

COMPONENTES DE VARIÂNCIA

- O PROBLEMA DE ESTIMATIVAS NEGATIVAS -

ROBERTO CLÁUDIO FROTA BEZERRA

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

ORIENTADOR:

PROF. DR. CLÓVIS DE ARAUJO PERES

- SÃO PAULO, JUNHO DE 1976 -

Aos meus pais PRISCO e TACILA  
o agradecimento maior

À minha mulher MARIA DAS GRAÇAS  
e aos meus filhos  
PRISCO e ROBERTO CLÁUDIO

## AGRADECIMENTOS

Várias pessoas contribuíram numa etapa de minha formação acadêmica, que culminou com essa dissertação. Destaco,

- o Prof. Dr. Clóvis de Araujo Peres, do Instituto de Matemática e Estatística da Universidade de São Paulo (IME-USP), não só por ser meu orientador e pela pessoa humana que é, mas também pela constante orientação estatística, mesmo fora deste trabalho;
- o Prof. Carlos Alberto de Bragança Pereira, do IME-USP pelo estímulo, ajuda e amizade constante;
- o Prof. Dr. Carlos Alberto Barbosa Dantas, do IME.USP, pioneiro na formação de pós-graduados em Estatística no Brasil, que me convenceu a procurar ser mais um iniciado em Estatística;
- os Profs. Mateus Mosca Vianna e Antonio Clécio Fonteles Thomas, da Universidade Federal do Ceará (UFC), pela execução de toda a parte numérica e computacional deste trabalho;
- o Prof. José Jackson Lima Albuquerque, da UFC, por ter sido meu primeiro mestre e orientador na área de Estatística;
- o Sr. João Baptista Esteves de Oliveira, do IME-USP, responsável final pela forma gráfica deste trabalho.

## INDICE

INTRODUÇÃO . . . . .	1
CAP. 1 - SOBRE A ESTIMAÇÃO DE COMPONENTES DE VARIÂNCIA. . . . .	5
1.1 - Dados Balanceados . . . . .	5
1.2 - Dados Não-Balanceados . . . . .	8
1.3 - O Problema de Estimativas Negativas . . . . .	13
CAP. 2 - ESTIMAÇÃO QUADRÁTICA NÃO VICIADA E NÃO NEGATI- VA DE COMPONENTES DE VARIÂNCIA . . . . .	19
2.1 - O Modelo Geral . . . . .	19
2.2 - Condições para Estimabilidade Não Viciada e Não Negativa . . . . .	21
2.3 - Consequências e Aplicações . . . . .	23
2.4 - Estimação Quadrática Não Viciada de $(\sigma^2_\alpha, \sigma^2_\epsilon)$ num Modelo Aleatório Simples - Um Exemplo . . . . .	30
CAP.3 - INFERÊNCIA BAYESIANA DE COMPONENTES DE VARIÂN- CIA . . . . .	38
3.1 - A Idéia de Inferência Bayesiana . . . . .	38
3.2 - Inferência Bayesiana de Componentes de Va- riância num Modelo Aleatório Simples . . . . .	41
3.2.1 - O Modelo . . . . .	41
3.2.2 - A Função de Verossimilhança . . . . .	43
3.2.3 - A Distribuição "a priori" Não Informati- va . . . . .	44
3.2.4 - As Distribuições "a posteriori" . . . . .	46
3.2.5 - Os Estimadores de Bayes . . . . .	50
3.3 - Um Exemplo . . . . .	51
APÊNDICES . . . . .	56
A - A Priori Não Informativa . . . . .	56
B - A Distribuição $\chi^2$ . . . . .	62
C - Um "Programa" para encontrar "a posteriori" de $\sigma^2_\alpha$ . . . . .	64
REFERÊNCIAS BIBLIOGRÁFICAS . . . . .	67

## INTRODUÇÃO

Desde a sua introdução por Sir Ronald A. Fisher, a Análise de Variância tem sido largamente usada para testar a significância de efeitos de tratamentos, ou melhor dizendo, para testar a existência de diferenças entre médias de tratamentos, e a maior parte dos usuários da Estatística, a tem como uma técnica específica para este objetivo. No entanto, os problemas resolvidos pela Análise de Variância são um pouco mais gerais. Entre esses problemas destacamos a estimação de *componentes de variância*, que aqui serão caracterizados.

Para uma melhor compreensão do exposto acima, vamos considerar a técnica da Análise de Variância na solução de dois tipos de problemas.

O primeiro é aquele no qual estamos interessados em testar a significância de efeitos de um número fixo de tratamentos, ou então, estimar esses efeitos. Esse é o problema tradicional e é resolvido a partir de um modelo, que na sua forma mais simples, recebe na literatura a denominação de *modelo fixo com um fator*, e é representado por

$$y_{ij} = \mu + \alpha_i + e_{ij},$$

onde  $y_{ij}$  é a  $j$ -ésima observação do  $i$ -ésimo tratamento,  $\mu$  é a média geral,  $\alpha_i$  é o efeito do tratamento  $i$ ,  $e_{ij}$  é o termo (aleatório) do erro correspondente à  $(ij)$ -ésima observação.

Estimação e Testes de Hipóteses são feitos sobre esse modelo, usando além da suposição básica de que os  $e_{ij}$  são independentes e identicamente distribuídos (i.i.d) com  $N(0, \sigma_e^2)$ , a restrição

$$\sum_i \alpha_i = 0,$$

para que os efeitos  $\alpha_i$  possam ser funções estimáveis.

No segundo problema, menos conhecido, temos representado no experimento, não mais todos os níveis do fator (tratamento), mas sim apenas uma amostra de níveis do fator. Essa modificação de situação torna  $\alpha_i$  um efeito aleatório, e a partir do modelo visto acima teríamos  $y_{ij}$  e  $\mu$  caracterizados como anteriormente e mais  $E(\alpha_i) = 0$ ,  $\text{var}(\alpha_i) = \sigma_\alpha^2$ ,  $E(e_{ij}) = 0$ ,  $\text{var}(e_{ij}) = \sigma_e^2$ ,  $E(\alpha_i \alpha_k) = 0$  ( $i \neq k$ ) e  $E(\alpha_i e_{i'j'}) = 0 \forall i, i'$  e  $j'$ . Com isto obteríamos:

$$\text{var}(y_{ij}) = \sigma_\alpha^2 + \sigma_e^2$$

advindo daí a origem da terminologia *componentes de variância*. Neste segundo problema o nosso interesse é o de estimar as variâncias  $\sigma_\alpha^2$  e  $\sigma_e^2$ . Com as características aqui discutidas, o modelo visto anteriormente, na literatura recebe a denominação geral de *modelo aleatório com um fator*. As inferências a serem feitas sobre o modelo, ou melhor dizendo, sobre os componentes de variância, exigiriam que a variável aleatória  $\alpha_i$  fosse i.i.d. com  $N(0, \sigma_\alpha^2)$  e  $e_{ij}$  fosse i.i.d. com  $N(0, \sigma_e^2)$ .

Com o objetivo de motivar o uso de componentes de variância discutiremos a situação abaixo.

Considere a situação em que temos uma amostra de  $m$  sacos de lã, selecionados de uma grande população de sacos. De cada um desses sacos de lã, que farão parte do experimen

to, selecionamos  $n$  amostras que irão constituir as repetições. Suponha ainda que a nossa variável de interesse seja a resistência ao rompimento, codificada de acordo com certos requisitos técnicos. O nosso problema é decompor a variabilidade (medida em termos de variância) da variável observada, em dois componentes, um devido à diferença entre sacos ( $\sigma_{\alpha}^2$ ) e o outro devido à diferença entre as amostras dentro do saco ( $\sigma_{\epsilon}^2$ ). Esse problema é resolvido quando estimamos os componentes de variância associados ao modelo aleatório simples.

Uma outra aplicação de componentes de variância é no campo da Genética, quando estamos interessados em decompor a variância de um caráter, medida num ser vivo, em componentes de variância genética e ambiental.

Nesta monografia temos por objetivo precípua, discutir um *problema* que acompanha a estimação de componentes de variância, que é o de encontrarmos em certas ocasiões, estimativas negativas desses componentes. A discussão desse problema foi dividida em três etapas, correspondendo cada uma a um Capítulo.

No Capítulo 1 fazemos uma abordagem bem elementar sobre a estimação de componentes de variância, levando o leitor a tomar contato, de uma maneira bem informal, com o *problema de estimativas negativas*.

No Capítulo 2 trabalhando com a classe de estimadores quadráticos e não viciados dos componentes de variância, procuramos discutir as condições de estimação não negativa desses componentes, e encerramos com a resolução comentada de um exemplo bem simples, procurando tornar mais inteligíveis as idéias lá discutidas.



No Capítulo 3 abordamos o problema de estimativas negativas de uma maneira diferente, buscando uma solução através da Inferência Bayesiana. Encerramos o Capítulo com a resolução de um exemplo, que no seu desenrolar, por envolver integrais de funções não muito simples, necessita de técnicas de integração numérica, que foram utilizadas, com o auxílio do computador. Essa particularidade, serve para enfatizar, a importância do computador na solução de certos problemas através da Inferência Bayesiana.

Além desses três Capítulos, são apresentados três Apêndices, com o objetivo de clarificar ou complementar algumas passagens existentes no corpo principal dessa monografia.

Uma explicação que devemos aos eventuais leitores desse trabalho, é a de que a introdução de certos neologismos como estimabilidade, bayesiano, bayesianismo, etc., deveu-se à falta de expressões correspondentes na nossa língua.

## CAPÍTULO 1

### SOBRE A ESTIMAÇÃO DE COMPONENTES DE VARIÂNCIA

Neste capítulo discorreremos de uma maneira tão sucinta quanto possível, sobre os métodos de estimação de componentes de variância, que produzem estimativas negativas desses componentes e, enfecharemos com algumas idéias de como contornar ou resolver este problema. Com o intuito de tornar mais claro o assunto, dividimos o capítulo em três seções; nas duas primeiras falamos sobre a estimação de componentes de variância em dados balanceados e não balanceados e, na terceira abordamos o problema das estimativas negativas.

#### 1.1 - DADOS BALANCEADOS

Suponha a seguinte situação

CLASSES	I	II	III	IV
	19	25	20	30
OBSERVAÇÕES	17	5	18	5
	15	15	14	10
	13	10	10	15

Suponha ainda que os dados acima seguem o modelo abaixo

$$y_{ij} = \mu + \alpha_i + e_{ij}, \quad i=1, \dots, 4 \quad j=1, \dots, 4 \quad (1.1.1)$$

onde  $\mu$  é o efeito médio verdadeiro,  $\alpha_i$  é um efeito aleatório com  $E(\alpha_i) = 0$ ,  $\text{var}(\alpha_i) = \sigma_\alpha^2$  e  $\text{covar}(\alpha_i, \alpha_{i'}) = 0$  ( $i \neq i'$ ),  $e_{ij}$  é o termo usual do erro, que também é aleatório com  $E(e_{ij}) = 0$ ,  $\text{var}(e_{ij}) = \sigma_e^2$  e covariâncias entre seus termos e, entre seus termos e  $\alpha_i$ , todas supostas iguais a zero. Vale ressaltar que os efeitos aleatórios  $\alpha_i$  e  $e_{ij}$  tem significados diferentes no modelo, pois  $\alpha_i$  é um efeito que aparece pela introdução de um fator. O modelo recebe a denominação de modelo aleatório em classificação simples em dados balanceados.

O nosso principal interesse é estimar os componentes de variâncias  $\sigma_\alpha^2$  e  $\sigma_e^2$ . A maneira usual de estimarmos esses componentes é através do uso de certas quantidades que aparecem no quadro de análise de variância (ANOVA), ou mais especificamente, igualando os quadrados médios observados (Q.M.) aos seus valores esperados [ $E(QM)$ ]. A partir dos dados vistos anteriormente temos o seguinte quadro da ANOVA,

FONTES DE VARIAÇÃO	GL	SQ	QM	E(QM)
Classes	3	11	3,7	$\sigma_e^2 + 4\sigma_\alpha^2$
Erro	12	648	54	$\sigma_e^2$
TOTAL	15	659	-	-

então,

$$\sigma_e^2 = 54$$

$$\hat{\sigma}_e^2 = 54$$



$$\sigma_e^2 + 4\sigma_\alpha^2 = 3,7$$

$$\hat{\sigma}_\alpha^2 = (3,7 - 54) / 4 = -12,6 \quad (1.1.2)$$

Obtivemos uma estimativa negativa para um parâmetro sabida-

mente não negativa, e observe que esse exemplo é uma ilustração bem simples do uso da ANOVA na obtenção de um estimador para um componente de variância. Observe também que os estimadores são as soluções das equações lineares nos parâmetros. Daqui por diante diremos que esses estimadores são obtidos pelo método da ANOVA. Note que esses estimadores são os mais usados.

Neste momento talvez já surja a pergunta: "Afora as facilidades de cálculo (pois já aproveita o quadro da ANOVA), o que esse estimador tem de interessante para ter um uso tão geral e indiscriminado, apesar de produzir em algumas situações, estimativas negativas?" A resposta talvez esteja no fato dos estimadores componentes de variância obtidos pelo método da ANOVA (em dados balanceados) apresentarem algumas propriedades interessantes.

(i) são *não viciados*. Suponha que  $m$  seja o vetor dos quadrados médios,  $\sigma^2$  seja o vetor dos componentes de variância a serem estimados. Então, se  $E(m) = P\sigma^2$  para alguma matriz não singular  $P$ , nós tomamos  $m = P\sigma^2$  como equações para estimar  $\sigma^2$ . Então

$$E(\hat{\sigma}^2) = P^{-1}E(m) = P^{-1}P\sigma^2 = \sigma^2.$$

(ii) são *quadráticos não viciados de mínima variância*. Esta propriedade é mostrada por Graybill & Hultquist [1961]. Ela indica que entre todos os estimadores de  $\sigma^2$  que são funções quadráticas das observações e que são não viciados, os que possuem variância menor são obtidos pelo método da ANOVA.

Essas duas propriedades não necessitam da suposição de normalidade para os elementos aleatórios dos modelos, apenas que eles tenham média e covariâncias *zero* e variâncias *finitas*. Isto porque os valores esperados dos quadra-

dos médios nos quadrados da ANOVA não usam suposições de normalidade, e assim os estimadores dos componentes de variância obtidos pelo método da ANOVA não vão depender de exigências de normalidade. Entretanto, se fizermos suposições de normalidade, os estimadores dos componentes de variância obtidos pelo método da ANOVA em dados balanceados, são baseados em estatísticas suficientes minimais, resultado encontrado em Graybill & Hultguist [1961].

Todas as considerações feitas até aqui, são válidas para qualquer situação de classificação cruzada ou hierárquica, desde que o modelo seja aleatório e em dados balanceados. Com relação à aplicação do método, podemos dizer que as equações obtidas quando da igualdade entre os quadrados médios observados e os valores esperados, serão sempre consistentes, e portanto as soluções (estimadores) serão sempre encontradas.

O método da ANOVA para estimar componentes de variância em dados balanceados, também é usado em modelos mistos.

Apesar das facilidades de cálculo, e de algumas propriedades ótimas, os estimadores dos componentes de variância pelo método da ANOVA em dados balanceados, apresenta um inconveniente, que é o de produzir *estimativas negativas*. E há possibilidade disto acontecer em qualquer modelo (misto ou aleatório) e em qualquer classificação (cruzada ou hierárquica), e temos que reconhecer que isto é um fato por demais desagradável.

## 1.2 - DADOS NÃO BALANCEADOS

Abordaremos agora alguns métodos de estimação de

componentes de variância em dados não balanceados. Suponha a situação abaixo

FATOR A	A <sub>1</sub>		A <sub>2</sub>		A <sub>3</sub>	
FATOR B	B <sub>1</sub>	B <sub>2</sub>	B <sub>1</sub>	B <sub>2</sub>	B <sub>1</sub>	B <sub>2</sub>
OBSERVAÇÕES	5	10	10	5	2	10
	25		15	30	20	20
			20		30	

Suponha ainda que os dados acima seguem o *modelo aleatório classificação cruzada* em dados não balanceados,

$$Y_{ijk} = \mu + \alpha_i + \beta_j + \gamma_{ij} + e_{ijk}, \quad i=1, \dots, 3, \quad j=1, 2, \quad k=1, \dots, n_{ij} \quad (1.2.1)$$

onde  $\mu$  é o efeito médio verdadeiro,  $\alpha_i$  é efeito aleatório com  $E(\alpha_i) = 0$  e  $\text{var}(\alpha_i) = \sigma_\alpha^2$ ,  $\beta_j$  é um efeito aleatório com  $E(\beta_j) = 0$  e  $\text{var}(\beta_j) = \sigma_\beta^2$ , a interação  $\gamma_{ij}$  é um efeito aleatório com  $E(\gamma_{ij}) = 0$  e  $\text{var}(\gamma_{ij}) = \sigma_\gamma^2$ ,  $e_{ijk}$  é o termo aleatório do erro com  $E(e_{ijk}) = 0$  e  $\text{var}(e_{ijk}) = \sigma_e^2$  e ainda mais, todas as covariâncias entre os efeitos aleatórios, e entre eles e os termos do erro são supostas iguais a zero. Na linguagem de Planejamento de Experimentos  $\alpha_i$  e  $\beta_i$  seriam efeitos principais.

O nosso objetivo a partir do conhecimento dos dados existentes no início desta seção é o de estimar os componentes de variância  $\sigma_\alpha^2$ ,  $\sigma_\beta^2$ ,  $\sigma_\gamma^2$  e  $\sigma_e^2$ . Para isto preencheremos inicialmente o quadro da ANOVA, e a partir deste, estimaremos os componentes de variância.

FONTE DE VARIAÇÃO	GL	SQ	QM	E(QM)
Fator A	2	25,6	12,80	$\sigma^2 + n_0'' \sigma_\gamma^2 + n_1'' \sigma_\beta^2 + n_2'' \sigma_\alpha^2$
Fator B	1	4,8	4,80	$\sigma^2 + n_0' \sigma_\gamma^2 + n_1' \sigma_\beta^2 + n_2' \sigma_\alpha^2$
Interação AB	2	32,7	16,35	$\sigma^2 + n_0 \sigma_\gamma^2 + n_1 \sigma_\beta^2 + n_2 \sigma_\alpha^2$
Erro	7	929,2	132,74	$\sigma^2$
TOTAL	12	992,3	-	-

onde

$$n_0 = \left[ n_{..} - \sum_i \frac{\sum_j n_{ij}^2}{n_{i.}} - \sum_j \frac{\sum_i n_{ij}^2}{n_{.j}} + \frac{\sum_i \sum_j n_{ij}^2}{n_{..}} \right] / (a-1)(b-1)$$

$$n'_0 = \left[ \sum_j \frac{\sum_i n_{ij}^2}{n_{.j}} - \frac{\sum_i \sum_j n_{ij}^2}{n_{..}} \right] / (b-1)$$

$$n''_0 = \left[ \sum_i \frac{\sum_j n_{ij}^2}{n_{i.}} - \frac{\sum_i \sum_j n_{ij}^2}{n_{..}} \right] / (a-1)$$

$$n_1 = \left[ \frac{\sum_j n_{.j}^2}{n_{..}} - \sum_i \frac{\sum_j n_{ij}^2}{n_{i.}} \right] / (a-1)(b-1)$$

$$n'_1 = \left[ n_{..} - \frac{\sum_j n_{.j}^2}{n_{..}} \right] / (b-1)$$

$$n''_1 = \left[ \sum_i \frac{\sum_j n_{ij}^2}{n_{i.}} - \frac{\sum_j n_{ij}^2}{n_{..}} \right] / (a-1)$$

$$n_2 = \left[ \frac{\sum_i n_{i.}^2}{n_{..}} - \sum_j \frac{\sum_i n_{ij}^2}{n_{.j}} \right] / (a-1)(b-1)$$

$$n'_2 = \left[ \sum_j \frac{\sum_i n_{ij}^2}{n_{.j}} - \frac{\sum_i n_{i.}^2}{n_{..}} \right] / (b-1)$$

$$n_2'' = \left[ n_{..} - \frac{\sum_i n_{i.}^2}{n_{..}} \right] / (a-1) \quad (1.2.2)$$

Substituindo os respectivos valores nas fórmulas acima, e resolvendo o sistema de equações lineares nos componentes de variância, obtemos

$$\hat{\sigma}_e^2 = 132,74 \quad \hat{\sigma}_\gamma^2 = 59,06 \quad \hat{\sigma}_\beta^2 = 42,58 \quad \hat{\sigma}_\alpha^2 = -2,58 \quad (1.2.3)$$

Detalhes de como fórmulas vistas em (1.2.2) podem ser obtidas encontram-se em Searle [1971b].

O método usado acima para estimar componentes de variância é conhecido na literatura como *Método 1 de Henderson* e, é essencialmente o mesmo usado para dados balanceados. Por este motivo é também chamado de método da análise de variância para estimar componentes de variância. De todos os métodos usados para estimar componentes de variância este é o mais utilizado. O *Método 1 de Henderson* quando usado em modelos aleatórios produz estimadores não viciados para todos os componentes de variância. No entanto esta propriedade não é válida quando o método é usado em modelos mistos, pois neste caso produz estimadores viciados. Detalhes destes fatos encontram-se nos artigos de Searle [1968;1971a; 1971b].

Com o objetivo de contornar este problema de tendenciosidade dos estimadores de componentes de variância em modelos mistos, surgiu o método conhecido como *Método 2 de Henderson*. Em síntese, este método consiste em inicialmente estimarmos os efeitos fixos do modelo e, os dados são então ajustados por esses estimadores e os componentes de variância são estimados dos dados assim ajustados. Usando este procedimento, realmente produziremos estimadores não viciados,



mas em contrapartida, o procedimento não é definido de maneira única (pois envolve uma inversa generalizada) e também, não pode ser usado quando há interação entre os efeitos fixos e aleatórios. Isto é mostrado em detalhes por Searle [1968; 1971a; 1971b].

Outro método sugerido por Henderson, e que recebeu a denominação de *Método 3 de Henderson*, é baseado no método de ajustamento de constantes (denominação motivada pelo fato de que algumas vezes os efeitos fixos em modelos de efeitos fixos são chamados de constantes), que tem uso tradicional em modelos de efeitos fixos. Este método não usa somas de quadrados da ANOVA como os *métodos 1 e 2*, mas reduções nas somas de quadrados, devido ao ajustamento de constantes, e os componentes de variância são estimados através do ato de igualar cada redução calculada ao seu valor esperado sob o modelo completo. Detalhes deste método, inclusive com aplicações podem ser encontrados em Searle [1968; 1971b].

Parafraseando Searle [1968] podemos dizer que todos esses três métodos envolvem, cálculos de quadrados médios de algum tipo, obtenção de seus valores esperados e resolução das equações lineares nos componentes de variância desconhecidos, obtidos da igualdade entre quadrados médios calculados e seus valores esperados.

Em resumo, poderíamos dizer sobre os três métodos de Henderson: O *Método 1* apresenta como vantagens a sua analogia com o método da ANOVA para dados balanceados e sua relativa facilidade de cálculo, e como desvantagem o fato de produzir estimadores viciados dos componentes de variância, quando usado em modelos mistos; o *Método 2* tem a vantagem de produzir estimadores não viciados em modelos mistos e como desvantagens o fato de não ser unicamente definido e o de

não poder ser usado quando existe interação de efeitos fixos e aleatórios; o *Método 3* apresenta como vantagens o fato de produzir estimadores não viciados dos componentes de variância em modelos mistos e o de ser o mais indicado para modelos desse tipo, pois não faz restrições quanto às interações entre os efeitos fixos e aleatórios, e como desvantagem principal o de envolver cálculos excessivamente trabalhosos. Como características comuns todos eles apresentam os fatos de, quando usados em dados balanceados, reduzem-se ao método da ANOVA, e o de produzirem *estimativas negativas dos componentes de variância*.

Outros métodos usados em dados não balanceados e conhecidos na literatura como *método das médias* e *método das somas simétricas* são comentados por Searle [1971a; 1971b]. Esses métodos fornecem estimadores não viciados dos componentes de variância, reduzem-se ao método da ANOVA quando usados em dados balanceados, e produzem estimativas negativas dos componentes de variância.

Após uma rápida enumeração e comentários reduzidos de alguns métodos disponíveis para estimarmos componentes de variância, e que produzem estimativas negativas desses componentes, voltamos ao ponto de partida: que fazer quando as estimativas negativas ocorrem? ou então, que métodos alternativos existem que não produzem estimativas negativas?

Searle [1971a; 1971b] faz um bom comentário, apesar de reduzido, sobre o problema acima. Baseado nisto e complementando com algumas idéias que apareceram em artigos posteriores às publicações acima, discorreremos ligeiramente sobre o problema.

### 1.3 - O PROBLEMA DE ESTIMATIVAS NEGATIVAS

Devido à desagradabilidade do fato de estimarmos

como negativos certos componentes de variância, o problema de estimativas negativas tem merecido por parte dos estatísticos um tratamento especial. Talvez não seja exagero afirmarmos que este fato tenha sido o responsável pelas recentes contribuições na área de estimação de componentes de variância.

Que devemos fazer quando encontramos uma estimativa negativa de um componente de variância? Searle [1971a] enumera vários procedimentos alternativos, e alguns deles são aqui transcritos.

- (i) Apresentar a estimativa obtida e aprender a conviver com ela, como ervas daninhas no gramado. Ela pode ser tomada como uma evidência de que o verdadeiro valor do componente é zero. Isto não é satisfatório quando queremos utilizar uma estimativa da soma de componentes de variância, um dos quais tendo estimativa negativa. A estimativa da soma incluindo este componente é então menor que a soma sem ele.
- (ii) Aceitar a estimativa negativa como uma evidência de que o verdadeiro valor do componente correspondente é zero, sugerindo a mudança da estimativa negativa pelo valor zero. Isto pode parecer bastante lógico, mas como parte da estimação foi truncada, isto perturba as propriedades dos estimadores.
- (iii) Interpretação da estimativa negativa como indicação de um modelo errôneo. Neste contexto, Anderson [1965] afirma que quando uma estimativa negativa ocorre, há possibilidade de haver problemas nos cálculos ou na especificação do modelo. Então, a primeira etapa seria conferir os cálculos realizados e a segunda, se a primeira estivesse correta, seria talvez a reconsideração do modelo. Mesmo assim, permanecendo o pro

blema da estimativa negativa, ele sugere considerar o valor do componente como sendo zero.

No aspecto de reconsideração do modelo, Searle & Fawcett [1970] discutem um procedimento em classificação simples, de considerar o modelo em termos de populações finitas, em vez de populações infinitas, procedimento que nos leva a encontrar estimativas não negativas, onde anteriormente, sob a suposição de populações infinitas elas eram negativas.

Já Nelder [1954] afirma que existem experimentos onde temos possibilidade de encontrarmos estimativas negativas para os componentes de variância. Este fato é mostrado por ele em Blocos Aleatorizados e em "Split-Plot".

Searle [1971b] dá como conselho final: "Tomar as estimativas negativas como indicação de dados insuficientes, e ir atrás da última esperança do estatístico: coletar mais dados e analisá-los, eles próprios ou combinados com aqueles que produziram estimativas negativas. Se a estima obtida usando os dados combinados é negativa, temos uma evidência adicional de que o componente corresponde é zero.

Até a presente etapa dessa monografia, a estimação de componentes de variância foi vista sob a luz dos métodos que produzem estimativas negativas, e discutimos procedimentos vários que tentam contornar o problema. Uma outra abordagem para o problema de estimativas negativas, e considerada mais fundamentada, é sugerir métodos alternativos de estimação que não produzem estimativas negativas para os componentes de variância.

Nesta linha, talvez como primeiro trabalho, surgiu o de Herbach [1959], que usa estimadores de máxima verossimilhança.

milhança, que são não negativos. No seu trabalho ele descreveu os estimadores dos componentes de variância para o modelo aleatório simples em dados balanceados. Eles apresentam como vantagem o fato de serem não negativos, e como desvantagem o fato de serem truncados e viciados.

Thompson [1962] na tentativa de resolver o problema de estimativas negativas desenvolveu um algoritmo, por ele denominado de "pool-the-minimum-violator". Esse algoritmo resulta da maximização da função de verossimilhança dos quadrados médios, sujeita a um conjunto de restrições, que recebe a denominação de princípio de máxima verossimilhança restritivo. Existem aplicações desse algoritmo no artigo escrito por Thompson e Moore [1963]. Este procedimento provoca um truncamento, e o estimador resultante é viciado.

Supondo um modelo do tipo

$$y_{ij} = \mu + \alpha_i + e_{ij}, \quad i=1, \dots, m \text{ e } j=1, \dots, n$$

com as mesmas suposições dadas em (1.1.1), temos como estimadores de  $\sigma_\alpha^2$  e  $\sigma_e^2$ ,

(i) ANOVA

$$\hat{\sigma}_\alpha^2 = (QME - QMD) / n$$

$$\hat{\sigma}_e^2 = QME$$

(ii) Máxima verossimilhança

$$\hat{\sigma}_\alpha^2 = \begin{cases} \left[ \frac{(m-1)}{m} \cdot QME - QMD \right] / n, & \text{se } [(m-1)/m] \cdot QME \geq QMD \\ 0, & \text{se } [(m-1)/m] \cdot QME < QMD \end{cases}$$

$$\hat{\sigma}_e^2 = \begin{cases} \text{QME, se } [(m-1)/m] \cdot \text{QME} \geq \text{QMD} \\ \text{SQT}/(mn-1), \text{ se } [(m-1)/m] \cdot \text{QME} < \text{QMD} \end{cases}$$

(iii) Máxima verossimilhança Restritivo

$$\hat{\sigma}_\alpha^2 = \begin{cases} (\text{QME}-\text{QMD})/n, \text{ se } \text{QME} \geq \text{QMD} \\ 0, \text{ se } \text{QME} < \text{QMD} \end{cases}$$

$$\hat{\sigma}_e^2 = \begin{cases} \text{QME, se } \text{QME} \geq \text{QMD} \\ \text{SQT}/mn, \text{ se } \text{QME} < \text{QMD} \end{cases}$$

onde QME, QMD e SQT significam respectivamente, quadrado médio entre, quadrado médio dentro e soma de quadrados total.

Rao [1972] estendeu um novo método de estimação de nominado MINQUE (Minimum Norm Quadratic Unbiased Estimation) ao problema de estimação de componentes de variância e covariância. Os estimadores obtidos, após uma modificação introduzida pelo autor, são não negativos, mas não viciados.

LaMotte [1973] desenvolveu dentro da classe dos estimadores quadráticos não viciados, as condições para obtermos estimativas não negativas de combinações lineares dos componentes de variância. Devido à clara importância das idéias desenvolvidas no artigo acima citado, destinamos o Capítulo 2 dessa monografia, para o detalhamento e discussão dos resultados obtidos por LaMotte.

Todos os trabalhos citados até aqui estudaram o problema de estimação dos componentes de variância dentro do aspecto não bayesiano, isto é, ignorando os métodos bayesia-

nos quando das inferências sobre os componentes de variância. Em meados da década de 60, através de Hill [1965] e Tiao & Tan [1965] surgiram os primeiros trabalhos nesta área, tratando da inferência bayesiana sobre  $\sigma_{\alpha}^2$  e  $\sigma_e^2$ , num modelo aleatório simples, em dados não balanceados e balanceados respectivamente. A grande vantagem prática do uso dos métodos bayesianos em componentes de variância, é que as "estimativas" obtidas são sempre não negativas. No Capítulo 3 dessa monografia discorreremos sobre o problema de fazermos inferências sobre  $\sigma_{\alpha}^2$  e  $\sigma_e^2$  num modelo aleatório simples em dados balanceados.

## CAPÍTULO 2

### ESTIMAÇÃO QUADRÁTICA NÃO VICIADA E NÃO NEGATIVA DE COMPONENTES DE VARIÂNCIA

No capítulo 1 fizemos algumas considerações sobre os vários métodos de estimação de componentes de variância. Através de exemplos simples, mostramos a possibilidade de estimar como negativo, um componente de variância (um parâmetro sabidamente não negativo), usando o método da ANOVA. Também ficou caracterizado, que dentro da abordagem não bayesiana, de todos os estimadores que fornecem estimativas não negativas dos componentes de variância, nenhum apresenta a propriedade de ser não viciado.

Neste capítulo restringiremos a classe geral dos estimadores dos componentes de variância à classe dos estimadores quadráticos não viciados e, dentro dela, procuraremos discutir as condições de estimabilidade não negativa desses componentes.

#### 2.1 - O MODELO GERAL

Seja  $Y$  uma variável aleatória  $N$ -dimensional, com  $ve$



tor de médias

$$E(Y) = X\beta \quad (2.1.1)$$

onde  $\beta$  é um vetor de parâmetros  $q \times 1$ ,  $X$  é uma matriz de constantes conhecidas  $N \times q$ , e  $Y$  tem matriz de covariância.

$$\text{cov}(Y) = V(\lambda) = \sum_{i=1}^K \lambda_i V_i \quad (2.1.2)$$

onde  $\lambda$  é um vetor de parâmetros (chamados componentes de variância)  $K \times 1$ ,  $V_i$  é uma matriz simétrica  $N \times N$  de constantes conhecidas. Será suposto que  $\lambda$  é tal que  $V(\lambda)$  é *positiva definida*. Onde não existir ambiguidade,  $V(\lambda)$  será denotada por  $V$ .

O modelo caracterizado por (2.1.1) e (2.1.2) é muito geral, requerendo apenas que os elementos do vetor de médias sejam combinações lineares conhecidas de um conjunto de parâmetros ( $\beta$ ), e que os elementos da matriz de covariância sejam combinações lineares de outro conjunto de parâmetros ( $\lambda$ ).

O nosso problema central é estimar a função  $p'\lambda$ , onde  $p$  é um vetor de constantes  $K \times 1$ . Desejamos estimar  $p'\lambda$  por uma forma quadrática das observações. Serão consideradas as formas quadráticas do tipo  $Y'AY$ , onde  $A$  é uma matriz simétrica  $N \times N$ .

Como estamos interessados em estimação quadrática não viciada e não negativa devemos propor um estimador que seja

- a. quadrático
- b. não viciado
- c. não negativo

A condição (a) está satisfeita, já que propomos u-

ma forma quadrática para estimador de  $p'\lambda$ ; a condição (b) ficará satisfeita se tomarmos  $E(Y'AY) = p'\lambda$ ; e finalmente a condição (c) também ficará satisfeita se A for uma *matriz não negativa definida*.

Um resultado (ver Searle [1971b]) que nos será útil é o seguinte:

$$E(Y'AY) = \text{tr}(AV) + \beta'X'AX\beta \quad (2.1.3)$$

onde V é a matriz de covariância de Y e  $\text{tr}(M)$  é a soma dos elementos da diagonal da matriz M.

PROPOSIÇÃO - Uma condição necessária e suficiente para que  $Y'AY$  seja um estimador não viciado de  $p'\lambda$  é que  $X'AX = 0$  e  $\text{tr}(AV_i) = p_i$ .

PROVA -

(Se) - Se vale  $X'AX = 0$  e  $\text{tr}(AV_i) = p_i$  temos

$$E(Y'AY) = \sum_{i=1}^K \lambda_i \text{tr}(AV_i) + \beta'X'AX\beta = \sum_i \lambda_i p_i = p'\lambda$$

(Só se) - Como a condição é para  $\forall \beta$ , tomemos  $\beta = 0$ .

Então,  $E(Y'AY) = \sum_i \lambda_i \text{tr}(AV_i) = T'\lambda$  onde,

$T' = [\text{tr}(AV_1), \dots, \text{tr}(AV_k)]$  ou seja

$p_i = \text{tr}(AV_i)$  então,  $E(Y'AY) = p'\lambda + \beta'X'AX\beta$

e para que seja não viciado

$$\beta'X'AX\beta = 0 \quad \forall \beta \implies X'AX = 0.$$

## 2.2 - CONDIÇÕES PARA ESTIMABILIDADE NÃO VICIADA E NÃO NEGATIVA

A forma quadrática proposta ( $Y'AY$ ) satisfará as con

dições (a), (b) e (c) se entre todas as formas da matriz  $A$  escolhermos:

- (i)  $A$  não negativa definida, isto é,  
 $x'Ax \geq 0, \forall x, N \times 1$
- (ii)  $X'AX = 0$
- (iii)  $\text{tr}(AV) = p'\lambda$  ou de uma maneira equivalente  $\text{tr}(AV_i) = p_i$ .

Mostraremos agora toda uma formalização capaz de garantir que as condições acima sejam satisfeitas.

LEMA - Uma condição necessária e suficiente para que (i) e (ii) sejam satisfeitas é que exista uma matriz  $C$  tal que  $A = WCC'W$ , onde  $W = V^{-1} - V^{-1}X(X'V^{-1}X)^{-1}X'V^{-1}$ .

PROVA - (Se) -  $A = WCC'W$ , então  $A$  é não negativa definida e  $X'AX = 0$ , pois  $X'W = 0$   
-  $A$  é não negativa definida, pois  $K' = x'WC$  é um vetor real  $\implies x'Ax = x'WCC'Wx = KK' \geq 0$   
-  $X'W = 0$ ; para isto usaremos dois fatos:

Fato 1 - Se  $V^{-1}$  é positiva definida,  
 $A'V^{-1}A = 0 \implies A = 0$

Fato 2 -  $PX'V^{-1} = PX'V^{-1}X \implies PX'V^{-1} = QX'V^{-1}$  fazendo

$P = X'V^{-1}X(X'V^{-1}X)^{-1}$  e  $Q = I$ , onde  $MM^{-1}M = M$  temos,  $X'V^{-1}X(X'V^{-1}X)^{-1}X'V^{-1}X = X'V^{-1}X \implies X'V^{-1}X(X'V^{-1}X)^{-1}X'V^{-1} = X'V^{-1}$  então,  
 $X'W = X'V^{-1} - X'V^{-1}X(X'V^{-1}X)^{-1}X'V^{-1} = X'V^{-1} - X'V^{-1} = 0.$

(Só se) - Se  $A$  é não negativa definida  $\exists B$  real tq  
 $A = BB'$

se  $X'AX = 0$  então  $X'BB'X = 0 \implies X'B = 0$   
mas  $X'B = 0$  se só se  $\exists C$  tal que  $B = WC$

$$\begin{aligned} \text{(se)} \quad & - \text{ se } B = WC \implies X'B = X'WC = 0 \\ \text{(s\~o se)} \quad & - \text{ se } X'B = 0, \text{ seja } C = VB, \text{ ent\~ao} \\ WC = WV B & = [V^{-1} - V^{-1}X(X'V^{-1}X)^{-1}X'V^{-1}]VB = \\ & = B - V^{-1}X(X'V^{-1}X)^{-1}X'B = B. \end{aligned}$$

Ent\~ao, A \u00e9 n\~ao negativa definida e  $X'AX = 0$  se s\~o se

$$A = BB' = WCC'W$$

TEOREMA - Uma condi\u00e7\~ao necess\~aria e suficiente para que (i), (ii) e (iii) sejam satisfeitas \u00e9 que A obede\u00e7a as seguintes condi\u00e7\~oes: existe C tq  $A = WCC'W$  e  $\text{tr}(C'WV_iWC) = p_i$ , onde  $W = V^{-1} - V^{-1}X(X'V^{-1}X)^{-1}X'V^{-1}$ .

PROVA -

Pelo Lema, (i) e (ii) valem se s\~o se  $A = WCC'W$

(Se) - Se  $p_i = \text{tr}(C'WV_iWC) = \text{tr}(WCC'WV_i)$  e como  $A = WCC'W \implies \text{tr}(AV_i) = p_i$

(S\~o se) - Se  $\text{tr}(AV_i) = p_i$ , como A \u00e9 n\~ao negativa definida e  $X'AX=0$  pelo Lema, \u00e9 C tq  $A = WCC'W \implies p_i = \text{tr}(AV_i) = \text{tr}(WCC'WV_i) = \text{tr}(C'WV_iWC)$

COROL\~ARIO - Se para algum i ( $i=1, \dots, k$ ),  $V_i$  \u00e9 positiva definida e  $p_i = 0$ , o \u00fanico vetor p para o qual existe um estimador quadr\~atico n\~ao viciado e n\~ao negativo para  $p'\lambda$  \u00e9  $p = 0$ .

PROVA -

Se  $p_i = 0$  ent\~ao  $\text{tr}(CWV_iWC) = 0$  e se  $V_i$  \u00e9 positiva definida  $\implies WC = 0 \implies \text{tr}(C'WV_jWC) = p_j = 0, \forall j=1, \dots, k$ .

### 2.3 - CONSEQU\~ENCIAS E APLICA\u00c7\~OES

Usando a notac\~ao de Rao [1972] n\~os podemos escre-

ver a nossa variável N-dimensional  $Y$  como uma estrutura linear da forma

$$Y = X\beta + U_1\xi_1 + \dots + U_k\xi_k \quad (2.3.1)$$

onde  $X$  e  $\beta$  são definidos como em (2.1.1),  $U_i$  é uma matriz da  $N \times c_i$  e  $\xi_i$  é um vetor  $c_i \times 1$  de variáveis não correlacionadas com média zero e matriz de dispersão  $\sigma_i^2 I_{c_i}$ ,  $i=1, \dots, k$ , onde os  $\sigma_i^2$  são desconhecidos e  $I_{c_i}$  é uma matriz de identidade de  $c_i \times c_i$ . Ainda mais,  $\xi_i$  e  $\xi_j$  são não correlacionados. Em particular, podemos pensar em escrever o modelo da ANOVA de acordo com (2.3.1), e neste caso,  $U_k = I$  e  $c_k = N$ . Então temos que

$$\left. \begin{aligned} E(Y) &= X\beta \\ \text{cov}(Y) &= \sigma_1^2 U_1 U_1' + \dots + \sigma_k^2 I \end{aligned} \right\} \quad (2.3.2)$$

isto é, nos modelos da ANOVA temos a seguinte estrutura

$$\left. \begin{aligned} V_i &= U_i U_i' , \quad i=1, \dots, k-1 \\ V_k &= I \\ \lambda_i &\geq 0 , \quad i=1, \dots, k \end{aligned} \right\} \quad (2.3.3)$$

Uma sequência imediata do *Corolário* da seção anterior é que, nos modelos da ANOVA, o único componente individual que pode ser estimado isoladamente de uma maneira não viciada por uma forma quadrática não negativa é  $\lambda_k$ , e até mesmo  $\lambda_k$  é assim estimável somente se todo  $V_i$ ,  $i=1, \dots, k-1$ , for singular. Outra consequência do *Teorema* é que nesses modelos da ANOVA, apenas os  $p$ 's tais que  $p_i \geq 0$ ,  $i=1, \dots, k$ , podem fazer com que  $p'\lambda$  possa ser estimado de uma maneira não viciada por uma quadrática não negativa.

Uma aplicação de todas as idéias vistas até este

ponto será dada através de um exemplo com o modelo aleatório simples em dados balanceados.

Considere o modelo

$$y_{ij} = \mu + \alpha_i + e_{ij} \quad (2.3.4)$$

onde  $\alpha_i \sim (0, \sigma_\alpha^2)$   $e_{ij} \sim (0, \sigma_e^2)$ ,  $i=1, \dots, m$ ,  $j=1, \dots, n$  e ainda  $E(\alpha_i \alpha_k) = 0$ ,  $i \neq k$ ,  $E(\alpha_i e_{i', j'}) = 0$ ,  $\forall i, i', j'$ . Temos que,

$$\text{cov}(y_{ij}, y_{i'j'}) = \begin{cases} \sigma_\alpha^2 + \sigma_e^2 & , i=i' \text{ e } j=j' \\ \sigma_\alpha^2 & , i=i' \text{ e } j \neq j' \\ 0 & , i \neq i' \end{cases} \quad (2.3.5)$$

Então, para  $i=1$  teríamos

$$\text{cov} \begin{bmatrix} y_{11} \\ y_{12} \\ \vdots \\ y_{1n} \end{bmatrix} = \begin{bmatrix} \sigma_\alpha^2 + \sigma_e^2 & \sigma_\alpha^2 & \dots & \sigma_\alpha^2 \\ \sigma_\alpha^2 & \sigma_\alpha^2 + \sigma_e^2 & \dots & \sigma_\alpha^2 \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_\alpha^2 & \sigma_\alpha^2 & \dots & \sigma_\alpha^2 + \sigma_e^2 \end{bmatrix} = \sigma_e^2 I_n + \sigma_\alpha^2 J_n \quad (2.3.6)$$

e,

$$\text{cov} \begin{bmatrix} y_{11} \\ y_{12} \\ \vdots \\ y_{mn} \end{bmatrix} = \begin{bmatrix} \sigma_e^2 I_n + \sigma_\alpha^2 J_n & & & \\ & \cdot & & 0 \\ & \cdot & \cdot & \\ 0 & & \cdot & \sigma_e^2 I_n + \sigma_\alpha^2 J_n \end{bmatrix} = \sum_{i=1}^m (\sigma_e^2 I_n + \sigma_\alpha^2 J_n) \quad (2.3.7)$$

onde  $\sum^+$  indica a operação de "soma direta" de matrizes,  $I_n$  é uma matriz identidade  $n \times n$ ,  $J_n$  é uma matriz  $n \times n$ , com todos os elementos iguais a 1. Indicaremos "produto de Kronocker" por  $\otimes$ , e um vetor  $n \times 1$  que só possui uns será denotado por  $1_n$ . Então, podemos escrever que

$$\begin{aligned}
 \sum_{i=1}^m (\sigma_e^2 I_n + \sigma_\alpha^2 J_n) &= I_m \otimes (\sigma_e^2 I_n + \sigma_\alpha^2 J_n) = \\
 &= I_m \otimes \sigma_e^2 I_n + I_m \otimes \sigma_\alpha^2 J_n = \\
 &= \sigma_e^2 I_{m \cdot n} + \sigma_\alpha^2 (I_m \cdot I_n) \otimes (1_n 1_n') = \\
 &= \sigma_e^2 I_{m \cdot n} + \sigma_\alpha^2 (I_m \otimes 1_n) \cdot (I_m \otimes 1_n)' = \\
 &= \sigma_e^2 I_{m \cdot n} + \sigma_\alpha^2 KK' \quad (2.3.8)
 \end{aligned}$$

o que nos faz escrever

$$V(\lambda) = \lambda_2 I + \lambda_1 KK' \quad (2.3.9)$$

onde,  $K = I_m \otimes 1_n$ .

Seja  $\lambda_2 = 1$  e  $\lambda_1 = 0$ . Então,

$$\begin{aligned}
 W &= V^{-1} - V^{-1}X(X'V^{-1}X)^{-1}X'V^{-1} = \\
 &= I_{mn} - 1_{mn}(1_{mn}'1_{mn})^{-1}1_{mn}' = \\
 &= I_{mn} - \frac{1}{mn} 1_{mn}1_{mn}' \quad (2.3.10)
 \end{aligned}$$

de modo que,

$$\begin{aligned}
 WV_1W &= WKK'W = (I_{mn} - \frac{1}{mn} 1_{mn}1_{mn}')KK'(I_{mn} - \frac{1}{mn} 1_{mn}1_{mn}') = \\
 &= KK' - \frac{1}{mn} 1_{mn}1_{mn}' \quad (2.3.11)
 \end{aligned}$$

e

$$WV_2W = WIW = WW = W \quad (2.3.12)$$

observe que se somarmos e subtrairmos  $\frac{1}{n} KK'$  de  $W$  obtemos

$$W = \frac{1}{n} WV_1W + (I_{mn} - \frac{1}{n} KK') \quad (2.3.13)$$

onde  $y'Wy$ ,  $\frac{1}{n} y'WV_1Wy$ ,  $y'(I_{mn} - \frac{1}{n} KK')y$  funcionam respectivamente como uma soma de quadrados total corrigida, soma de quadrados entre e soma de quadrados dentro. Vejamos,

$$\begin{aligned} y'Wy &= y'[I_{mn} - \frac{1}{mn} 1_{mn}1'_{mn}]y = y'y - \frac{1}{mn} y'1_{mn}1'_{mn}y = \\ &= y'y - \frac{1}{mn} \left( \sum_{ij} y_{ij} \right) \cdot \left( \sum_{ij} y_{ij} \right) = \sum_{ij} y_{ij}^2 - mn\bar{y}_{..}^2 = \\ &= \text{SQ TOTAL CORRIGIDA} \end{aligned}$$

$$\begin{aligned} y'WV_1Wy &= y'[KK' - \frac{1}{m} 1_{mn}1'_{mn}]y = y'KK'y - \frac{1}{m} y'1_{mn}1'_{mn}y = \\ &= y'(I_m \otimes 1_n)(I_m \otimes 1'_n)y - \frac{1}{m} (\sum_{ij} y_{ij})(\sum_{ij} y_{ij}) = \\ &= y'(I_m) \otimes 1_n 1'_n y - mn^2 \bar{y}_{..}^2 = \\ &= y'I_m \otimes J_n y - mn^2 \bar{y}_{..}^2 = \\ &= (n\bar{y}_{1.})^2 + (n\bar{y}_{2.})^2 + \dots + (n\bar{y}_{m.})^2 - mn\bar{y}_{..}^2 = \\ &= n^2 \sum_i \bar{y}_{i.}^2 - mn^2 \bar{y}_{..}^2. \end{aligned}$$

$$\Rightarrow \frac{1}{n} y'WV_1Wy = n \sum_i \bar{y}_{i.}^2 - mn\bar{y}_{..}^2 = \text{SQ ENTRE}$$

$$\begin{aligned} y'[I_m - \frac{1}{n} KK']y &= y'y - \frac{1}{n} y'KK'y = \sum_{ij} y_{ij}^2 - \frac{1}{n} n^2 \sum_i \bar{y}_{i.}^2 = \\ &= \sum_{ij} y_{ij}^2 - n \sum_i \bar{y}_{i.}^2 = \text{SQ DENTRO} \end{aligned}$$

Em (2.3.13) como os termos da direita são matrizes não negativas definidas, para qualquer vetor  $\alpha$ ,



$$\alpha' W \alpha \geq \alpha' \left( \frac{1}{n} W V_1 W \right) \alpha \quad (2.3.14)$$

Seja  $C$  uma matriz  $m \times m$  com vetores coluna  $c_i$ . Por (2.3.14),

$$c_i' W c_i \geq c_i' \left( \frac{1}{n} W V_1 W \right) c_i \quad (2.3.15)$$

de modo que

$$\sum_i c_i' W c_i \geq \sum_i c_i' \left( \frac{1}{n} W V_1 W \right) c_i \quad (2.3.16)$$

o termo do lado esquerdo de (2.3.16) é  $\text{tr}(C' W V_2 W C)$  e o termo do lado direito é  $\text{tr}(C' W V_1 W C)/n$ . Se a condição do Teorema está satisfeita deve então ser verdade que

$$p_2 \geq \frac{1}{n} p_1 \geq 0 \quad (2.3.17)$$

Se  $n=1$  e  $m > 1$ ,

$$I_{mn} - \frac{1}{n} K K' = I_m - K K' = I_m - I_m = 0, \text{ pois } K = I_m \otimes 1_1$$

então

$$\text{tr}(C' W V_2 W C) = \text{tr}(C' W V_1 W C)$$

$$\implies p_2 = p_1 = p \geq 0$$

resultando,

$$p' \lambda = [pp] \begin{bmatrix} \lambda_1 \\ \lambda_2 \end{bmatrix} = p \lambda_1 + p \lambda_2 = p(\lambda_1 + \lambda_2)$$

isto é, somente múltiplos positivos de  $(\lambda_1 + \lambda_2)$  podem ser estimados de uma maneira não negativa por quadráticas não viadas.

Se  $n > 1$  e  $m = 1$ ,  
temos que,

$$\text{tr}(C'WV_2WC) = \text{tr}\left(\frac{1}{n} C'WV_1WC\right) = 0$$

resultando

$$p'\lambda = [0 \quad 0] \begin{bmatrix} \lambda_1 \\ \lambda_2 \end{bmatrix} = 0$$

isto é, somente o 0 pode ser estimado de uma maneira não ne  
gativa por quadráticas não viciadas.

Se  $n > 1$  e  $m > 1$ , e ainda se (2.3.17) ocorre, então existe u-  
ma forma quadrática não viciada e não nega-  
tiva para  $p'\lambda$ .

Escolha uma matriz  $c$  com apenas a primeira coluna  
 $c_1$  diferente de zero. Temos que  $W = \frac{1}{n} WV_1W + (I - \frac{1}{n} KK')$ . En-  
tão,

$c_1'Wc_1$  pode ser particionada em

$$c_1' \frac{1}{n} WV_1Wc_1 \text{ e } c_1'(I - \frac{1}{n} KK')c_1$$

Escolha  $c_1$  tal que

$$c_1'Wc_1 = p_2 \text{ e } c_1'WV_1Wc_1 = \frac{1}{n}p_1 \text{ e } p_2 \geq \frac{1}{n}p_1$$

Então se  $n > 1$  e  $m > 1$ , para que  $p'\lambda$  seja estimado por uma for  
ma quadrática não viciada e não negativa, é necessário e su  
ficiente que (2.3.17) ocorra. Isto é, sempre podemos esti-  
mar  $p'\lambda$  por uma forma quadrática não viciada e não negativa  
desde que

$$p_2 \geq \frac{1}{n}p_1$$

Então,

$$p'\lambda = \lambda_2 = [0 \quad 1] \begin{bmatrix} \lambda_1 \\ \lambda_2 \end{bmatrix}$$

satisfaz a condição e

$$p'\lambda = n\lambda_1 + \lambda_2 = [n \quad 1] \begin{bmatrix} \lambda_1 \\ \lambda_2 \end{bmatrix}$$

também, mas,

$$p'\lambda = \lambda_1 = [1 \quad 0] \begin{bmatrix} \lambda_1 \\ \lambda_2 \end{bmatrix}$$

não satisfaz a condição.

A conclusão a que se chega, é que o modelo aleatório simples, podem ser estimados por uma forma quadrática não viciada e não negativa, o componente de variância  $\lambda_2$  e a combinação linear dos componentes de variância dada por  $n\lambda_1 + \lambda_2$ . Mas, infelizmente o componente de variância  $\lambda_1$  não pode ser estimado de uma maneira não negativa através de uma forma quadrática não viciada.

Em síntese podemos afirmar que, em qualquer modelo de análise de variância, o único componente de variância que pode ser estimado isoladamente por uma forma quadrática não viciada e não negativa é  $\lambda_k$  (ou seja, a variância residual).

#### 2.4 - ESTIMAÇÃO QUADRÁTICA NÃO VICIADA E NÃO NEGATIVA DE $\sigma_e^2$ E $\sigma_\alpha^2$ NUM MODELO ALEATÓRIO SIMPLES - UM EXEMPLO

Os estimadores dos componentes de variância, obti-

dos pelo método de ANOVA em dados balanceados, são sabidamente quadráticos e não viciados, pertencendo logicamente à classe dos estimadores discutidos no artigo de LaMotte [1973], haja visto a seção 2.3. Mesmo assim, e assumindo o ônus da repetição às vezes enfadonha, mas com um objetivo maior de tornar mais simples e mais inteligíveis as idéias já vistas neste Capítulo, procuraremos desenvolver em detalhes o exemplo abaixo,

	GRUPO 1	GRUPO 2
OBSERVAÇÕES	$y_{11}$ $y_{12}$	$y_{21}$ $y_{22}$

que tem por modelo matemático

$$y_{ij} = \mu + \alpha_i + e_{ij} \quad (2.4.1)$$

onde  $\alpha_i \sim (0, \sigma_\alpha^2)$ ,  $e_{ij} \sim (0, \sigma_e^2)$ ,  $i=1,2$  e  $j=1,2$ , ainda mais,  $\mu$  é um parâmetro desconhecido,  $\alpha_i$  e  $e_{ij}$  são variáveis aleatórias mutuamente independentes com médias zero e variâncias  $\sigma_\alpha^2$  e  $\sigma_e^2$ , respectivamente. De acordo com Rao [1972] este modelo pode ser escrito como

$$Y = X\beta + U_1\xi_1 + U_2\xi_2 \quad (2.4.2)$$

onde  $Y$  é um vetor de variáveis aleatórias  $4 \times 1$ ,  $\beta$  é um vetor de dimensão 1 de parâmetro desconhecido,  $X$  é uma matriz de constantes conhecidas  $4 \times 1$ ,  $\xi_1$  é um vetor  $2 \times 1$  de variáveis aleatórias não correlacionadas com média zero e matriz covariância  $\sigma_1^2 I_2$  (como  $\sigma_1^2$  desconhecido e  $I_2$  uma matriz identidade de  $2 \times 2$ ),  $U_1$  é uma matriz de constantes conhecidas  $4 \times 2$ ,  $\xi_2$  é um vetor  $4 \times 1$  dos termos do erro e  $U_2 = I_4$ . Então,

$$Y = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} \mu + \begin{bmatrix} 1 & 0 \\ 1 & 0 \\ 0 & 1 \\ 0 & 1 \end{bmatrix} \alpha + \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} e \quad (2.4.3)$$

E como,

$$\text{cov}(Y) = \sigma_1^2 U_1 U_1' + \sigma_2^2 I \quad (2.4.4)$$

temos que

$$\text{cov}(Y) = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 1 \end{bmatrix} \sigma_\alpha^2 + \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \sigma_e^2 \quad (2.4.5)$$

Até esta altura procuramos apenas, através de um exemplo bem simples (talvez o mais simples possível), mostrar como podemos escrever o nosso modelo, usando uma formulação bem geral para um modelo linear. No entanto, o nosso objetivo primeiro é o de verificar o que ocorre com as estimativas de  $\sigma_e^2$  e de  $\sigma_\alpha^2$ . Durante todo este Capítulo trabalhamos com a classe dos estimadores quadráticos e não viciados dos componentes de variância, e usando o método da ANOVA em dados balanceados (caso do nosso exemplo) obtemos estimadores para  $\sigma_e^2$  e  $\sigma_\alpha^2$  que são funções de formas quadráticas das observações e são não viciados. Os estimadores de  $\sigma_e^2$  e  $\sigma_\alpha^2$  são respectivamente,

$$\hat{\sigma}_e^2 = \text{QME} \quad \text{e} \quad \hat{\sigma}_\alpha^2 = \frac{1}{n} [\text{QMD} - \text{QME}] \quad (2.4.6)$$

onde, QME representa o quadrado médio "entre" grupos, e QMD representa o quadrado médio "dentro" de grupos, sendo que  $n$  é o número de observações por grupo.

Como na ANOVA, quando preenchemos o quadro da análise de variância, obtemos quantidades que representam os quadrados médios das diversas "fontes de variação", e como essas quantidades são as mesmas, quer o modelo seja fixo ou aleatório, desenvolveremos as idéias para o preenchimento do quadro, a partir de um modelo fixo.

Seja um modelo idêntico a (2.4.1), com exceção de  $\alpha_i$  ser agora uma constante. Então teremos numa forma matricial, que

$$Y = Ap + e \quad (2.4.7)$$

onde  $Y$  é um vetor de variáveis aleatórias  $4 \times 1$ ,  $p$  é um vetor de parâmetros desconhecidos  $3 \times 1$  e  $e$  é um vetor dos termos do erro  $4 \times 1$ . Então,

$$Y = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 1 & 0 & 1 \\ 1 & 0 & 1 \end{bmatrix} \begin{bmatrix} \mu \\ \alpha_1 \\ \alpha_2 \end{bmatrix} + \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} e \quad (2.4.8)$$

E o quadro da análise de variância (ver Searle [1971b]) seria

FONTES DE VARIAÇÃO	GL	SQ	
Entre grupos	$\rho(A) - 1$	$Y' \{A(A'A)^{-1}A' - N^{-1}1_N 1_N'\} Y$	$\frac{SQE}{GLE}$
Dentro de grupos	$N - \rho(A)$	$Y' \{I_N - A(A'A)^{-1}A'\} Y$	$\frac{SQD}{GLD}$
T O T A L	$N - 1$	$Y'Y - Y'N^{-1}1_N 1_N'Y$	

onde  $\rho(A)$  é o posto da matriz  $A$ ,  $N$  é o número total de observações,  $(A'A)^{-1}$  é a inversa generalizada de  $A'A$  e  $1_N$  é um vetor de uns de dimensão  $N$ .

No nosso exemplo temos que  $\rho(A) = 2$ ,  $N = 4$ , e mais

$$A(A'A)^{-1}A' = \begin{bmatrix} 1/2 & 1/2 & 0 & 0 \\ 1/2 & 1/2 & 0 & 0 \\ 0 & 0 & 1/2 & 1/2 \\ 0 & 0 & 1/2 & 1/2 \end{bmatrix}$$

Então,

$$\hat{\sigma}_e^2 = \frac{1}{4} \cdot Y' \cdot \begin{bmatrix} 1 & -1 & 0 & 0 \\ -1 & 1 & 0 & 0 \\ 0 & 0 & 1 & -1 \\ 0 & 0 & -1 & 1 \end{bmatrix} \cdot Y \quad (2.4.9)$$

$$\hat{\sigma}_\alpha^2 = \frac{1}{8} \cdot Y' \cdot \begin{bmatrix} 0 & -2 & 1 & 1 \\ -2 & 0 & 1 & 1 \\ 1 & 1 & 0 & -2 \\ 1 & 1 & -2 & 0 \end{bmatrix} \cdot Y \quad (2.4.10)$$

A condição para que  $\hat{\alpha}_e^2$  seja uma quantidade não negativa é que a matriz envolvida na forma quadrática (2.4.9) seja *não negativa definida* (n.n.d.), o mesmo acontecendo para  $\hat{\sigma}_\alpha^2$ . Pelo *Teorema da Redução Canônica* de matrizes (ver Rao [1973]) sabemos que  $A$  é uma matriz simétrica, existe uma matriz ortogonal  $U$  tal que  $A = UD'U$ , onde  $D$  é uma matriz diagonal com os elementos da diagonal iguais às raízes características de  $A$ , e a matriz  $U$  tem como colunas vetores característicos (associados às raízes características de  $A$ ) unitários e mutuamente ortogonais.

No nosso exemplo temos que a matriz associada a (2.4.9) possui quatro raízes características ( $\lambda_1 = \lambda_2 = 0$  e  $\lambda_3 = \lambda_4 = 2$ ) todas maiores ou iguais a zero, possibilitando-nos escrever,

$$\begin{aligned} Y'AY &= Y'UDU'Y = \\ &= Z'DZ = \\ &= Z'D^{1/2} \cdot D^{1/2}Z \geq 0, \text{ porque } \acute{e} \text{ uma SQ de reais} \\ &\implies A \acute{e} \text{ n.n.d.} \end{aligned}$$

Temos que  $D^{1/2}$  é uma matriz diagonal com os elementos da diagonal definidos como a raiz quadrada dos elementos correspondentes da diagonal  $D$ . Em síntese podemos dizer que,  $\hat{\sigma}_e^2$  sempre será estimado de maneira não negativa por uma forma quadrática não viciada, quando usamos o método da ANOVA.

Já a matriz associada a (2.4.10) possui como raízes características ( $\lambda_1=0$ ,  $\lambda_2 = \lambda_3 = 2$ ,  $\lambda_4 = -4$ ). Como uma matriz simétrica n.n.d. possui todas as raízes características  $\lambda_j \geq 0$  (ver Rao [1973]), podemos dizer que a matriz associada a (2.4.10) não é n.n.d., indicando que nem sempre  $Y'AY \geq 0$ , isto é, há possibilidade de  $\hat{\sigma}_\alpha^2$  ser uma quantidade negativa.

Como já sabemos que podemos estimar  $\sigma_\alpha^2$  por uma quantidade negativa, uma pergunta que talvez surja, seja: não seria possível calcular a probabilidade de obter uma estimativa negativa para o componente  $\sigma_\alpha^2$ , no modelo aqui discutido? A possibilidade passa a existir a partir do instante em que são satisfeitas as suposições,

$$\alpha_i \sim N(0, \sigma_\alpha^2) \quad \text{e} \quad e_{ij} \sim N(0, \sigma_e^2)$$

no modelo

$$y_{ij} = \mu + \alpha_i + e_{ij}, \quad i=1, \dots, m \text{ e } j=1, \dots, n$$



fazendo com que

$$\frac{SQE}{E(QME)} = \frac{(m-1)QME}{\sigma_e^2 + n\sigma_\alpha^2} \sim \chi^2_{(m-1)}$$

$$\frac{SQD}{E(QMD)} = \frac{m(n-1)QMD}{\sigma_e^2} \sim \chi^2_{m(n-1)}$$

e

$$\frac{(QME)/(\sigma_e^2 + n\sigma_\alpha^2)}{(QMD)/\sigma_e^2} = \frac{QME}{QMD} \cdot \frac{\alpha_e^2}{\sigma_e^2 + n\sigma_\alpha^2} \sim F_{(m-1), m(n-1)}$$

E como,

$$\hat{\sigma}_\alpha^2 = n^{-1}(QME - QMD) < 0 \text{ se } (QME/QMD) < 1$$

temos então que

$$\begin{aligned} \Pr\{\hat{\sigma}_\alpha^2 < 0\} &= \Pr\{(QME/QMD) < 1\} = \\ &= \Pr\left\{\frac{QME}{QMD} \cdot \frac{\sigma_e^2}{\sigma_e^2 + n\sigma_\alpha^2} < \frac{\sigma_e^2}{\sigma_e^2 + n\sigma_\alpha^2}\right\} = \\ &= \Pr\left\{F_{(m-1), m(n-1)} < \frac{\sigma_e^2}{\sigma_e^2 + n\sigma_\alpha^2}\right\} \\ &= \Pr\left\{F_{(m-1), m(n-1)} < \frac{1}{1 + n\rho}\right\} \end{aligned}$$

onde  $\rho = \sigma_\alpha^2 / \sigma_e^2$ .

Isto significa que se conhecermos a relação entre  $\sigma_\alpha^2$  e  $\sigma_e^2$ , podemos calcular a probabilidade de obtermos uma estimativa negativa para o componente  $\sigma_\alpha^2$ .

Voltando ao exemplo discutido nesta seção, onde  $m=n=2$ , podemos formar o quadro abaixo,

$\rho$	0	1/20	1/10	1/5	1/2	1	2	10	20
$\text{Pr}\{\hat{\sigma}_\alpha^2 < 0\}$	0,58	0,56	0,54	0,51	0,45	0,38	0,30	0,16	0,10

nos indicando que, num planejamento do tipo visto neste exemplo específico, a probabilidade de obtermos uma estimativa negativa (usando um estimador quadrático e não viciado) para o componente  $\sigma_\alpha^2$ , não é das menores, pelo menos no intervalo  $0 \leq \sigma_\alpha^2 < \sigma_e^2$ .

Usando as mesmas idéias, e apenas a título de ilustração, podemos calcular algumas probabilidades de obtenção de uma estimativa negativa para o componente  $\sigma_\alpha^2$ , a partir de um planejamento do tipo visto no início do Capítulo 1, onde  $m=n=4$ ; isto nos daria

$\rho$	0	1/5	1	2	10
$\text{Pr}\{\hat{\sigma}_\alpha^2 < 0\}$	0,57	0,35	0,11	0,05	0,005

Já aqui, poderíamos dizer por exemplo, que a probabilidade de estimarmos como negativo o componente  $\sigma_\alpha^2$ , não é pequena no intervalo  $0 \leq \sigma_\alpha^2 < (1/5)\sigma_e^2$ .

## CAPÍTULO 3

### INFERÊNCIA BAYESIANA DE COMPONENTES DE VARIÂNCIA

Nos capítulos precedentes discorreremos sobre a estimação dos componentes de variância, dando ênfase ao problema de estimativas negativas desses componentes. No entanto, toda a nossa discussão fez-se à luz da teoria clássica.

No presente capítulo nos propomos a estudar o problema de "estimação" dos componentes de variância dentro do contexto bayesiano. Como nosso objetivo primeiro, é o de permitir um acompanhamento "pari-passu" das idéias, que aqui serão desenvolvidas, a nossa abordagem será feita a partir de algumas noções básicas da inferência bayesiana. Em seguida, tendo por base o modelo aleatório simples em dados balanceados, "estimaremos", por métodos bayesianos, os componentes de variância.

#### 3.1 - A IDÉIA DA INFERÊNCIA BAYESIANA

Seja  $X$  uma variável aleatória cuja função densidade de probabilidade<sup>(\*)</sup> (f.d.p.) é  $f(x/\theta)$ , onde  $\theta \in \Theta$ . Se  $\theta$  for conhecido, a distribuição de probabilidade estará totalmen-

---

(\*) - A terminologia densidade é aqui usada tanto para variável aleatória discreta como para variável aleatória contínua.

te especificada, e não haverá problemas de *estimação*. Mas, na prática, o comum é  $\theta$  ser desconhecido, e neste caso, como proceder?

Até o momento, o nosso problema de estimação foi encarado da seguinte maneira: "Retira-se uma amostra

$$\vec{X}' = (X_1, \dots, X_n)$$

da população que tem f.d.p.  $f(x/\theta)$  e, com base nos valores amostrais  $\vec{x}' = (x_1, \dots, x_n)$  estima-se o parâmetro desconhecido  $\theta$ ". Melhor dizendo, o problema é definir uma função  $t = t(\vec{x})$ , tal que se  $\vec{x}' = (x_1, x_2, \dots, x_n)$  são os valores amostrais observados de  $\vec{X}' = (X_1, X_2, \dots, X_n)$  então  $t(\vec{x})$  será a *estimativa* de  $\theta$ . Tal procedimento faz parte do que será chamado, por nós, de *estimação clássica*.

Na abordagem bayesiana existe uma diferença fundamental, pois  $\theta$  não mais será suposto um parâmetro, mas sim uma variável aleatória, com f.d.p.  $f(\theta)$ .

Suponha como anteriormente, que retiramos uma amostra aleatória  $\vec{X}' = (X_1, \dots, X_n)$  com o intuito de obtermos informações sobre  $\theta$ . Na situação clássica  $f(x/\theta)$  indicava a densidade da variável aleatória  $X$ , com  $\theta$  sendo suposto fixo. Agora que  $\theta$  é uma variável aleatória,  $f(x/\theta)$  representa a densidade condicional de  $X$ , dado  $\theta$  fixado. Temos então que

$$f(\vec{x}'|\theta) \cdot f(\theta) = f(\vec{x}', \theta) = f(\theta|\vec{x}') \cdot f(\vec{x}') \quad (3.1.1)$$

Dadas as observações  $\vec{x}'$ , a densidade condicional de  $\theta$  é

$$f(\theta|\vec{x}') = \frac{f(\vec{x}'|\theta) \cdot f(\theta)}{f(\vec{x}')} = c \cdot f(\vec{x}'|\theta) \cdot f(\theta) \quad (3.1.2)$$

onde

$$f(\vec{x}) = E\{f(\vec{x}|\theta)\} = c^{-1} = \begin{cases} \int f(\vec{x}|\theta) \cdot f(\theta) \cdot d\theta, & \text{se } \theta \text{ é v.a.} \\ & \text{contínua} \\ \sum f(\vec{x}|\theta) \cdot f(\theta), & \text{se } \theta \text{ é v.a. dis-} \\ & \text{creta} \end{cases}$$

isto porque  $E\{g(\theta)\}$  é a esperança matemática de  $g(\theta)$  com respeito à distribuição  $f(\theta)$ .

A relação (3.1.2) ou sua equivalente é usualmente referida na literatura como o *Teorema de Bayes*. Nesta expressão,  $f(\theta)$  representa o nosso conhecimento sobre  $\theta$ , antes de observarmos os dados, e será chamada de *distribuição "a priori"* de  $\theta$ ; correspondentemente,  $f(\theta|\vec{x})$  representa o nosso conhecimento sobre  $\theta$  após observarmos os dados, e será chamada de *distribuição "a posteriori"* de  $\theta$  dado as observações;  $c$  é simplesmente uma constante de normalização, necessária para que a integral (ou soma) de  $f(\theta|\vec{x})$  sobre  $\theta$  seja 1. Por uma questão de simplicidade chamaremos em algumas ocasiões  $f(\theta)$  de "priori" e  $f(\theta|\vec{x})$  de "posteriori".

$$\text{Como } L(\theta|\vec{x}) = \prod_{i=1}^n f(x_i|\theta) = f(x_1|\theta) \dots f(x_n|\theta) = f(\vec{x}|\theta) \quad (3.1.3)$$

podemos escrever a partir de (3.1.2) que,

$$\boxed{\text{distribuição "a posteriori"} \propto \text{verossimilhança} \times \text{distribuição "a priori"}} \quad (3.1.4)$$

Em (3.1.4) temos de uma maneira sintética a idéia da inferência bayesina: a "priori" expressa a nossa opinião sobre  $\theta$  antes do experimento ser realizado, a *verossimilhança*

ça expressa a informação contida na amostra, e a "posteriori" expressa a nossa opinião final sobre  $\theta$  após a realização do experimento. Melhor dizendo,  $f(\theta)$  é um modelo probabilístico representativo do nosso suposto conhecimento sobre a variável aleatória  $\theta$ ,  $f(\theta|\vec{x})$  é o modelo probabilístico que representa o nosso conhecimento "calibrado" pela amostra, e  $L(\theta|\vec{x})$  é o mecanismo de "calibração". O problema da inferência bayesiana está resolvido no momento em que encontramos a distribuição "a posteriori".

### 3.2 - INFERÊNCIA BAYESIANA DE COMPONENTES DE VARIÂNCIA NUM MODELO ALEATÓRIO SIMPLES

Nesta seção, que abrange praticamente todo o Capítulo 3 dessa monografia, nos fixaremos no modelo aleatório simples e adotaremos a "abordagem bayesiana" no problema de "estimação" dos componentes de variância. Para isto, será necessário especificarmos detalhadamente o modelo, encontrarmos a função de verossimilhança e determinarmos a distribuição "a priori". Com isso em mãos, poderemos obter a distribuição "a posteriori".

#### 3.2.1 - O MODELO

Como preliminar introduziremos um sumário de notação e suposições que serão utilizadas no modelo que adotaremos, dado por

$$y_{ij} = \mu + \alpha_i + e_{ij}, \quad i=1, \dots, m, \quad j=1, \dots, n \quad (3.2.1.1)$$

onde  $\mu$  é um parâmetro de locação desconhecida,  $\alpha_1, \dots, \alpha_m$  e  $e_{11}, \dots, e_{mn}$  são variáveis aleatórias não observáveis, conjuntamente independentes, com  $\alpha_i \sim N(0, \sigma_\alpha^2)$  e  $e_{ij} \sim N(0, \sigma_e^2)$ . É um

fato conhecido (ver Graybill & Multquist [1961]) que

$$(\bar{y}_{..}, \text{SQE}, \text{SQD})$$

é uma estatística suficiente minimal para  $(\mu, \sigma_{\alpha}^2, \sigma_e^2)$ , onde

$$\left. \begin{aligned} \bar{y}_{..} &= N^{-1} \sum_{ij} y_{ij} \\ \text{SQE} &= \sum_{ij} (\bar{y}_{i.} - \bar{y}_{..})^2 \\ \text{SQD} &= \sum_{ij} (y_{ij} - \bar{y}_{i.})^2 \end{aligned} \right\} \quad (3.2.1.2)$$

com  $\bar{y}_{i.} = n^{-1} \sum_j y_{ij}$  e  $N = mn$ .

Além do mais, as componentes de  $(\bar{y}_{..}, \text{SQE}, \text{SQD})$  são independentemente distribuídas dado  $(\mu, \sigma_{\alpha}^2, \sigma_e^2)$  como

$$\left. \begin{aligned} \bar{y}_{..} &\sim N(\mu, \bar{\sigma}^2/N) \\ \text{SQE} &\sim \bar{\sigma}^2 \chi_{v_{\alpha}}^2 \\ \text{SQD} &\sim \sigma_e^2 \chi_{v_e}^2 \end{aligned} \right\} \quad (3.2.1.3)$$

onde  $\bar{\sigma}^2 = \sigma_e^2 + n\sigma_{\alpha}^2$ ,  $v_{\alpha} = m-1$  e  $v_e = m(n-1)$ .

Temos também que

$$\left. \begin{aligned} \text{QME} &= \text{SQE}/v_{\alpha} \\ \text{QMD} &= \text{SQD}/v_e \end{aligned} \right\} \quad (3.2.1.4)$$

Já é sabido que

$$\hat{\sigma}_\alpha^2 = n^{-1}(\text{QME-QMD})$$

é o estimador não viciado de mínima variância para  $\sigma_\alpha^2$ . Esse é o estimador da ANOVA que foi discutido no Capítulo 1 e que, também pertence à classe dos estimadores que tiveram algumas propriedades de estimabilidade discutidas no Capítulo 2

### 3.2.2 - A FUNÇÃO DE VEROSSIMILHANÇA

Para o modelo (3.2.1.1) vimos anteriormente em (2.3.5) que,

$$\text{cov}(y_{ij}, y_{i'j'}) = \begin{cases} \sigma_\alpha^2 + \sigma_e^2, & \text{se } i=i' \text{ e } j=j' \\ \sigma_\alpha^2 & , \text{ se } i=i' \text{ e } j \neq j' \\ 0 & , \text{ se } i \neq i' \end{cases}$$

A função de verossimilhança para  $y_{ij}$  será

$$\begin{aligned} L(\vec{\theta} | \vec{y}) &= f(y_{11}, \dots, y_{1n}, y_{21}, \dots, y_{2n}, \dots, y_{m1}, \dots, y_{mn}) = \\ &= f(y_{11}, \dots, y_{1n}) f(y_{21}, \dots, y_{2n}) \dots f(y_{m1}, \dots, y_{mn}) = \\ &= f(\vec{y}_1) f(\vec{y}_2) \dots f(\vec{y}_m) \end{aligned}$$

onde  $\vec{\theta}' = (\mu, \sigma_\alpha^2, \sigma_e^2)$ ,  $\vec{y}' = (y_{11}, \dots, y_{mn})$ . E mais,  $\vec{y}_i$  ( $i=1, \dots, m$ ) tem distribuição  $N(\mu^*, V^*)$  com  $\mu^* = 1_n \mu$  e  $V^* = \sigma_e^2 I_n + \sigma_\alpha^2 J_n$  [ver (2.3.6)]. Então,

$$f(\vec{y}_i) = (2\pi)^{-n/2} \cdot |V^*|^{-1/2} \cdot \exp\{-\frac{1}{2}(\vec{y}_i - \mu^*)' (V^*)^{-1} (\vec{y}_i - \mu^*)\}$$

o que faz com que

$$L(\vec{\theta} | \vec{y}) = (2\pi)^{-\frac{1}{2}mn} \cdot |V^*|^{-m/2} \cdot \exp\{-\frac{1}{2} \sum_{i=1}^m (\vec{y}_i - \mu^*)' (V^*)^{-1} (\vec{y}_i - \mu^*)\}$$



Por Graybill [1961] temos que

$$|V^*| = (\sigma_e^2)^{n-1} \cdot (\sigma_e^2 + n\sigma_\alpha^2)$$

e também que

$$\sum_{i=1}^m (\vec{y}_i - \mu^*)' (V^*)^{-1} (\vec{y}_i - \mu^*) = \frac{1}{\sigma_e^2} \sum_{ij} (y_{ij} - \bar{y}_{i.})^2 + \\ + \frac{1}{\sigma_e^2 + n\sigma_\alpha^2} \left[ \sum_{ij} (\bar{y}_{i.} - \bar{y}_{..})^2 + \frac{nm(\bar{y}_{..} - \mu)^2}{\sigma_e^2 + n\sigma_\alpha^2} \right]$$

Então, podemos escrever

$$L(\vec{\theta} | \vec{y}) \propto (\sigma_e^2)^{-v_e/2} \cdot (\sigma_e^2 + n\sigma_\alpha^2)^{-(v_e+1)/2} \cdot \\ \cdot \exp \left\{ -\frac{1}{2} \left[ \frac{SQD}{\sigma_e^2} + \frac{SQE}{\sigma_e^2 + n\sigma_\alpha^2} + \frac{nm(\bar{y}_{..} - \mu)^2}{\sigma_e^2 + n\sigma_\alpha^2} \right] \right\}$$

ou

$$L(\vec{\theta} | \vec{y}) \propto (\sigma_e^2)^{-v_e/2} \cdot (\sigma_e^2 + n\sigma_\alpha^2)^{-(v_\alpha+1)/2} \cdot \\ \cdot \exp \left\{ -\frac{1}{2} \left[ \frac{v_e QMD}{\sigma_e^2} + \frac{v_\alpha QME}{\sigma_e^2 + n\sigma_\alpha^2} + \frac{nm(\bar{y}_{..} - \mu)^2}{\sigma_e^2 + n\sigma_\alpha^2} \right] \right\}$$

onde  $v_e$  e  $v_\alpha$  são definidos como em (3.2.1.3).

### 3.2.3 - A DISTRIBUIÇÃO "A PRIORI" NÃO-INFORMATIVA

A partir desse momento, temos como principal objetivo, a determinação da nossa "priori"  $f(\vec{\theta})$  onde

$$\vec{\theta}' = (\mu, \sigma_\alpha^2, \sigma_e^2).$$

Partiremos da suposição de que existe *pouco* ou *nenhum* conhe

cimento sobre  $\vec{\theta}$ , e neste caso a nossa "priori" chamar-se-á *não-informativa* (é aquela que não altera a informação fornecida pela amostra).

De início suponha que nossas opiniões sobre  $\mu$  são *a priori* independentes daquelas sobre  $(\sigma_\alpha^2, \sigma_e^2)$ . Então,

$$f(\mu, \sigma_\alpha^2, \sigma_e^2) = f(\mu) \cdot f(\sigma_\alpha^2, \sigma_e^2) \quad (3.2.3.1)$$

Como  $f(\mu) \propto$  constante (ver Apêndice A), temos,

$$f(\mu, \sigma_\alpha^2, \sigma_e^2) \propto f(\sigma_\alpha^2, \sigma_e^2) \quad (3.2.3.2)$$

E a *a priori não-informativa* para  $\sigma_\alpha^2$  e  $\sigma_e^2$  poderá ser obtida a través da aplicação da regra de Jeffreys: "a priori não-informativa para o vetor paramétrico  $(\sigma_\alpha^2, \sigma_e^2)$  é tomada como sendo proporcional à raiz quadrada do determinante da matriz de informação" (ver Apêndice A). Isto é,

$$f(\sigma_\alpha^2, \sigma_e^2) \propto |\text{Inf}(\sigma_\alpha^2, \sigma_e^2)|^{1/2} \quad (3.2.3.3)$$

onde,

$$\text{Inf}(\sigma_\alpha^2, \sigma_e^2) = E \left\{ - \frac{\partial^2 \log L(\vec{\theta} | \vec{y})}{\partial \sigma_\alpha^2 \cdot \partial \sigma_e^2} \right\} = \frac{1}{2} \begin{bmatrix} \frac{v_\alpha + 1}{\bar{\sigma}^4} + \frac{v_e}{2\sigma_e^2} & \frac{n(v_\alpha + 1)}{\bar{\sigma}^4} \\ \frac{n(v_\alpha + 1)}{\bar{\sigma}^4} & \frac{n^2(v_\alpha + 1)}{\bar{\sigma}^4} \end{bmatrix}$$

e como,

$$|\text{Inf}(\sigma_\alpha^2, \sigma_e^2)| = \frac{n^2 v_e (v_\alpha + 1)}{2} \cdot \frac{1}{(\sigma_e^2)^2 (\sigma_e^2 + \sigma_\alpha^2)^2}$$

segue que

$$f(\mu, \sigma_\alpha^2, \sigma_e^2) \propto \frac{1}{\sigma_e^2 (\sigma_e^2 + n\sigma_\alpha^2)} \quad (3.2.3.4)$$

Maneiras alternativas de obtermos a priori (3.2.3.4) são encontrados no artigo de Tiao & Tan [1965] e no livro de Box & Tiao [1973].

### 3.2.4 - AS DISTRIBUIÇÕES "A POSTERIORI"

Por (3.1.4) temos que

$$f(\vec{\theta}|\vec{y}) \propto L(\vec{\theta}|\vec{y}) \times f(\vec{\theta})$$

onde  $\vec{\theta} = (\mu, \sigma_\alpha^2, \sigma_e^2)$ . Pelos resultados de (3.2.2.1) e (3.2.3.4) podemos escrever

$$f(\mu, \sigma_\alpha^2, \sigma_e^2|\vec{y}) \propto (\sigma_e^2)^{-v_e/2} \cdot (\sigma_e^2 + n\sigma_\alpha^2)^{-(v_\alpha+1)/2} \cdot \exp\left\{-\frac{1}{2}\left[\frac{v_e \text{QMD}}{\sigma_e^2} +\right.\right.$$

$$\left. + \frac{v_\alpha \text{QME}}{\sigma_e^2 + n\sigma_\alpha^2} + \frac{nm(\bar{y}.. - \mu)^2}{\sigma_e^2 + n\sigma_\alpha^2}\right\} \times (\sigma_e^2)^{-1} (\sigma_e^2 + n\sigma_\alpha^2)^{-1} =$$

$$= (\sigma_e^2)^{-\left(\frac{1}{2}v_e + 1\right)} \cdot (\sigma_e^2 + n\sigma_\alpha^2)^{-\frac{1}{2}(v_\alpha+1)-1} \times$$

$$\times \exp\left\{-\frac{1}{2}\left[\frac{v_e \text{QMD}}{\sigma_e^2} + \frac{v_\alpha \text{QME}}{\sigma_e^2 + n\sigma_\alpha^2} + \frac{nm(\bar{y}.. - \mu)^2}{\sigma_e^2 + n\sigma_\alpha^2}\right]\right\},$$

$$-\infty < \mu < \infty, \sigma_e^2 > 0, \sigma_\alpha^2 > 0 \quad (3.2.4.1)$$

Mas como nosso objetivo básico é fazer inferências sobre  $\sigma_e^2$  e  $\sigma_\alpha^2$ , e não sobre  $\vec{\theta}$ , devemos de início pensarem obter a distribuição conjunta "a posteriori" de  $(\sigma_e^2, \sigma_\alpha^2)$  e as distribuições "a posteriori" de  $\sigma_e^2$  e  $\sigma_\alpha^2$ .

#### A DISTRIBUIÇÃO CONJUNTA "A POSTERIORI" DE $(\sigma_\alpha^2, \sigma_e^2)$

A idéia natural para obtermos a distribuição "a pos

teriori" de  $(\sigma_\alpha^2, \sigma_e^2)$  é a de integrarmos (3.2.4.1) sobre  $\mu$ , o que nos dará

$$f(\sigma_\alpha^2, \sigma_e^2 | \vec{y}) = K \cdot (\sigma_e^2)^{-\frac{1}{2}(v_e+1)} \cdot (\sigma_\alpha^2)^{-\frac{1}{2}(v_\alpha+1)} \cdot \exp \left\{ -\frac{1}{2} \left[ \frac{v_e \text{QMD}}{\sigma_e^2} + \frac{v_\alpha \text{QME}}{\sigma_e^2 + n\sigma_\alpha^2} \right] \right\},$$

$$\sigma_e^2 > 0, \sigma_\alpha^2 > 0 \quad (3.2.4.2)$$

onde

$$K = \frac{n(v_e \text{QME})^{\frac{1}{2}v_e} \cdot (v_\alpha \text{QMD})^{\frac{1}{2}v_\alpha} \cdot 2^{-\frac{1}{2}(v_e+v_\alpha)}}{\Gamma(\frac{1}{2}v_e) \cdot \Gamma(\frac{1}{2}v_\alpha) \cdot \Pr\{F_{v_\alpha, v_e} < \text{QME/QMD}\}}$$

resultado encontrado por Box & Tiao [1973].

Usando a definição da distribuição  $\chi^{-2}$  (ver Apêndice B), Box & Tiao [1973] escreveram (3.2.4.2) como

$$f(\sigma_\alpha^2, \sigma_e^2 | \vec{y}) = \frac{(v_e \text{QMD})^{-1} f(\chi_{v_e}^{-2} = \sigma_e^2 / v_e \text{QMD}) n(v_\alpha \text{QME})^{-1} \cdot f[\chi_{v_\alpha}^{-2} = (\sigma_e^2 + n\sigma_\alpha^2) / v_\alpha \text{QME}]}{\Pr\{F_{v_\alpha, v_e} < \text{QME/QMD}\}},$$

$$\sigma_e^2 > 0, \sigma_\alpha^2 > 0 \quad (3.2.4.3)$$

onde  $f(\chi_v^{-2} = x)$  é a densidade de uma variável  $\chi^{-2}$  com  $v$  g.l. avaliados em  $x$ .

A DISTRIBUIÇÃO "A POSTERIORI" DE  $\sigma_e^2$

Se integrarmos (3.2.4.3) sobre  $\sigma_\alpha^2$ , obviamente obteremos  $f(\sigma_e^2 | \vec{y})$ . Segundo Box & Tiao [1973] a distribuição "a posteriori" do componente de variância  $\sigma_e^2$ , é dada por

$$f(\sigma_e^2 | \vec{y}) = \frac{(v_e \text{QMD})^{-1} \cdot f(\chi_{v_e}^{-2} = \sigma_e^2 / v_e \text{QMD}) \cdot \Pr\{\chi_{v_\alpha}^2 < v_\alpha \text{QME} / \sigma_e^2\}}{\Pr\{F_{v_\alpha, v_e} < \text{QME} / \text{QMD}\}}$$

$\sigma_e^2 > 0$  (3.2.4.4)

A distribuição "a posteriori" de  $\sigma_e^2$  é igual ao produto de dois fatores, o primeiro sendo a densidade de uma variável  $\chi^{-2}$  com  $v_e$  graus de liberdade e o segundo, a razão de uma probabilidade sobre a  $\chi^2$  e de uma probabilidade sobre a F.

A DISTRIBUIÇÃO "A POSTERIORI" DE  $\sigma_\alpha^2$

Chegamos ao ponto que cria mais problemas, quando usamos a abordagem clássica da inferência estatística, que é o de fazermos inferências sobre o componente da variância  $\sigma_\alpha^2$ . Como já vimos anteriormente, na abordagem clássica, o estimador de  $\sigma_\alpha^2$  que é mais usado e que apresenta a propriedade de ser não viciado e de mínima variância, em algumas situações, produz estimativas negativas.

Na abordagem bayesiana não temos o tipo de problema especificado acima, pois a "posteriori" de  $\sigma_\alpha^2$  está definida no intervalo  $\sigma_\alpha^2 > 0$ .

A obtenção da "posteriori" para  $\sigma_\alpha^2$  segue, em linhas

gerais, a mesma idéia até aqui adotada. Então, devemos integrar (3.2.4.3) sobre  $\sigma_e^2$ , o que nos dará,

$$f(\sigma_\alpha^2 | \vec{y}) = \omega \cdot \int_0^\infty f\left(\chi_{v_\alpha}^{-2} = \frac{\sigma_e^2 + n\sigma_\alpha^2}{v_\alpha \text{QME}}\right) \cdot f\left(\chi_{v_e}^{-2} = \frac{\sigma_e^2}{v_e \text{QMD}}\right) \cdot d\sigma_e^2,$$

$\sigma_\alpha^2 > 0$  (3.2.4.5)

onde

$$\omega = \frac{n \cdot (v_e \text{QMD})^{-1} \cdot (v_\alpha \text{QME})^{-1}}{\Pr\{F_{v_\alpha, v_e} < \text{QME/QMD}\}}$$

Isto é, usando a "priori não-informativa" vista em (3.2.3.4), a distribuição  $f(\sigma_\alpha^2 | \vec{y})$  contém todo o conhecimento "a posteriori" sobre  $\sigma_\alpha^2$ . Observe que  $f(\sigma_\alpha^2 | \vec{y})$  está definida no intervalo  $(0, +\infty)$ .

Não parece possível expressar  $f(\sigma_\alpha^2 | \vec{y})$  por funções simples, fazendo com que a densidade para cada valor de  $\sigma_\alpha^2$  seja obtida por processos numéricos. Em (3.2.4.5) a partir do momento em que temos as observações amostrais, passamos a conhecer as quantidades à esquerda da integral, e as duas funções que constituem o integrando dependem de  $\sigma_e^2$  e  $\sigma_\alpha^2$ . Se dermos valores a  $\sigma_\alpha^2$ , e usarmos uma técnica adequada de integração numérica, obteremos os correspondentes valores de

$$f(\sigma_\alpha^2 | \vec{y}).$$

Numa etapa posterior voltaremos a este problema quando da resolução de um exemplo.

Box & Tiao [1973], discutem algumas aproximações,

que podem ser usadas, para expressar  $f(\sigma_\alpha^2 | \vec{y})$  por funções simples. No entanto, aqui não nos ateremos a esse problema.

Algumas características da "posteriori" de  $\sigma_\alpha^2$ , dada por (3.2.4.5) são estudadas por Box & Tiao [1973]. Quando da resolução do exemplo a ser dado discutiremos algumas delas.

### 3.2.5 - OS ESTIMADORES DE BAYES

Quando especificamos a distribuição "a posteriori" de  $\theta$ , temos resolvido o nosso problema de inferência bayesiana. No entanto, às vezes, alguém mais desavisado deseja representar  $\theta$  de uma maneira mais simples, e a idéia natural é a de procurar uma constante que represente a distribuição "a posteriori". Ou melhor dizendo, desejamos sintetizar a informação contida na "posteriori", através de uma constante. Esta idéia inicial de simplificação, torna-se difícil, no momento em que desejamos saber qual a melhor constante e qual o método geral de escolha.

A essa constante acima comentada, alguns autores deram o nome de *Estimador de Bayes*. Barnett [1973] caracteriza como estimador de Bayes a moda da "posteriori", já Mood, Graybill & Boes [1974] definem a *média* da "posteriori" como sendo o estimador de Bayes. Por essas duas definições, com a primeira acompanhada da justificativa: "... uma interpretação direta do valor mais provável para  $\theta$ .."; e a segunda, sem maiores detalhes explicativos por parte dos autores, sentimos a arbitrariedade da idéia do "estimador de Bayes".

A idéia desses "estimadores" dentro do contexto da inferência bayesiana, não deixa de ser uma influência da teoria clássica. Esta influência dá margem a uma abordagem dual

ao problema, pois especificamente, a "posteriori" é obtida, mas não usada diretamente para fazermos inferências sobre  $\theta$ , e sim utilizada para sugerir constantes a serem usadas como "estimadores". Uma discussão detalhada desse problema encontra-se em Tiao & Box [1972]. Procurando dar uma melhor visão do problema resolvemos o exemplo abaixo.

### 3.3 - UM EXEMPLO

A partir da situação discutida em 1.1, obtemos

$$v_\alpha = 3, v_e = 12, n = 4, QME = 3,7, QMD = 54.$$

O nosso objetivo aqui é a obtenção da "posteriori" do componente de variância  $\sigma_\alpha^2$ . Por (3.2.4.5) temos que, após algumas simplificações

$$F(\sigma_\alpha^2 | \vec{y}) = \frac{n(v_\alpha QME)^{-1} (v_e QMD)^{-1}}{\Pr\{F_{v_\alpha, v_e} < QME/QMD\}} \cdot \frac{1}{\Gamma(v_\alpha | 2) \cdot 2^{v_\alpha/2} \cdot \Gamma(v_e | 2) \cdot 2^{v_e/2}} \cdot \left(\frac{1}{v_\alpha QME}\right)^{-\left(\frac{v_\alpha}{2} + 1\right)} \cdot \left(\frac{1}{v_e QMD}\right)^{-\left(\frac{v_e}{2} + 1\right)} \cdot \int_0^\infty (\sigma_e^2 + n\sigma_\alpha^2)^{-\left(\frac{v_\alpha}{2} + 1\right)} \cdot (\sigma_e^2)^{-\left(\frac{v_e}{2} + 1\right)} \cdot \exp\left\{\frac{-v_\alpha QME}{2\sigma_e^2 + 2n\sigma_\alpha^2}\right\} \cdot \exp\left\{\frac{-v_e QMD}{2\sigma_e^2}\right\} \cdot d\sigma_e^2.$$

Após a substituição dos valores vistos no início desta seção e notando  $\sigma_\alpha^2$  por  $X$ ,  $\sigma_e^2$  por  $Z$  e o integrando por  $G_X(X, Z)$  temos

$$f(X | \vec{y}) = 2,31 \times 10^{16} \int_0^\infty G_X(X, Z) dZ$$



que é a "posteriori" de  $\sigma_{\alpha}^2$ .

O valor de  $f$  para cada valor de  $X$ , pode ser obtido através da integração numérica da função  $G$ . A técnica de integração numérica usada foi o método de Simpson, ver Hamming [1971]. Após a obtenção desses valores, nos defrontamos com outro tipo de problema: conhecidas algumas ordenadas de


$$f(X|\vec{y})$$

e sabendo que  $0 \leq X < \infty$ , até que o valor da abcissa devemos ir, para que a integral de  $f$  de 0 até esse valor, forneça uma aproximação razoável da área total sob a curva. Obviamente por  $f$  se tratar de uma função densidade, a área total deve ser 1. Todos esses procedimentos numéricos foram executados num computador IBM/370, modelo

e no Apêndice C encontra-se o "programa" com base no qual esses cálculos foram executados. Nesse programa temos como saída as ordenadas de  $f$  a partir de  $X=0$  com incrementos na abcissa de 0,1, e também a área sob a curva de 0 a 1, 0 a 2, 0 a 3, etc. No primeiro teste com  $X$  variando de 0 a 250 obtivemos uma área sob a curva de 0,9781, e na execução final após uma série de testes, trabalhamos com  $X$  de 0 a 1.000, o que nos deu uma área total sob a curva igual a 0,9880, e um tempo total de computação de 38 minutos. Resolvemos adotar esse resultado, porque mesmo que quadruplicássemos esse tempo, obteríamos uma pequena melhora nesta área total, além de não afetar substancialmente as conclusões que poderíamos tirar. Abaixo segue um pequeno sumário de algumas ordenadas da "posteriori" de  $\sigma_{\alpha}^2$ , assim como a idéia gráfica dessa distribuição

$\sigma_{\alpha}^2$	$f(\sigma_{\alpha}^2 \vec{y}) \times 10^5$
0	12.860
0,1	12.540

$\sigma_{\alpha}^2$	$f(\sigma_{\alpha}^2   \vec{y}) \times 10^5$
0,2	12.260
0,3	11.970
0,4	11.700
0,5	11.430
1,0	10.240
2,0	8,358
3,0	6.950
4,0	5.869
5,0	4.338
10,0	2.356
20,0	981
50,0	216
100,0	52
250,0	4
1.000,00	0,2



DISTRIBUIÇÃO "A POSTERIORI" DO COMPONENTE  $\sigma_{\alpha}^2$

Nesse ponto, conseguimos atingir o desejo maior do Estatístico, que "acredita" na Inferência Bayesiana, que é a obtenção da "posteriori". Com base nela serão feitas as inferências necessárias.

É claro que, sob o ponto de vista numérico poderíamos refinar os resultados aqui encontrados, obtendo valores para as ordenadas de  $f$  usando incrementos nas abcissas menores que 0,1, e integrando  $f$  de 0 a um valor maior que 1.000. No entanto esse refinamento não ofereceria maiores vantagens, quando desejássemos tirar conclusões a partir da "posteriori".

Tentando caracterizar a inconsistência da abordagem clássica em cima da Inferência Bayesiana, voltamos à idéia (não aceita pelos "bayesianos") de tentar sumariar a informação contida na "posteriori", através de algumas características dela (estimadores de Bayes). No nosso exemplo encontramos

Moda	=	0,0
Mediana	=	7,4
Média	=	21,3

E agora, o que fazer?

De acordo com Mood, Graybill & Boes [1974] deveríamos ter 21,3 como "estimador de Bayes" para o componente de variância  $\sigma_{\alpha}^2$ . Ora, esse valor fica fora do intervalo

$$0 \leq \sigma^2 < 20,$$

cuja probabilidade é 0,75, em outras palavras, é um valor que está à direita do 3º quartil da distribuição "a posteriori". E convenhamos, não é razoável aceitar o fato de que, essa medida (média) represente melhor a nossa "posteriori" do que a moda (0,0) ou a mediana (7,4). Vale notar que, não somente os autores acima recomendam a *média* como estimador de

Bayes, mas também uma certa quantidade de autores de livros clássicos na Estatística.

Longe de nós a idéia de por exemplo, afirmar que a *moda* é um melhor estimador de Bayes, apesar de no presente exemplo, ela ser mais informativa do que a *média*. É lógico que numa outra situação, poderíamos ter a *média* como melhor representante.

A idéia que temos, que aceitamos, e que sentimos, é a de que admitir Estimador de Bayes, é trair a pureza da Inferência Bayesiana.

## APÊNDICE A

### A PRIORI NÃO-INFORMATIVA

Faremos algumas considerações sobre situações em que desejamos determinar uma "priori" para o parâmetro  $\theta$  e que temos *pouco* ou *nenhum* conhecimento sobre ele, e nesse caso a nossa "priori" chamar-se-á *não-informativa*. Todo esse apêndice será desenvolvido a partir dos comentários feitos por Zellner [1971] sobre "priors não-informativas", quando esse autor baseou-se nas idéias de Sir Harold Jeffreys, desenvolvidas no clássico (para os bayesianos, pelo menos) "Theory of Probability". Introduziremos alguns complementos extraídos de Box & Tiao [1973].

Das recomendações de Jeffreys, de como escolher uma distribuição "a priori", que represente ignorância sobre o parâmetro do modelo sob consideração, podemos extrair duas regras,

REGRA 1 - Se o parâmetro pode assumir qualquer valor no intervalo  $(-\infty, +\infty)$  sua "priori" deverá ser tomada como sendo uniformemente distribuída.

EXEMPLO - Seja o caso de um parâmetro desconhecido  $\mu$  diga-

mos uma média, que possa assumir valores de  $-\infty$  a  $+\infty$ . Então, de acordo com a regra,

$$f(\mu)d\mu \propto d\mu, \quad -\infty < \mu < \infty \quad (\text{A.A1})$$

ou

$$f(\mu) \propto \text{constante}.$$

**REGRA 2** - Se o parâmetro pode assumir qualquer valor no intervalo  $(0, +\infty)$ , a "priori" de seu logaritmo deverá ser tomada como sendo uniformemente distribuída.

**EXEMPLO** - Seja o caso de um parâmetro desconhecido  $\sigma$ , um desvio padrão. Para tal parâmetro Jeffreys sugere

$$\theta = \log \sigma, \text{ e}$$

$$f(\theta)d\theta \propto d\theta, \quad -\infty < \theta < \infty \quad (\text{A.A2})$$

e como  $d\theta/d\sigma = 1/\sigma$ , segue que

$$F(\sigma)d\sigma \propto 1/\sigma d\sigma, \quad 0 < \sigma < \infty$$

Na situação da *Regra 1* nós vemos que a densidade sugerida, é obviamente imprópria, pois

$$\int_{-\infty}^{\infty} f(\mu)d\mu = \infty.$$

Do ponto de vista de Jeffreys isto é uma vantagem, pois

$$\text{Pr}\{a < \mu < b\} / \text{Pr}\{c < \mu < d\} = 0/0$$

é indeterminado onde  $a, b, c$  e  $d$  são quaisquer números finitos, indicando que não podemos fazer qualquer afirmação sobre a chance de que  $\mu$  pertença a algum par de intervalos finitos. Esta propriedade foi vista por Jeffreys como uma representação formal da ignorância. No entanto, o problema da f.d.p. imprópria persiste. Uma idéia que surge naturalmente

é a de considerarmos uma f.d.p. própria da forma

$$f(\mu)d\mu = \frac{1}{2M} d\mu, \quad -M \leq \mu \leq M \quad (\text{A.A3})$$

Mas, infelizmente quando assim procedemos, introduzimos uma informação "a priori" sobre a amplitude de variação de  $\mu$  e então, deixamos de ter ignorância completa sobre  $\mu$ . No entanto, se fizermos  $M \rightarrow \infty$ , podemos olhar (A.A3) como uma boa aproximação para (A.A1).

Como o objetivo de complementar o raciocínio de Jeffreys, Zellner [1971] introduz uma medida de informação dada por

$$H = \int_{-M}^M f(\mu) \log f(\mu) d\mu \quad (\text{A.A4})$$

e verifica que a f.d.p. própria que minimiza  $H$  é (A.A3), e conclui dizendo que a f.d.p. uniforme é uma "priori de informação minimal", e melhor ainda, quando  $M \rightarrow \infty$  (A.A3) é uma boa aproximação para (A.A.1). Além disso Zellner [1971] mostra através de um exemplo que a combinação de uma f.d.p. "a priori" imprópria (A.A.1) com uma função de verossimilhança, através do Teorema de Bayes, fornece uma f.d.p. "a posteriori" própria.

Com relação à *Regra 2*, a mais importante observação feita por Jeffreys é que (A.A2) é invariante sobre transformações da forma  $\phi = \sigma^n$ , isto é,  $d\phi = n\sigma^{n-1}d\sigma$  e então

$$d\phi/\phi \propto d\sigma/\sigma.$$

Além disso ele mostra que  $\Pr\{0 < \sigma < a\} / \Pr\{a < \sigma < \infty\}$  é indeterminada, pois

$$\int_0^\infty d\sigma/\sigma = \infty, \quad \int_0^a d\sigma/\sigma = \infty \quad \text{e} \quad \int_a^\infty d\sigma/\sigma = \infty,$$

sendo isto uma representação formal da ignorância. Zellner

[1971] mostra que a função  $H$  será minimizada tomando  $f(\theta) \propto$  constante, e isto é uma justificativa teórica de informação, para tomarmos  $\theta = \log \sigma$  uniformemente distribuída. Pela propriedade de invariância  $f(\sigma) \propto 1/\sigma$  implica  $f(\sigma^2) \propto 1/\sigma^2$ , que representam a ignorância sobre  $\sigma$  ou  $\sigma^2$ , respectivamente.

Com respeito ainda às idéias de Jeffreys com relação à "prioris não-informativas" Box & Tiao [1973] dão a seguinte

REGRA DE JEFFREYS - A distribuição a priori para um parâmetro  $\theta$  é aproximadamente não-informativa se é tomada proporcional à raiz quadrada da medida de informação de Fisher. Isto é,

$$f(\theta) \propto I^{1/2}(\theta) \quad (\text{A.A5})$$

onde *medida de informação de Fisher* sobre  $\theta$  na amostra  $y' = (y_1, \dots, y_n)$  é definida como

$$I_n(\theta) = E_{\vec{y}|\theta} \left[ - \frac{\partial^2 \log f(\vec{y}|\theta)}{\partial \theta^2} \right] = E_{\vec{y}|\theta} \left[ \frac{\partial \log f(\vec{y}|\theta)}{\partial \theta} \right]^2$$

e

$$I(\theta) = E_{y|\theta} \left[ - \frac{\partial^2 \log f(y|\theta)}{\partial \theta^2} \right]$$

então, quando  $\vec{y}$  é uma amostra aleatória  $I_n(\theta) = nI(\theta)$ . Se aplicarmos esta regra para obtermos "prioris" com relação aos parâmetros  $(\mu, \sigma)$  da Normal, nós obtemos (ver Box & Tiao [1973]) quando

-  $\mu$  desconhecido e  $\sigma$  conhecido.

$$I(\theta) = \text{constante} \implies p(\mu) \propto \text{constante}$$



-  $\sigma$  desconhecido e  $\mu$  conhecido

$$I(\theta) = \frac{1}{\sigma^2} \times \text{constante} \implies p(\sigma) \propto 1/\sigma$$

ou  $p(\log \sigma) \propto \text{constante}$ .

E teremos como uma extensão multiparamétrica a seguinte

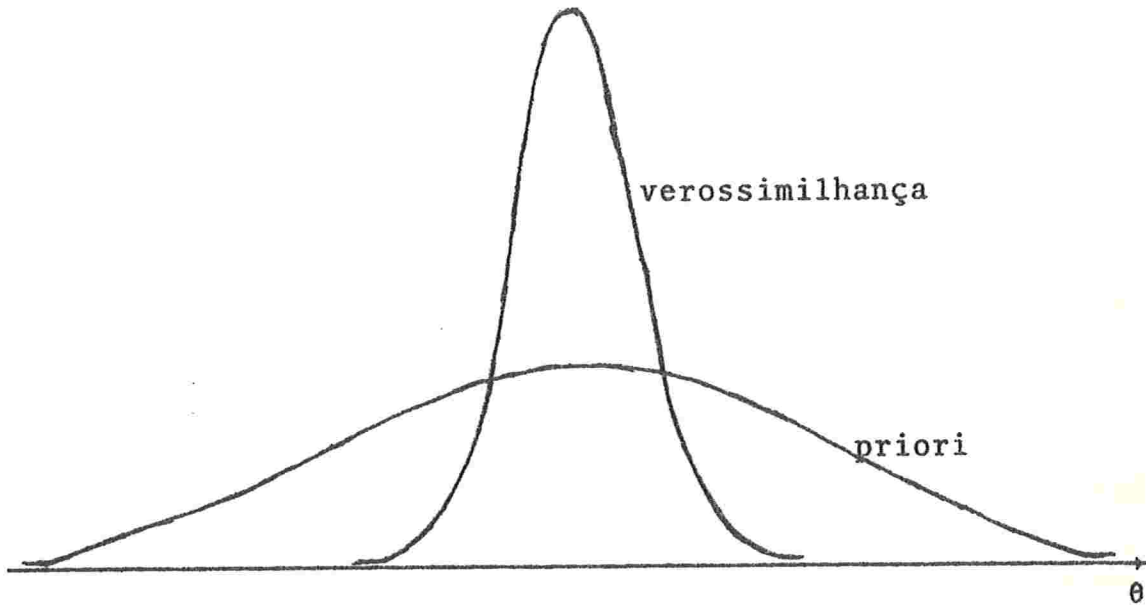
REGRA DE JEFFREYS "MULTIPARAMÉTRICA" - A distribuição a priori para um conjunto de parâmetros é tomada como sendo proporcional à raiz quadrada do determinante da matriz informação. Isto é

$$f(\vec{\theta}) \propto |I_n(\vec{\theta})|^{1/2} \quad (\text{A.A6})$$

Jeffreys obteve esta regra, como no caso do parâmetro simples, requerendo *invariância* sobre transformações de parâmetros. Esta regra no entanto, deve ser aplicada com cuidado, principalmente quando parâmetros de locação e escala ocorrem simultaneamente.

Box & Tiao [1973] fazem algumas considerações sobre alguns "cuidados" que devem ser tomados na aplicação da Regra de Jeffreys. É enfatizado por eles a necessidade de investigarmos as implicações das transformações em cada situação à luz de qualquer conhecimento a priori sobre independência. Quando, por exemplo, em termos de um julgamento a priori temos que  $\theta_1$  em  $\vec{\theta}' = (\theta_1, \theta_2, \dots, \theta_k)$  é independente de  $(\theta_2, \dots, \theta_k)$  aplicamos a regra separadamente para  $\theta_1$  e  $(\theta_2, \dots, \theta_k)$ .

Alguns autores hesitam em empregar as f.d.p. impróprias recomendadas por Jeffreys. Em contrapartida eles introduzem "prioris localmente uniformes", que são prioris "razoavelmente achatadas" sobre o intervalo no qual a verossimilhança assume valores apreciáveis, e não assume grandes valores fora desses intervalos (ver figura na página seguinte).



Como a posteriori  $\propto$  priori  $\times$  verossimilhança, para o caso de uma "priori localmente uniforme", teríamos

posteriori  $\propto$  verossimilhança

A grande vantagem da priori localmente uniforme é que trabalhamos com uma f.d.p. própria. Já como desvantagens temos que a condição de Jeffreys para ignorância completa não está satisfeita, além do fato de termos que conhecer alguma coisa sobre a verossimilhança, o que pode não ser o caso em algumas situações gráficas. No entanto se temos informação sobre a variação de  $\theta$  e a função de verossimilhança é disponível, ela pode ser usada com boa vantagem. Quando esse tipo de informação não existe, pouca diferença prática existe se nós usamos uma priori "localmente uniforme" ou uma f.d.p. imprópria de Jeffreys, Maiores detalhes sobre as idéias envolvidas na escolha de prioris que representam pouco ou nenhum conhecimento sobre o parâmetro, podem ser encontrados em Box & Tiao [1973].

## APÊNDICE B

### A DISTRIBUIÇÃO DO $\chi^2$

Um dos resultados de importância em Estatística, é que se  $X \sim N(\mu, \sigma^2)$ , e se uma amostra  $\vec{X}' = (X_1, \dots, X_n)$  dessa população é retirada, a quantidade

$$\chi_n^2 = \sum_{i=1}^n \frac{(X_i - \mu)^2}{\sigma^2} = \frac{ns^2}{\sigma^2} \quad (\text{A.B1})$$

é

$$f(\chi_n^2) = [\Gamma(n/2) 2^{n/2}]^{-1} \cdot (\chi^2)^{(n/2)-1} \cdot \exp\left\{-\frac{1}{2}\chi^2\right\}, \quad (\text{A.B2})$$

$\chi^2 > 0$

que é a distribuição  $\chi^2$  com n graus de liberdade.

Na teoria clássica (não-bayesiana), se desejamos fazer inferências sobre  $\sigma^2$ , podemos sem maiores problemas usar a distribuição  $\chi^2$ .

Na teoria bayesiana, o problema de fazer inferências sobre  $\sigma^2$ , não é tão direto, isto porque deveremos ter a distribuição "a posteriori" de  $\sigma^2$ , e esta poderá não ser uma  $\chi^2$ .

No caso de termos n observações de  $X \sim N(\mu, \sigma^2)$  e,

*pouco* ou *nenhum* conhecimento "a priori" sobre  $\sigma^2$ .

$$L(\sigma^2 | \vec{x}) \propto (\sigma^2)^{-n/2} \cdot \exp\left\{-\frac{ns^2}{\sigma^2}\right\} \quad (\text{A.B3})$$

$$f(\sigma^2) \propto \sigma^{-2} \quad (\text{ver Apêndice A}) \quad (\text{A.B4})$$

e a distribuição "aposteriori" de  $\sigma^2$ , será dada por

$$f(\sigma^2 | \vec{x}) \propto f(\sigma^2) \cdot L(\sigma^2 | \vec{x}) \quad \text{ou} \quad (\text{A.B5})$$

$$f(\sigma^2 | \vec{x}) = k \cdot (\sigma^2)^{[(n/2)+1]} \cdot \exp\left\{-\frac{ns^2}{2\sigma^2}\right\}, \quad \sigma^2 > 0 \quad (\text{A.B6})$$

A constante de normalização de  $k$  deve garantir que

$$\int_0^{\infty} f = 1$$

Assim procedendo obteremos

$$f(\sigma^2 | \vec{x}) = \frac{(ns^2/2)^{n/2}}{\Gamma(n/2)} \cdot (\sigma^2)^{-[(n/2)+1]} \cdot \exp\left\{-\frac{ns^2}{2\sigma^2}\right\}, \quad \sigma^2 > 0 \quad (\text{A.B7})$$

O resultado acima motivou o " $\chi^2$  invertido" que é obtido de (A.B1), fazendo a transformação

$$\chi_n^{-2} = \frac{1}{\chi_n^2} \quad (\text{A.B8})$$

para produzir

$$f(\chi_n^{-2}) = [\Gamma(n/2) 2^{n/2}]^{-1} \cdot (\chi^{-2})^{-[(n/2)+1]} \cdot \exp\left\{-\frac{1}{2\sigma^{-2}}\right\}, \quad \chi^{-2} > 0 \quad (\text{A.B9})$$

Se compararmos (A.B9) com (A.B7), veremos que "a posteriori"  $\sigma^2/ns^2$  tem distribuição  $\chi_n^{-2}$ .

APÊNDICE C

UM "PROGRAMA" PARA ENCONTRAR A "POSTERIORI" DE  $\sigma^2$

\*\*\*\*\*

```

C VARIÁVEIS INTEIRAS UTILIZADAS NO PROGRAMA
C I - CHAVE PARA DECIDIR QUE FATOR MULTIPLICA A ORDEMADA DA G
C ICNT - CONTADOR DE ORDEMADAS DA F P/ CALCULO DE INTEGRAIS INTERMEDIARIAS
C J - CHAVE USADA NA MONTAGEM DAS ORDEMADAS DA F
C KK - CHAVE USADA PARA DECIDIR SOBRE O JSD DO TESTE DA MEDIANA OU DO VALOR FIN
C L - CHAVE PARA CONTROLAR O RETORNO DA ROTINA DE CONTAGEM DE LINHAS
C LINHA - CONTADOR DE LINHAS
C NR - NUMERO DO EQUIPAMENTO DE ENTRADA
C NW - NUMERO DO EQUIPAMENTO DE SAIDA

```

\*\*\*\*\*

\*\*\*\*\*

```

C VARIÁVEIS REAIS UTILIZADAS NO PROGRAMA
C A,B,C,D,E - PARAMETROS PARA CALCULO DA ORDEMADA DA G
C DIF1 - DIFERENÇA ENTRE D,SSO E A INTEGRAL DA G
C DIF2 - DIFERENÇA ENTRE L,000 E A INTEGRAL DA G
C DX,DY - INCREMENTOS DE X E Y, RESPECTIVAMENTE
C GG - ORDEMADA DA G
C H1,H2,H3 - ORDEMADAS DA F PARA USO NA REGRA DE SIMPSON ITERATIVA
C S1,S2,S3 - INTEGRAIS DA F USADAS PARA MONTAR AS ORDEMADAS DA F
C S4 - VALOR DA MEDIA DA FUNCAO F
C X,YN - VALORES INICIAL E FINAL DE X
C Y,YN - VALORES INTERMEDIARIO E FINAL DE Y

```

\*\*\*\*\*

```

0001 C      EXTERNAL DEXP
0002 C      REAL * 8 X,Y,DY,YN,A,B,C,D,S,G,E,SS,DIF1,DIF2,DX,SL,S2,S3
0003 C      REAL * 8 H1,H2,H3,S4,XMED
0004 C      G(A,B,E) = 2.31E+16 * A * B *DEXP(E)
0005 C      INICIALIZACAO DE CAMPOS
0006 C      I = 1
0007 C      S4 = 0.
0008 C      SS = 0.
0009 C      J = 1
0010 C      ICNT = 0
0011 C      KK = 1
0012 C      NR = 1
0013 C      NW = 3
0014 C      LINHA = 0

```

```

C      SALTA PARA A PRIMEIRA FOLHA
0014 C      WRITE (NW,1)
0015 C      1 FORTAT (I1,F30K,'CALCULO DAS INTEGRAIS DAS FUNCOES DA FORMA //
          C      109X,'G = 2.31E+16 * ((Y+4)*X) ** (-2.5) * Y**(-7) * EXP((-0.5)*I)
          C      2*(.659*Y+2592*X)/(Y+4*X)*Y) //)

```

005-FORTRAN IV-360N-FO-479 3-8 MAINPGM DATE 07/07/59 09.43.18 1P55 U002

C LEITURA DO X INICIAL, DOS INCREMENTOS DX E DY

C E DOS VALORES FINAIS XN E YN  
READ (NR,5) X,DX,XN,DY,YN  
5 FORMAT (F4.1,F2.1,F6.1,F3.1,F3.0)  
C INICIO DA ROTINA  
6 Y = 0.

0018 S = 0.

0019 C CALCULO DA ORDEENADA DE G

7 Y = Y + DY  
A = (Y + X) \* (-2.5)  
B = Y \* (-7)  
C = (659 \* Y + 2592 \* X) \* (-0.5)  
D = (Y + 4 \* X) \* Y  
E = C / D  
GG = G(A,B,E)

C VERIFICA SE JA ATINGIU O ULTIMO VALOR DO INTERVALO DO Y

IF (Y - YN) 9,15,15

C DECIDIR QUAL FATOR MULTIPLICA A ORDEENADA DA ?

9 GO TO (11,13),I

11 GG = 4 \* GG  
S = S + GG

12 I = 2  
GO TO 7

13 GG = 2 \* GG  
S = S + GG

14 I = 1  
GO TO 7

C ADICIONA ULTIMA ORDEENADA, E CALCULA VALOR DA INTEGRAL

15 S = S + GG  
S = DY \* S

16 S = S / 3

C MONTAGEM DAS ORDEENADAS DA F

42 CONTINUE

22 S1 = S  
H1 = X \* S1

J = 2  
GO TO 25

23 S2 = 4 \* S  
H2 = X \* S2

J = 3  
GO TO 25

24 S3 = S  
H3 = X \* S3

J = 2

C CALCULO ITERATIVO DA INTEGRAL DA F, E DA MEDI

SS = SS + DX \* (S1 + S2 + S3) / 3

S1 = S3  
SM = SM + DX \* (H1 + H2 + H3) / 3

H1 = X \* S3

ICONT = ICONT + 1

IF (ICONT - 5) 39,35,35

35 WRITE (ND,37) X,SS

37 FORMAT (/5X,FA AREA SOB A F, ATE ,F7.1, VALE ,E10.4,)

0016

0017

0018

0019

0020

0021

0022

0023

0024

0025

0026

0027

0028

0029

0030

0031

0032

0033

0034

0035

0036

0037

0038

0039

0040

0041

0042

0043

0044

0045

0046

0047

0048

0049

0050

0051

0052

0053

0054

0055

0056

0057

0058

0059

0060

09.43.18 PAISE 0003

09.43.18

IME

DATE 37/06/77

MAINP64

DOS FORTRAI II. 360N-FD-479 J-8

```

0061          ICOUNT = 0
0062          L = 2
0063          GO TO 49
0064          39 CONTINUE
0065          GJ TO (30,28),KK
C
0066          TESTE PARA ENCONTRAR A MEDIANA
0067          30 DIF1 = 0.500 - SS
0068          IF (D.001 - DIF1) 25,26,25
0069          26 WRITE (N4,27) X,SS
0070          27 FORMAT (/5X,'SENDO A INTEGRAL DE 0 A ',F5.1,' ISUAL A ',E10.4,
0071          1,' AJUELE E A PROVAVEL MEDIANA',/)
0072          XMED = X
0073          L = 3
0074          GO TO 49
0075          44 CONTINUE
0076          KK = 2
0077          GJ TO 25
C
0078          TESTE PARA ENCONTRAR O VALOR FINAL
0079          28 DIF2 = 1.000 - SS
0080          IF (D.001 - DIF2) 25,31,31
0081          31 WRITE (N4,29) X,SS
0082          29 FORMAT (/5X,'A AREA ATE ',F7.1,' VALE ',E10.4)
0083          L = 4
0084          GO TO 49
0085          46 CONTINUE
0086          WRITE (N4,41) SM,XMED
0087          41 FORMAT (/5X,'A MEDIA VALE ',E10.4/5X,'A MEDIANA VALE ',E10.4//)
0088          GO TO 19
0089          25 X = X + DX
0090          IF (X - KN) 6,31,31
0091          CONTROLE DE PAGINAS
0092          49 LINHA = LINHA + 1
0093          IF (LINHA - 35) 53,51,51
0094          51 WRITE (N4,1)
0095          LINHA = 0
0096          53 CONTINUE
0097          GO TO (42,34,44,46),L
0098          19 WRITE(N4,77)
0099          77 FORMAT(5X,'A MODA VALE 0.0000E 00')
0100          WRITE(N4,21)
0101          21 FORMAT (5X,'UFA... FINALMENTE TERMINEI ESTA DRAGA')
0102          STOP
0103          END

```

## REFERÊNCIAS BIBLIOGRÁFICAS

- ANDERSON, R.L. -1965- Negative variance estimates, Tecnometrics, 7: 75-76.
- BARNETT, V -1973- Comperative Statistical Inference, N.York: John Wiley.
- BOX, G.E.P. and TIAO, G.C. -1970- Bayesian Inference in Statistical Analysis, Reading, Mass: Addison-Wesley.
- GRAYBILL, F.A. -1961- An Introduction to Linear Statistical Models I, New York, McGraw-Hill.
- GRAYBILL, F.A. and HULGUIST, R.A. -1961- Theorems concerning Eisenhart's Model II, Ann.Math.Statist. 32:261-269.
- HAMMING, R.W. -1971- Introduction to Applied Numerical Analysis, New York: McGraw-Hill.
- HERBACH, L.H. -1959- Properties of Model II type analysis of variance tests, Ann.Math.Statist. 30: 939-959.
- HILL, B.M. -1965- Inference about variance components in the one-way model. J.Amer.Statis.Ass. 60: 806-825.
- LAMOTTE, L.R. -1973- On non-negative quadratic unbiased estimation of variance components. J.Amer.Statist.Ass. 68: 728-730.
- MOOD, A.M., GRAYBILL, F.A. and BOES, D.C. -1974- Introduction to the Theory of Statistics, 3d.ed. Tokyo: McGraw-Hill, Kogakusha.
- NELDER, J.A. -1954- The interpretation of negative components of variance, Biometrika, 41: 544-548.
- RAO, C.R. -1972- Estimation of variance and covariance components in linear models, J.Amer.Statist.Ass. 67:112-115.



- RAO, C.R. -1973- Linear Statistical Inference and Applications, 2d. ed. New York, John Wiley
- SEARLE, S.R. -1968- Another look at Henderson's methods of estimating variance components. Biometrics, 24: 749-788.
- SEARLE, S.R. -1971a- Topics in variance components estimation, Biometrics, 27: 1-76.
- SEARLE, S.R. -1971b- Linear Models, New York, John Wiley.
- SEARLE, S.R. and FAWCETT, R.F. -1970- Expected mean square in variance components models having finite populations, Biometrics, 26: 243-254.
- THOMPSON, W.A. Jr. -1962- The problem of negative estimates of variance components, Ann.Math.Statist., 33: 273-289.
- THOMPSON, W.A.Jr. and MOORE, J.R. -1963- Non negative estimates of variance components. Technometrics, 5:441-450.
- TIAO, G.C. and Box, G.E.P. -1972- Some Comments on "Bayes" Estimations. Univ.of Wisconsin, Dep.of Statistics, Tech. Report, n° 297.
- TIAO, G.C. and TAN, W.Y. -1965- Bayesian analysis of random-effect models in the analysis of variance I. Posterior distribution of variance-components. Biometrika, 52:37-53.
- ZELLNER, A. -1971- An Introduction to Bayesian Inferences in Econometrics, New York, John Wiley.