção de Y e Z . Em várias situações em estatística, há uma tendência em concluir pela simples independência entre T e (Y, Z) . Alguns exemplos deste tipo de erro são apresentados por Dawid (1979b) como “falácias da independência condicional”. Convém lembrar a primeira versão (1955) do Teorema de Basu 2, cujo erro foi concluir por uma independência simples sem levar em conta o condicionamento. Este problema será abordado na unidade 2.3.

Suficiência

Definição 2.4 : T é uma estatística suficiente para X com respeito a θ , se $X \perp\!\!\!\perp \theta | T$.

O interesse do pesquisador bayesiano, como já foi dito anteriormente, está em determinar a esperança a posteriori $E[f | X]$, onde f é uma função $\sigma(\theta)$ -mensurável. No caso de T ser uma estatística suficiente $E[f | X] = E[f | T]$ e portanto, o aprendizado relevante da amostra X a respeito de θ está concentrado na estatística suficiente T . Este aprendizado muitas vezes é chamado de informação. Vejamos a seguir a idéia de Basu (1975) sobre informação.

Segundo Basu, dois experimentos \mathcal{E}_1 e \mathcal{E}_2 geradores de dois pontos amostrais x_1 e x_2 são igualmente informativos para θ se obtemos a mesma inferência na previsão de θ .

Exemplo 2.7 : Uma urna contém bolas numeradas de $\theta + 1, \theta + 2, \dots, \theta + 100$, onde $\Theta = \mathcal{N}$. Realiza-se os dois experimentos caracterizados a seguir.

\mathcal{E}_1 : retira-se 10 bolas da urna e observa-se os seguintes valores nas bolas retiradas,

$$x_1 = (15, 16, 27, 32, 57, 83, 92, 100, 102, 113).$$

\mathcal{E}_2 : retira-se 2 bolas da urna e observa-se os seguintes valores,

$$x_2 = (15, 113).$$

Em ambos os casos (\mathcal{E}_1 e \mathcal{E}_2) o que podemos inferir a respeito do parâmetro θ é que

$$\theta + 1 \leq 15 \text{ e } \theta + 100 \geq 113 \Rightarrow \theta = 13 \text{ ou } 14.$$

Portanto, a informação a respeito de θ é a mesma nos dois casos, isto é,

$$Inf(\mathcal{E}_1, x_1) = Inf(\mathcal{E}_2, x_2).$$

Com seria de esperar, se T é uma estatística suficiente a informação contida em um determinado ponto amostral x é a mesma contida em t , onde $T(x) = t$ (Basu,1975).

Exemplo 2.8: Sejam X_1, X_2, X_3 variáveis aleatórias estatisticamente independentes com distribuição comum $N(\theta, 1)$.

É fácil verificar que as estatísticas $T_1 = (X_1, X_2 + X_3)$ e $T_2 = (X_1 + X_2, X_3)$ são individualmente suficiente para $(X_1, X_2, X_3) = X$ com respeito a θ . Isto é, $X \perp\!\!\!\perp \theta \mid T_1$ e $X \perp\!\!\!\perp \theta \mid T_2$. O que implica que $\theta \perp\!\!\!\perp T_2 \mid T_1$ e $\theta \perp\!\!\!\perp T_1 \mid T_2$.

Se por um lado θ não depende de T_2 , e por outro lado não depende de T_1 , então podemos afirmar que θ não depende de (T_1, T_2) ? A afirmação não é verdadeira pois se fosse resultaria em $\theta \perp\!\!\!\perp X$, o que é um absurdo. Entretanto, utilizando o corolário 2.2, é possível afirmar que $\theta \perp\!\!\!\perp (T_1, T_2) \mid T_1 \wedge T_2$.

Proposição 2.6: Sejam T e T_1 duas estatísticas, tais que T é suficiente para X com respeito a θ e $T \subset T_1$. Então, T_1 é suficiente para θ .

Prova: Pela Proposição 2.3 temos que

$$X \perp\!\!\!\perp \theta \mid T \text{ e } T_1 \subset X \Rightarrow X \perp\!\!\!\perp \theta \mid (T, T_1).$$

Mas, $T \subset T_1 \Rightarrow (T, T_1) = T_1$. Logo, $X \perp\!\!\!\perp \theta \mid T_1$. ◇

Através desta proposição observamos que de um modo geral a suficiência Bayesiana não é equivalente a Clássica, pois nesta última a Proposição 2.6 não é verdadeira. Basta lembrar o Exemplo 1.5 onde encontramos uma sigma álgebra que contém uma outra suficiente e contudo, não é suficiente.

Ancilaridade

Definição 2.5 : S é uma estatística ancilar com respeito a θ se $S \perp\!\!\!\perp \theta$.

Neste caso a esperança a posteriori $E[f \mid S]$ é igual a priori, onde f é $\sigma(\theta)$ -mensurável. Podemos dizer que S , isoladamente, não contém informação a respeito de θ . No entanto, os exemplos e comentários do capítulo 1, a respeito da importância das estatísticas ancilares, quando em conjunto com outra estatística, continuam válidos.

Proposição 2.7: Sejam S e S_1 estatísticas tais que S é ancilar para θ e $S_1 \subset S$, então S_1 é ancilar para θ .

Prova: imediata da proposição 2.3 .

Vamos retomar o Exemplo 1.9 onde (X, Y) tem distribuição Normal bivariada e onde o parâmetro desconhecido θ é a covariância . Além disso, $X \sim N(0, 1)$ e $Y \sim N(0, 1)$. Portanto, X e Y são individualmente ancilares para θ . No entanto, (X, Y) é suficiente. Escrevendo em termos de esperança condicional resulta

$$X \perp\!\!\!\perp \theta, Y \perp\!\!\!\perp \theta \not\Rightarrow (X, Y) \perp\!\!\!\perp \theta.$$

A condição que deve ser acrescentada para que a implicação acima seja válida é, $Y \perp\!\!\!\perp \theta \mid X$. Pois neste caso, ela é a própria Proposição 2.4 com Z constante.

Proposição 2.8: Sejam S_1 e S_2 duas estatísticas ancilares tal que $S_1 \perp\!\!\!\perp S_2 \mid \theta$, então (S_1, S_2) é ancilar.

Prova: Utilizando o Corolário 2.1, temos que

$$S_1 \perp\!\!\!\perp S_2 \mid \theta \text{ e } S_1 \perp\!\!\!\perp \theta \Rightarrow S_1 \perp\!\!\!\perp S_2 \text{ e } S_1 \perp\!\!\!\perp \theta \mid S_2.$$

Pela proposição 2.4 ,utilizando o fato de que $\theta \perp\!\!\!\perp S_2$ e $S_1 \perp\!\!\!\perp \theta \mid S_2$, temos que $\theta \perp\!\!\!\perp (S_1, S_2)$. \diamond

Fortemente Identificável e Conjunto Separador

Definição 2.5: Se $\forall f \in L_\infty(T)$ existe $f^* \in L_\infty(Y)$, tal que $f_1 \neq f_2 \Rightarrow f_1^* \neq f_2^*$ π -essencialmente, então T é fortemente identificável por Y .

Notação : $T \not\prec Y$

Em particular, se $f^* = E[f/Y]$, temos $E[f \mid Y] = 0 \Rightarrow f = 0$ π -essencialmente.

Considerando $Y = \theta$ temos a versão bayesiana de estatística completa.

Definição 2.6: $A \in \mathcal{F}$ é um conjunto separador se

- (i) $0 < \pi(A) < 1$ e,
- (ii) $E[I_A \mid \theta] = E^2[I_A \mid \theta]$.

Proposição 2.9: Não existe um conjunto A separador se, e somente se, $\theta \wedge X$ for essencialmente constante.

Prova: (\Leftarrow) Seja A um conjunto separador, então

$$\begin{aligned} E\left[[I_A - E(I_A \mid \theta)]^2 \mid \theta\right] &= E\left[I_A^2 - 2I_A E[I_A \mid \theta] + E^2[I_A \mid \theta] \mid \theta\right] = \\ &= E[I_A \mid \theta] - 2E[I_A \mid \theta]E[I_A \mid \theta] + E^2[I_A \mid \theta] = E[I_A \mid \theta] - E^2[I_A \mid \theta] = 0. \end{aligned}$$

Portanto,

$$E\left[[I_A - E(I_A \mid \theta)]^2 \mid \theta\right] = 0 \Rightarrow I_A = E[I_A \mid \theta] \quad \pi - q.c..$$

Logo, A é $\sigma(\theta)$ -mensurável e portanto, A é $\sigma(\theta) \wedge \sigma(X)$ - mensurável. Mas $0 < \pi(A) < 1$, o que implica que $\theta \wedge X$ não é essencialmente constante. \diamond

(\Rightarrow) Suponha que $\theta \wedge X$ não é essencialmente constante. Então, existe $B \in \sigma(\theta) \wedge \sigma(X)$ tal que, $0 < \pi(B) < 1$. Como $B \in \sigma(\theta)$, temos que $E[I_B | \theta] = I_B$ e $E^2[I_B | \theta] = I_B^2 = I_B$. Portanto B é um conjunto separador, o que contradiz a hipótese. \diamond

2.3 OS TEOREMAS DE BASU SOB A PERSPECTIVA BAYESIANA

Teorema de Basu 1

Sejam T, S, θ três objetos aleatórios tais que (T, S) é uma estatística e θ o parâmetro de interesse. Se $S \perp\!\!\!\perp \theta$, $X \perp\!\!\!\perp \theta | T$ e $T \not\prec \theta$, então $S \perp\!\!\!\perp T | \theta$.

Em palavras, se S é ancilar para θ e T é fortemente identificável por θ e suficiente para X , então S e T são condicionalmente independentes dado θ .

Prova : Utilizando a proposição 2.3 temos que

$$S \perp\!\!\!\perp \theta | T \tag{2.11}.$$

Utilizando (2.11) e a proposição 2.2 ,temos que, $\forall f \in L_\infty(S)$,

$$E[f | \theta] = E[E[f | (\theta, T)] | \theta] = E[E[f | T] | \theta].$$

Portanto, $E[E(f | \theta) - E(f | T) | \theta] = 0$ e pela ancilaridade de S , temos que

$$E[E(f) - E(f | T) | \theta] = 0.$$

Logo $E[f] = E[f | T]$ $\pi - q.c.$ pois $T \not\prec \theta$. Portanto,

$$S \perp\!\!\!\perp T \tag{2.12}.$$

Utilizando (2.11) , (2.12) e o corolário 2.1 concluímos que $S \perp\!\!\!\perp T | \theta$. \diamond

Antes de apresentarmos o segundo teorema de Basu vamos analisar o erro da sua primeira versão (Basu, 1955) dada a seguir.

Sejam T e S duas estatísticas onde T é suficiente para θ e S é estatisticamente independente de T , então S é ancilar para θ . Caracterizava-se assim a classe das estatísticas ancilares. Podemos escrever esta afirmação de uma outra maneira,

$$X \perp\!\!\!\perp \theta | T \text{ e } S \perp\!\!\!\perp T | \theta \Rightarrow S \perp\!\!\!\perp \theta.$$

Fica fácil para nós, depois de visto Corolário 2.2, perceber o erro da afirmação. Para que a sentença acima seja verdadeira é necessário que $\theta \wedge T$ seja essencialmente constante.

Teorema de Basu 2

Seja T uma estatística suficiente para X com respeito a θ . A estatística $\theta \wedge T$ é essencialmente constante se, e somente se, para toda S tal que $S \perp\!\!\!\perp T | \theta$, S é ancilar.

Prova : (\Rightarrow) imediata do Corolário 2.2 .

(\Leftarrow) Seja $S_1 = \theta \wedge T$. Como $S_1 \subset \theta$, temos que $S_1 \perp\!\!\!\perp T | \theta$, então por hipótese, $S_1 \perp\!\!\!\perp \theta$. Portanto, usando a Proposição 2.3, temos que $S_1 \perp\!\!\!\perp S_1$. Logo, S_1 é essencialmente constante. \diamond

Teorema de Basu 3

Sejam S e T duas estatísticas, onde S é ancilar em relação a θ e $S \perp\!\!\!\perp T | \theta$. Se (S, T) é suficiente para X com respeito a θ , então T também é suficiente para X com respeito a θ .

Prova: Utilizando o corolário 2.1, temos que

$$S \perp\!\!\!\perp \theta \text{ e } S \perp\!\!\!\perp T | \theta \Rightarrow S \perp\!\!\!\perp T \text{ e } S \perp\!\!\!\perp \theta | T.$$

Aplicando a Proposição 2.4, resulta

$$S \perp\!\!\!\perp \theta | T \text{ e } X \perp\!\!\!\perp \theta | (S, T) \Rightarrow X \perp\!\!\!\perp \theta | T. \quad \diamond$$

CAPITULO 3: APLICAÇÕES

3.1. CARACTERIZAÇÃO DA DISTRIBUIÇÃO DE DIRICHLET ATRAVÉS DE DISTRIBUIÇÕES GAMA

Nesta unidade definiremos a distribuição de Dirichlet através de variáveis aleatórias independentes Gamas com o objetivo de apresentar a Proposição 3.1 , cuja prova é uma aplicação do Teorema de Basu 1 .

Definição 3.1 : Sejam X_1, X_2, \dots, X_{n+1} variáveis aleatórias estatisticamente independentes com distribuição Gama $(\alpha_i, \beta), i = 1, 2, \dots, n + 1$, respectivamente. Isto significa que a medida de probabilidade induzida por $X_i, i = 1, 2, \dots, n + 1$, é dada por

$$P_{X_i}(B) = \int_B \frac{\beta^{\alpha_i}}{\Gamma(\alpha_i)} e^{-\beta x_i} x_i^{\alpha_i - 1} d\lambda(x_i) \quad \forall B \in \mathcal{B},$$

onde λ é a medida de Lebesgue de \mathbb{R} e \mathcal{B} é a sigma álgebra de Borel.

Sejam $S = \sum_{i=1}^{n+1} X_i$ e $Y_k = \frac{X_k}{S}, k = 1, 2, \dots, n+1$, então $Y^* = (Y_1, Y_2, \dots, Y_{n+1})$ têm distribuição de Dirichlet com parâmetro $(\alpha_1, \alpha_2, \dots, \alpha_{n+1})$.

Definição 3.2 : Sejam P e Q duas medidas de probabilidade num espaço mensurável $(\mathcal{X}, \mathcal{A})$. Se existe um conjunto $A \in \mathcal{A}$ tal que $P(A) = 0$ e $Q(A^c) = 0$, então P é singular em relação a Q .

Por construção Y^* tem a seguinte restrição sob suas componentes, $\sum_{i=1}^{n+1} Y_i = 1$. Portanto, se P_{Y^*} é a medida de probabilidade induzida por Y^* e

$$A = \left\{ (y_1, \dots, y_{n+1}) \in [0, 1]^{n+1} : \sum_{i=1}^{n+1} y_i = 1 \right\},$$

temos que $P_{Y^*}(A) = 1$.

Por outro lado, se λ^{n+1} é a medida de Lebesgue do $[0, 1]^{n+1}$, temos que $\lambda^{n+1}(A) = 0$, pois A é de dimensão n . Portanto, P_{Y^*} é singular em relação a medida λ^{n+1} e então não existe a função densidade (em relação a medida de Lebesgue) de Y^* no \mathbb{R}^{n+1} .

Para solucionar este problema defina o vetor $Y = (Y_1, Y_2, \dots, Y_n)$ de tal forma que $\sum_{i=1}^n Y_i < 1$ e $Y_{n+1} = 1 - \sum_{i=1}^n Y_i$. Neste caso, a medida P_Y induzida pelo vetor Y é dominada pela medida λ^n do \mathbb{R}^n e portanto podemos definir a função densidade de Y .

Através de transformações de variáveis não é difícil verificar que sua densidade é dada por

$$f(y_1, \dots, y_n) = K \prod_{i=1}^n y_i^{\alpha_i - 1} (1 - \sum_{i=1}^n y_i)^{\alpha_{n+1} - 1}.$$

onde K é uma constante.

Para diferenciar os dois vetores diremos que Y^* tem uma distribuição singular de Dirichlet e Y tem distribuição de Dirichlet. Observe que no caso de $n = 1$ a variável aleatória Y tem distribuição Beta.

Proposição 3.1 : Se Y tem distribuição de Dirichlet com parâmetro $(\alpha_1, \dots, \alpha_{n+1})$, então Y é estatisticamente independente de S .

Prova:

Fixado $\alpha_0 = (\alpha_1, \alpha_2, \dots, \alpha_{n+1})$, vamos mostrar que S é uma estatística suficiente e completa para β .

Como X_1, X_2, \dots, X_{n+1} são variáveis aleatórias Gamas independentes, sua densidade conjunta é dada por

$$g(x_1, x_2, \dots, x_{n+1}) = \beta^{\sum_{i=1}^{n+1} \alpha_i} \prod_{i=1}^{n+1} \frac{x_i^{\alpha_i-1}}{\Gamma(\alpha_i)} \exp\{-\beta \sum_{i=1}^{n+1} x_i\}.$$

Utilizando o Teorema da Fatoração, temos que S é suficiente para β .

É sabido que soma de Gamas independentes com igual parâmetro β , é também uma Gama. Portanto, S tem distribuição Gama(α, β) onde $\alpha = \sum_{i=1}^{n+1} \alpha_i$. Denotamos por $Q_{\alpha, \beta}$ a medida induzida por S .

Seja h uma função $\sigma(S)$ -mensurável tal que

$$\int_{\mathbb{R}^+} h dQ_{\alpha, \beta} = 0.$$

Temos que

$$\begin{aligned} \int_0^{\infty} h(u) \frac{\beta^\alpha}{\Gamma(\alpha)} e^{-\beta u} u^{\alpha-1} du = 0 & \Rightarrow \\ \Rightarrow \int_0^{\infty} k h^*(u) e^{-\beta u} du = 0, \end{aligned}$$

onde k é uma constante em relação a u e $h^*(u) = u^{\alpha-1} h(u)$. Pela unicidade da transformada de Laplace temos que

$$h^* = 0 \quad Q_{\alpha, \beta} - q.c. \quad \Rightarrow \quad h = 0 \quad Q_{\alpha, \beta} - q.c..$$

Portanto S é uma estatística completa.

Além disso, $(Y_1, Y_2, \dots, Y_n) = (\frac{X_1}{S}, \frac{X_2}{S}, \dots, \frac{X_n}{S})$ é invariante escala. Como β é um parâmetro escala (apêndice D), temos que (Y_1, \dots, Y_n) é ancilar para β . Finalmente, utilizando o Teorema de Basu 1 concluímos que S e (Y_1, \dots, Y_n) são estatisticamente independentes para todo α_0 .

Lembre que, pelo capítulo 2, a independência estatística é uma independência condicional. Logo, sob as hipóteses de que $X \perp\!\!\!\perp \beta \mid (S, \alpha)$, $Y \perp\!\!\!\perp \beta \mid \alpha$ e $S \not\perp\!\!\!\perp \beta \mid \alpha$, temos que $S \perp\!\!\!\perp (Y_1, \dots, Y_n) \mid (\alpha, \beta)$. Assim, S e (Y_1, \dots, Y_n) são estatisticamente independentes.

3.2. O RESULTADO DE DURBIN

O resultado apresentado por Durbin em 1961 e utilizado pelos estatísticos como Teorema de Durbin, se refere a um teste de aderência à distribuição Normal. Na ocasião, Durbin provou que para testar a aderência de um conjunto de observações independentes à distribuição $\text{Normal}(\mu, \sigma^2)$ basta testar a aderência de determinada transformação das observações a uma Normal padrão $[N(0, 1)]$. Como o objetivo é testar a normalidade, a técnica de Durbin é eliminar através de transformações de variáveis o parâmetro perturbador (μ, σ^2) . Durbin, utiliza-se de transformadas polares em sua prova, necessitando mostrar a independência entre cossenos e senos. Vamos refazer a prova do Teorema de Durbin utilizando os conceitos aqui trabalhados, em especial, o Teorema de Basu 1.

Teorema de Durbin: Seja $(\mathbb{R}^n, \mathcal{B}_n, \mathcal{P})$ um espaço estatístico onde, $\mathcal{P} = \{P_\theta : \theta = (\mu, \sigma^2) : \mu \in \mathbb{R}, \sigma^2 \in \mathbb{R}^+\}$ e P_θ tem medida de probabilidade Normal n -variada com covariância zero. Isto é, X_1, X_2, \dots, X_n são variáveis aleatórias estatisticamente independentes $N(\mu, \sigma^2)$.

Considere as seguintes estatísticas

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

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

Considere agora as variáveis aleatórias \bar{x} , com medida de probabilidade $N(0, \frac{1}{n})$ e, $(n-1)s^2$ com medida de probabilidade qui-quadrado com $(n-1)g.l.$. Observe que podemos pensar em \bar{x} e s^2 como sendo a média e a variância amostrais de n variáveis $N(0, 1)$.

Defina as variáveis x_1, x_2, \dots, x_n pela transformação

$$\frac{x_i - \bar{x}}{s} = \frac{X_i - \bar{X}}{S} \quad i = 1, 2, \dots, n.$$

Então, x_1, x_2, \dots, x_n são estatisticamente independentes com medida de probabilidade $N(0, 1)$.

Prova:

Parte I: Seja $W_{k-1} = (Z_1, Z_2, \dots, Z_{k-1})$, onde

$$Z_i = \frac{X_i - \bar{X}}{S} \quad i = 1, 2, \dots, n.$$

Claramente W_{k-1} é invariante em relação ao grupo

$$G = \{g_{a,b} : \mathbb{R}^n \rightarrow \mathbb{R}^n / g_{a,b}(x) = (\frac{x_1 - a}{b}, \dots, \frac{x_n - a}{b}), a \in \mathbb{R}, b > 0\}, k = 2, 3, \dots, n.$$

Logo, W_{k-1} é ancilar para (μ, σ^2) (Apêndice D).

Parte II: Vamos mostrar que (\bar{X}, S^2) é uma estatística suficiente e completa para (μ, σ^2) .

A função densidade conjunta das v.a. X_1, X_2, \dots, X_n é dada por

$$f(x_1, \dots, x_n) = (\sqrt{2\pi}\sigma)^{-n} \exp\left\{-\sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}\right\} =$$

$$\begin{aligned}
&= (\sqrt{2\pi}\sigma)^{-n} \exp\left\{-\left[\frac{\sum_{i=1}^n (x_i - \bar{X})^2 + n(\bar{X} - \mu)^2}{2\sigma^2}\right]\right\} = \\
&= (\sqrt{2\pi}\sigma)^{-n} \exp\left\{-\left[\frac{(n-1)S^2 + n(\bar{X} - \mu)^2}{2\sigma^2}\right]\right\}.
\end{aligned}$$

Utilizando o Teorema da Fatoração temos que (\bar{X}, S^2) é suficiente para (μ, σ^2) .

Para mostrar que a estatística é completa, vamos nos valer do conhecido fato que \bar{X} tem distribuição $N(\mu, \frac{\sigma^2}{n})$ e $Y = \frac{(n-1)S^2}{\sigma^2}$ tem distribuição qui-quadrado com $(n-1)$ graus de liberdade. Então, é possível encontrar a distribuição de $S^2 = \frac{\sigma^2}{(n-1)}Y$ que é,

$$g(y) = \frac{(n-1)((n-1)y)^{\frac{n-1}{2}-1}}{(2\sigma^2)^{\frac{n-1}{2}}\Gamma(\frac{n-1}{2})} \exp\left\{\frac{-(n-1)y}{2\sigma^2}\right\}.$$

Além disso, não é difícil mostrar, usando o Teorema de Basu 1, que \bar{X} e S^2 são estatisticamente independentes (ver exemplo 1.15). Portanto, a função densidade de (\bar{X}, S^2) é o produto das densidades de \bar{X} e S^2 .

Seja h uma função (\bar{X}, S^2) -mensurável, tal que $E[h] = 0$, então

$$\int_{-\infty}^{\infty} \int_0^{\infty} h(x, y) \left(\frac{n}{2\pi\sigma^2}\right)^{1/2} \exp\left\{\frac{-n(x-\mu)^2}{2\sigma^2}\right\} g(y) dy dx = 0.$$

Portanto,

$$\int_{-\infty}^{\infty} \int_0^{\infty} kh^*(x, y) \exp\left\{\frac{-n(x-\mu)^2 - (n-1)y}{2\sigma^2}\right\} dy dx = 0,$$

onde k é uma constante e $h^*(x, y) = h(x, y)[(n-1)y]^{\frac{n-1}{2}-1}$.

Considerando $u = (x - \mu)^2$ temos

$$\begin{aligned}
\int_{-\infty}^{\infty} h^*(x, y) \exp\left\{\frac{-n(x-\mu)^2}{2\sigma^2}\right\} dx &= 2 \int_0^{\infty} \frac{h^*(u, y) \exp\left\{\frac{-nu}{2\sigma^2}\right\}}{2\sqrt{u}} du = \\
&= \int_0^{\infty} h^{**}(u, y) \exp\left\{\frac{-nu}{2\sigma^2}\right\} du,
\end{aligned}$$

onde $h^{**}(u, y) = \frac{h^*(u, y)}{\sqrt{u}}$, para $u \neq 0$, e $h^{**}(u, y) = 0$, caso contrário. Logo,

$$\int_0^\infty \int_0^\infty kh^{**}(x, y) \exp\left\{\frac{-nu - (n-1)y}{2\sigma^2}\right\} dudy = 0.$$

Pela unicidade da transformada de Laplace $h^{**} = 0$ e portanto, $h = 0$.

Parte III: Dos resultados anteriores temos que W_{k-1} é ancilar, $k = 2, 3, \dots, n$ e, (\bar{X}, S^2) é suficiente e completa para (μ, σ^2) . Utilizando o Teorema de Basu 1 resulta que (\bar{X}, S^2) e W_{k-1} são estatisticamente independentes.

Além disso, W_{k-1} não depende de X_k e

$$Z_k = \frac{X_k - \bar{X}}{S}.$$

Segue que, W_{k-1} é estatisticamente independente de Z_k , para todo valor de k . Logo, Z_1, Z_2, \dots, Z_n são estatisticamente independentes.

Parte IV: Por definição

$$x_i = Z_i s + \bar{x}.$$

Observando-se s e \bar{x} , x_i é uma função linear de Z_i , $i = 1, \dots, n$. Portanto, os x_i 's são também estatisticamente independentes entre si. Além disso, por construção, são identicamente distribuídas.

Parte V : Observe que

$$\sum_{i=1}^n a_i x_i = \bar{x} \sum_{i=1}^n a_i,$$

onde \bar{x} tem distribuição $N(0, \frac{1}{n})$. Portanto, para toda sequência de reais a_i 's, temos que $\sum_{i=1}^n a_i x_i$ tem distribuição Normal. Logo, cada x_i tem distribuição Normal.

Considere $a_i = 1, \forall i$. Temos que $\sum_{i=1}^n x_i$ é $N(0, n)$. Logo, cada x_i é $N(0, 1)$. \diamond

APÊNDICE A : CONCEITOS BÁSICOS DE TEORIA DA MEDIDA

Nesta seção apresentaremos algumas definições, usuais na Teoria da Medida, que foram utilizadas no decorrer do trabalho. É interessante que o leitor tenha certa familiaridade com tais conceitos, o que poderá ser facilmente adquirido num curso básico de Teoria da Medida ou, num livro da área.

Definição A.1 : Seja \mathcal{X} um conjunto qualquer . Uma classe \mathcal{A} , de subconjuntos de \mathcal{X} , é uma sigma álgebra (σ -álgebra) se satisfaz,

$$i) \mathcal{X} \in \mathcal{A},$$

$$ii) A \in \mathcal{A} \Rightarrow A^c \in \mathcal{A},$$

$$iii) (A_n)_{n \geq 1} \in \mathcal{A} \Rightarrow \bigcup_{n=1}^{\infty} A_n \in \mathcal{A}.$$

A dupla $(\mathcal{X}, \mathcal{A})$ é chamada espaço mensurável.

Será denotada por $\sigma(A)$ a sigma álgebra gerada pelo conjunto A ($A \subset \mathcal{X}$), que é a menor sigma álgebra que contém A , isto é, se existe outra σ -álgebra \mathcal{A}^* tal que $A \in \mathcal{A}^*$, então $\sigma(A) \subset \mathcal{A}^*$.

Definição A.2 : Se F é a classe de todos os abertos de \mathcal{X} , então $\sigma(F)$ é denominada sigma álgebra de Borel e seus elementos de borelianos. Em particular, se $\mathcal{X} = \mathbb{R}$, então F é o conjunto dos intervalos abertos e utilizamos a notação $\mathcal{B} = \sigma(F)$. Além disso, utilizaremos a notação \mathcal{B}_n para os borelianos do \mathbb{R}^n .

Definição A.3 : Seja $(\mathcal{X}, \mathcal{A})$ um espaço mensurável. Uma função μ de \mathcal{A} em $\overline{\mathbb{R}} = \mathbb{R} \cup \{-\infty, +\infty\}$ é uma medida em $(\mathcal{X}, \mathcal{A})$, se satisfaz,

i) $\mu(\emptyset) = 0$,

ii) se $(A_n)_{n \leq 1}$ é uma sequência disjunta de elementos de \mathcal{A} , então

$$\mu\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} \mu(A_n).$$

Definição A.4 : Uma medida μ em $(\mathcal{X}, \mathcal{A})$ é σ -finita se existe uma sequência $(A_n)_{n \geq 1} \in \mathcal{A}$, tal que $\mathcal{X} = \bigcup_{n=1}^{\infty} A_n$ e $\mu(A_n) < \infty, \forall n \in \mathbb{N}$. Se $\mu(\mathcal{X}) < \infty$, então μ é finita.

Se μ for σ -finita (finita) diremos que $(\mathcal{X}, \mathcal{A}, \mu)$ é um espaço σ -finito (finito) .

Definição A.5 : Considerando o espaço mensurável $(\mathbb{R}, \mathcal{B})$ a medida λ , neste espaço, que satisfaz $\lambda[(a, b)] = b - a, \forall a, b \in \mathbb{R}$, é chamada de medida de Lebesgue.

Definição A.6 Uma relação \sim é válida essencialmente com respeito a uma medida μ se, $\mu(\{x \in \mathcal{X}, \text{talque, } \sim \text{ não ocorre } \}) = 0$. Em particular, se a relação for de igualdade, diremos que A e B são iguais essencialmente se $\mu(\{x \in \mathcal{X} : A \neq B\}) = 0$. A notação adotada será $A = B \mu - q.c..$

Se $\mathcal{M} = \{\mu_\theta : \theta \in \Theta\}$ é uma família de medidas, a relação \sim é \mathcal{M} essencialmente válida se $\mu_\theta(\{x \in \mathcal{X} \text{ talque } \sim \text{ não ocorre } \}) = 0, \forall \mu_\theta \in \mathcal{M}$. No caso da relação ser de

igualdade temos que se $\mu_\theta(\{x \in \mathcal{X} : A \neq B\}) = 0, \forall \mu_\theta \in \mathcal{M}$, então $A = B$ \mathcal{M} -q.c. (\mathcal{M} essencialmente).

APÊNDICE B : SISTEMAS DYNKIN

Em várias provas, no decorrer deste trabalho, utilizamos o recurso de mostrar que uma classe de subconjuntos era um D - sistema, e após utilizar o Teorema sobre sistemas Dynkin. Nesta seção, vamos apresentar e provar este teorema.

Definição B.1: Uma classe \mathcal{D} de subconjuntos de \mathcal{X} é um D-sistema ou sistema Dynkin, se as seguintes condições são válidas,

- (i) $\mathcal{X} \in \mathcal{D}$,
- (ii) se $A, B \in \mathcal{D}$ com $B \subset A$, então $A - B \in \mathcal{D}$,
- (iii) se $(A_n)_{n \geq 1} \in \mathcal{D}$ e $\lim_{n \rightarrow \infty} A_n = A$, então $A \in \mathcal{D}$.

Teorema B.1: Seja \mathcal{L} uma classe de subconjuntos de \mathcal{X} fechada por intersecções finitas. Se \mathcal{D} é um D-sistema e $\mathcal{L} \subset \mathcal{D}$, então $\sigma(\mathcal{L}) \subset \mathcal{D}$.

Prova: Seja \mathcal{D}_0 o menor D-sistema que contém \mathcal{L} . Vamos mostrar que $\sigma(\mathcal{L}) = \mathcal{D}_0$. Assim, fica provado o teorema.

Como $\sigma(\mathcal{L})$ é uma sigma álgebra ela é um D-sistema. Portanto, $\mathcal{D}_0 \subset \sigma(\mathcal{L})$. (B.1)

Seja $\mathcal{A} = \{A \in \mathcal{D}_0 : A \cap B \in \mathcal{D}_0, \forall B \in \mathcal{L}\}$. Como, \mathcal{L} é fechado por intersecções finitas temos que

$$A \in \mathcal{L} \Rightarrow A \cap B \in \mathcal{L}, \quad \forall B \in \mathcal{L}.$$

Mas,

$$\mathcal{L} \subset \mathcal{D}_0 \Rightarrow A \cap B \in \mathcal{D}_0 \Rightarrow A \in \mathcal{A}.$$

Logo $\mathcal{L} \subset \mathcal{A}$. Não é difícil verificar que \mathcal{A} é um D-sistema. Portanto, $\mathcal{D}_0 \subset \mathcal{A} \Rightarrow \mathcal{D}_0 = \mathcal{A}$.

Seja $\mathcal{A}^* = \{A \in \mathcal{D}_0 : A \cap B \in \mathcal{D}_0, \forall B \in \mathcal{D}_0\}$, então

$$A \in \mathcal{L} \Rightarrow A \cap B \in \mathcal{D}_0, \forall B \in \mathcal{A} = \mathcal{D}_0 \Rightarrow A \in \mathcal{A}^* \Rightarrow \mathcal{L} \subset \mathcal{A}^*.$$

Como \mathcal{A}^* é um D-sistema, temos que $\mathcal{D}_0 \subset \mathcal{A}^* \Rightarrow \mathcal{D}_0 = \mathcal{A}^*$. Portanto, \mathcal{D}_0 é uma sigma álgebra, pois é fechada por intersecções finitas. Logo, $\sigma(\mathcal{L}) \subset \mathcal{D}_0$ (B.2)

De (B.1) e (B.2) concluímos que $\sigma(\mathcal{L}) = \mathcal{D}_0$. \diamond

APÊNDICE C : FAMÍLIAS DOMINADAS

A intenção desta unidade é provar o fato, muito usado no decorrer da dissertação, de que para toda família de medidas dominada \mathcal{P} , existe uma família $\mathcal{P}_0 \subset \mathcal{P}$ enumerável, tal que $\mathcal{P} \equiv \mathcal{P}_0$. Para tal, necessitamos antes de alguns lemas.

Lema C.1: Seja $(\mathcal{X}, \mathcal{A}, \lambda)$ um espaço de medida sigma finito. Vamos considerar uma ordenação parcial \subset_λ , de modo que $A \subset_\lambda B$ se $\lambda(A \cap B^c) = 0$. Nesta condições, toda coleção \mathcal{L} de conjuntos de \mathcal{A} , fechada por uniões enumeráveis, tem um elemento máximo segundo esta ordenação. Isto é, existe $A_0 \in \mathcal{L}$ tal que $A \subset_\lambda A_0, \forall A \in \mathcal{L}$.

Prova:

Parte I - Vamos assumir que λ é uma probabilidade.

O conjunto $\{\lambda(A) : A \in \mathcal{L}\}$ é limitado e portanto, existe $\alpha = \sup_{A \in \mathcal{L}} \lambda(A)$. Além disso, $\forall n \in \mathbb{N}$, existe um $A_n \in \mathcal{L}$ tal que,

$$\lambda(A_n) > \alpha - \frac{1}{n}.$$

Seja $A_0 = \bigcup_{n=1}^{\infty} A_n$. Por hipótese, \mathcal{L} é fechada por uniões enumeráveis, então $A_0 \in \mathcal{L}$ e ainda

$$\alpha - \frac{1}{n} < \lambda(A_0) \leq \alpha \quad \forall n \in \mathbb{N}.$$

Fazendo $n \rightarrow \infty$, temos que $\lambda(A_0) = \alpha$.

Considere $A \in \mathcal{A}$, é possível escrever

$$A \cup A_0 = A_0 \cup (A \cap A_0^c),$$

e então

$$\alpha \geq \lambda(A \cup A_0) = \lambda(A_0) + \lambda(A \cap A_0^c) = \alpha + \lambda(A \cap A_0^c).$$

Portanto, $\lambda(A \cap A_0^c) = 0$ o que implica que $A \subset_{\lambda} A_0$. Logo, A_0 é o elemento máximo de \mathcal{L} segundo esta ordenação.

Parte II - Vamos considerar agora λ sendo apenas uma medida sigma finita.

Seja $(B_n)_{n \geq 1}$ uma partição de \mathcal{X} , tal que $\lambda(B_n) < \infty, \forall n \in \mathbb{N}$.

Defina,

$$\lambda_n(A) = \frac{\lambda(A \cap B_n)}{\lambda(B_n)} \quad \forall n \in \mathbb{N}, \quad \forall A \in \mathcal{A}.$$

É fácil verificar que λ_n é uma medida de probabilidade. Considere agora uma outra probabilidade que não depende de n ,

$$\lambda^* = \sum_{n=1}^{\infty} \frac{1}{2^n} \lambda_n.$$

Observe que $\lambda \equiv \lambda^*$. É claro que as ordenações C_{λ} e C_{λ^*} são equivalentes. Portanto, se existe um elemento máximo em C_{λ} também existe em C_{λ^*} . \diamond

Lema C.2: Se \mathcal{P} é dominada por uma medida sigma finita λ e fechada por combinações convexas enumeráveis, então \mathcal{P} é auto dominada. Isto é, existe $P_0 \in \mathcal{P}$, tal que $\mathcal{P} \ll P_0$.

Prova: Considere

$$\mathcal{L} = \{A \in \mathcal{A} : \lambda(A) > 0 \text{ e existe } \theta \in \Theta \text{ t.q. } \forall x \in A, \frac{dP_{\theta}}{d\lambda}(x) > 0 \text{ } \lambda - q.c.\}.$$

Parte I - Vamos mostrar que \mathcal{L} é fechada por uniões enumeráveis.

Seja $A = \bigcup_{n=1}^{\infty} A_n$, onde $A_n \in \mathcal{L}$ e P_{θ_n} é a probabilidade associada a $A_n \quad \forall n \in \mathbb{N}$.

Considere

$$P = \sum_{n=1}^{\infty} a_n P_{\theta_n},$$

onde $\sum_{n=1}^{\infty} a_n = 1$, de modo que P é uma probabilidade. Então,

$$\frac{dP}{d\lambda} = \sum_{n=1}^{\infty} a_n \frac{dP_{\theta_n}}{d\lambda}.$$

Se $x \in A$, então $\frac{dP}{d\lambda}(x) > 0 \quad \lambda - q.c.$ Além disso, por hipótese \mathcal{P} é fechada por combinações convexas, então $P \in \mathcal{P}$. Portanto, $A \in \mathcal{L}$.

Parte II - Pela parte I e o Lema C.1 concluímos que, existe um A_0 máximo em \mathcal{L} .

Vamos mostrar que $P_{\theta}(A_0^c) = 0, \quad \forall \theta \in \Theta$.

Suponha que a afirmação não seja válida. Então, existe $\theta_1 \in \Theta$ tal que $P_{\theta_1}(A_0^c) > 0$.

Considere $B = \{x \in A_0^c : \frac{dP_{\theta_1}}{d\lambda}(x) > 0\}$. Então,

$$0 < P_{\theta_1}(A_0^c) = P_{\theta_1}(B) + P_{\theta_1}(A_0^c \cap B^c).$$

Além disso,

$$P_{\theta_1}(A_0^c \cap B^c) = \int_{A_0^c \cap B^c} \left(\frac{dP_{\theta_1}}{d\lambda} \right) d\lambda \leq 0.$$

Portanto, $P_{\theta_1}(B) > 0 \Rightarrow \lambda(B) > 0$. Como $B \subset A_0^c$, então $\lambda(B \cap A_0^c) > 0$. O que contradiz o fato de A_0 ser o máximo.

Parte III - Finalmente, vamos mostrar que $\mathcal{P} \ll P_{\theta_0}$, onde P_{θ_0} está associada a A_0 .

Considere $N \in \mathcal{A}$ tal que $P_{\theta_0}(N) = 0$. Temos que

$$P_{\theta_0}(N) \geq P_{\theta_0}(N \cap A_0) = \int_{N \cap A_0} \frac{dP_{\theta_0}}{d\lambda} d\lambda.$$

Portanto, $\int_{N \cap A_0} \frac{dP_{\theta_0}}{d\lambda} d\lambda = 0$.

Mas, $x \in A_0 \Rightarrow \frac{dP_{\theta_0}}{d\lambda}(x) > 0 \lambda - q.c..$ e portanto,

$$\lambda(N \cap A_0) = 0 \Rightarrow P_{\theta}(N \cap A_0) = 0 \quad \forall \theta \in \Theta.$$

Utilizando a parte II temos que $P_{\theta}(N \cap A_0^c) = 0, \forall \theta \in \Theta.$

Logo,

$$P_{\theta}(N) = P_{\theta}(N \cap A_0) + P_{\theta}(N \cap A_0^c) = 0 \quad \forall \theta \in \Theta. \quad \diamond$$

Teorema C.1: Se \mathcal{P} é dominada, então existe uma subfamília $\mathcal{P}_0 = \{P_1, P_2, P_3, \dots\}$ enumerável, tal que $\mathcal{P} \equiv \mathcal{P}_0.$

Prova: Considere uma família \mathcal{P}^* , de modo que se $Q \in \mathcal{P}^*$, então existem $P_{\theta_1}, P_{\theta_2}, \dots \in \mathcal{P}$ e $a_1, a_2, \dots \in \mathbb{R}^+$, com $\sum_{n=1}^{\infty} a_n = 1$, onde $Q = \sum_{n=1}^{\infty} a_n P_{\theta_n}$. Isto é, \mathcal{P}^* é a família das combinações convexas das medidas de \mathcal{P} . Observe que $\mathcal{P} \subset \mathcal{P}^*$.

Como \mathcal{P} é dominada, existe uma medida sigma finita λ , tal que $P_{\theta} \ll \lambda, \forall \theta \in \Theta$ e então $Q \ll \lambda, \forall Q \in \mathcal{P}^*$. Logo, $\mathcal{P}^* \ll \lambda$. Além disso, \mathcal{P}^* é fechada por combinações convexas enumeráveis e pelo Lema C.2, \mathcal{P}^* é auto dominada. Logo, existe um $Q_0 \in \mathcal{P}^*$ tal que $\mathcal{P}^* \ll Q_0$, onde $Q_0 = \sum_{n=1}^{\infty} a_n P_n$, com $\sum_{n=1}^{\infty} a_n = 1$ e $P_n \in \mathcal{P}, \forall n$. Portanto, $\mathcal{P} \ll Q_0$ pois $\mathcal{P} \subset \mathcal{P}^*$.

Considere $\mathcal{P}_0 = \{P_1, P_2, \dots\}$, onde P_1, P_2, \dots , são as componentes da medida Q_0 . Então, $\mathcal{P} \ll \mathcal{P}_0$. Por outro lado, seja $N \in \mathcal{A}$ tal que $P_{\theta}(N) = 0, \forall \theta \in \Theta$, então $P_n(N) = 0, \forall P_n \in \mathcal{P}_0$. Portanto, $\mathcal{P}_0 \ll \mathcal{P}$ e então $\mathcal{P}_0 \equiv \mathcal{P}$. \(\diamond\)

APÊNDICE D: ANCILARIDADE E INVARIÂNCIA

Nesta seção apresentaremos um resultado de grande importância na Teoria Estatística. Através do Teorema D.1. é possível determinar se uma estatística é ancilar sem ser necessário recorrer a sua função densidade, bastando analisar seu comportamento como

função das observações. Este resultado facilita muito o trabalho, pois na maioria das vezes não é fácil encontrar a medida de probabilidade de determinada estatística.

Definição D.1: Considere o espaço $(\mathbb{R}^n, \mathcal{B}_n, \mathcal{P})$, com $\mathcal{P} = \{P_{\mu, \sigma} : \mu \in \mathbb{R}, \sigma \in \mathbb{R}^+\}$ onde

$$P_{\mu, \sigma}(B) = \int_B \frac{1}{\sigma^n} f\left(\frac{x_1 - \mu}{\sigma}, \dots, \frac{x_n - \mu}{\sigma}\right) d\lambda^n(x) \quad \forall B \in \mathcal{B}_n$$

e λ^n é a medida de Lebesgue do \mathbb{R}^n . Nestas condições, dizemos que μ é um parâmetro de locação e σ um parâmetro escala.

Definição D.2: A estatística T é invariante em relação a um grupo G se

$$T(g(x)) = T(x), \quad \forall g \in G, \quad \forall x \in \mathbb{R}^n.$$

Considerando o grupo G como

$$G = \{g_{a,b} : \mathbb{R}^n \rightarrow \mathbb{R}^n, \text{ t.q., } g_{a,b}(x) = \left(\frac{x_1 - a}{b}, \dots, \frac{x_n - a}{b}\right), a \in \mathbb{R}, b \in \mathbb{R}^+\}.$$

O seguinte resultado é válido.

Teorema D.1: Se T é invariante sob o grupo G , então T é ancilar em relação aos parâmetros de locação e escala. Isto é, a medida induzida por T é livre de (μ, σ) .

Prova: Sejam $B \in \mathcal{B}$ e Q a probabilidade induzida pela estatística T , então

$$\begin{aligned} Q(B) &= P_{\mu, \sigma}(T^{-1}(B)) = \int_{T^{-1}(B)} \frac{1}{\sigma^n} f\left(\frac{x_1 - \mu}{\sigma}, \dots, \frac{x_n - \mu}{\sigma}\right) d\lambda(x) = \\ &= \int_{T^{-1}(B)} \frac{1}{\sigma^n} f \circ g_{\mu, \sigma}(x) d\lambda(x) = \\ &= \int_{(T \circ g_{\mu, \sigma})^{-1}(B)} \frac{1}{\sigma^n} f \circ g_{\mu, \sigma}(x) d\lambda(x) = \int_{g_{\mu, \sigma}^{-1}(T^{-1}(B))} \frac{1}{\sigma^n} f \circ g_{\mu, \sigma}(x) d\lambda(x) = \end{aligned}$$

$$\begin{aligned}
&= \int_{T^{-1}(B)} \frac{1}{\sigma^n} f(x) d\lambda_{\mu, \sigma}^{-1}(x) = \int_{T^{-1}(B)} \frac{1}{\sigma^n} f(x) d\lambda(\sigma x_1 + \mu, \dots, \sigma x_n + \mu) = \\
&= \int_{T^{-1}(B)} \frac{1}{\sigma^n} f(x) \sigma^n d\lambda(x) = \int_{T^{-1}(B)} f(x) d\lambda(x)
\end{aligned}$$

Portanto, $Q(B)$ não depende de (μ, σ) . ◇

Corolário D.1 : Se T é invariante em relação ao grupo

$$G_1 = \{g_a : \mathbb{R}^n \rightarrow \mathbb{R}, t.q., g_a(x) = (x_1 - a, \dots, x_n - a), a \in \mathbb{R}\},$$

então T é ancilar em relação ao parâmetro locação.

Corolário D.2: Se T é invariante em relação ao grupo

$$G_2 = \{g_b : \mathbb{R}^n \rightarrow \mathbb{R}, t.q., g_b(x) = (\frac{x_1}{b}, \dots, \frac{x_n}{b}), b \in \mathbb{R}^+\},$$

então T é ancilar em relação ao parâmetro escala.

REFERÊNCIAS BIBLIOGRÁFICAS

- ASH, R.B. (1972) . *Real Analysis and Probability* . New York : Academic Press.
- BAHADUR, R.R. (1955) . Statistics and subfields. *Ann.Math.Statist.*, **26**: 490-497.
- BASU, D (1955). On statistics independent of a complete sufficient statistics. *Sankhyã* ,
15 : 377 - 380 .
- BASU, D. (1958) . On statistics independent of sufficient statistics. *Sankhyã* , **20**:
223-226 .
- BASU, D. (1959) . The family of ancillary statistics . *Sankhyã* , **21** : 247-256 .
- BASU, D. (1964) . Recovery of ancillary information . *Sankhyã* , **A, 26** : 3 - 16 .
- BASU, D. (1975) . Statistical information and likelihood . *Sankhyã* , **A, 37** : 1 - 71 .
- BASU, D. (1982) - Basu theorems . *Encyclopedia of statistical sciences*, 1, 193-196,
New York : Wiley.
- BASU, D. and GHOSH, J.K. (1967) . Sufficient statistics in sampling from a finite universe.
Bull.Int.Statist.Inst. , **42** : 850 - 859 .
- BASU, D. and TIWARI, R.C. (1980) . *Note on Dirichlet process*. Tallahassee, FSU,
29p. (FSU Statistics Report ,M.536) .
- BASU, D. and CHENG, S.C. (1981) . A note on sufficiency in coherent models . *Int.J.*
Math.Math.Sci., **4 (3)** : 571-582.
- BURKHOLDER, D.L. (1961) . Sufficiency in the undominated case . *Ann.Math.Statist.*,
32 : 1191 - 1200 .
- DAWID, A.P. (1979a) . Conditional independence in statistical theory . *J.Royal Statist.*
Soc., **B, 41** : 1 - 31 .
- DAWID, A. P. (1979b) . Some misleading arguments involving conditional independence.
J.Royal Statist.Soc. , **B, 41** : 249 - 252 .
- DURBIN, J. (1961) . Some methods of constructing exact tests . *Biometrika*, **48**:
41 - 55 .

- HALMOS, P. (1970) . *Measure theory - graduate texts in mathematics* . New York: Springer.
- HALMOS, P. and SAVAGE, L.J. (1949). Application of the Randon-Nikodym theorem to the theory of sufficient statistics . *Ann.Math. Statist.* , **20** : 225 - 241 .
- HASEGAWA, M. and PERLMAN, M.D. (1974) . On the existence of minimal sufficient subfield . *The Ann. of Statist.*, **2** (5) : 1049 - 1055 .
- KOEHN, U. and THOMAS, D.L. (1975). On statistics independent of sufficient statistic: Basu's Lemma . *The Amer. Statist.* **29** : 40 - 42 .
- LEHMANN, E. (1981) . An interpretation of completeness and Basu's theorem . *J. Amer.Statist. Ass.* , **76** (374) : 335 - 340 .
- LEHMANN, E. and SCHEFFÉ, H. (1950) . Completeness, similar regions, and unbiased estimation . *Sankhyã*, **10** : 305 - 840 .
- PATHAK, P.K. (1975) . *Note on Basu's lemma* . New Mexico, UNM, 5 p. (Technical Report, 308).
- PAULINO, C.D. (1988) . *Análise de dados categorizados incompletos: fundamentos, métodos e aplicações* . Tese de doutoramento , Universidade de São Paulo.
- PEREIRA, C.A. (1980). *Bayesian solutions to some classical problemas of statistics* . PhD Thesis Florida State University.
- PEREIRA, C.A. (1983) . Conditional independence in statistics. *Sankhyã* , **A**, **45**: 324 - 337.
- PICCI, G. (1974) . *Theory of sufficient statistics and structure analysis of transition probabilities with applications to identifiability* . Padova, LASEB - CNR , 50 p. (CCNRLASEB, 06/74).