

CARACTERIZAÇÃO DOS MELHORES ESTIMADORES  
LINEARES NÃO TENDENCIOSOS NO MODELO  
LINEAR GERAL

ROSA MARIA SALANI MOTA

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

*Prof. Dr. Euclides Custódio de Lima Filho*

- SÃO PAULO, DEZEMBRO DE 1982 -

Aos meus pais, Osvaldo e Horay-  
da, que me educaram com dedica-  
ção e carinho.

As minhas filhas, Bruna e Sula  
Ao João Maurício, companheiro ,  
incentivador e, sobretudo, ami-  
go.

A Inã

## AGRADECIMENTOS

Este trabalho é resultado da ajuda recebida de muitos, de diversas formas e nas diversas etapas de sua elaboração.

Quero a todos externar os melhores agradecimentos, em especial

Ao professor Euclides Custodio de Lima e Filho, pela sugestão do tema e por ter proporcionado uma formação básica tão necessária para a realização desta monografia.

Ao professor Adolpho Walter Pimazoni Canton do Departamento de Estatística da Universidade de São Paulo.

Ao professor Plínio Amarantes Quirino Simões pelo seu apoio constante no esclarecimento de conceitos matemáticos e pelo seu estímulo sem os quais não seria possível a realização deste trabalho.

Aos amigos Vera, Franklin, Carlinhos, Wagner, pelo estímulo nas horas difíceis.

Aos colegas do Curso de Pós-Graduação e as amigas da biblioteca do Instituto de Matemática e Estatística da Universidade de São Paulo pela convivência amigável.

Ao Sr. João Baptista Esteves de Oliveira, Alice Perran Taborga e Luzia do Carmo Namiki que colaboraram nesta monografia com o seu trabalho datilográfico.

## CONTEÚDO

- INTRODUÇÃO . . . . .	v
1 - ALGUNS RESULTADOS DE ÁLGEBRA LINEAR . . . . .	1
1.1 - Algumas Definições e Notações . . . . .	1
1.2 - Alguns Aspectos sobre Matrizes . . . . .	6
1.3 - Projetores e Projetores Ortogonais . . . . .	12
1.4 - Projetor Ortogonal Associado a uma Matriz . . . . .	30
2 - CARACTERIZAÇÃO DO BLUE NO MODELO DE GAUSS-MARKOFF . . . . .	43
2.1 - Aproximação dos Mínimos Quadrados. . . . .	43
2.2 - Computação dos Coeficientes de Mínimos Qua- drados e Equações Normais. . . . .	46
2.3 - Estimabilidade . . . . .	52
3 - CARACTERIZAÇÃO DE BLUE's NO MODELO DE GAUSS-MARKOFF GENERALIZADO (GMG) . . . . .	65
3.1 - Considerações a respeito do Modelo de GMG . . . . .	66
3.2 - Condições em que o Melhor Estimador de Mínimos Quadrados Simples (SLSE) é também um BLUE modelo de GMG . . . . .	87
3.3 - Caracterização dos BLUE's no modelo de GMG . . . . .	97
4 - ESTRUTURA DE COVARIÂNCIA DE EXPERIMENTOS ALEATORIZADOS. .	128
BIBLIOGRAFIA . . . . .	145

## INTRODUÇÃO

Nas mais diversas áreas científicas e tecnológicas, o pesquisador não raras vezes se depara com o problema da estimação de parâmetros de um modelo matemático cuja estrutura é da forma

$$y = X \beta + e$$

sendo,

$y = (y_i)$  um vetor  $n \times 1$  de observações

$X$  uma matriz  $n \times p$  de constantes conhecidas

$\beta$  um vetor  $p \times 1$  de parâmetros

$e$

$e = (e_i)$  um vetor  $n \times 1$  onde,

cada  $e_i$  é considerado uma perturbação (ou erro) associado ao  $i$ -ésimo valor observado e, satisfaz

$$E(e_i) = 0 \text{ para todo } i=1, \dots, n.$$

De um modo geral, o problema da estimação é o de encontrar, com base no vetor das observações,  $y$ , um vetor  $\hat{y}$  que de algum modo seja um "bom" estimador da  $E(y) = X\beta$ .

A solução clássica para esse problema, foi primeiramente es

tudada por Legendre e Gauss, em um trabalho onde, eles utilizam o então chamado Princípio dos Mínimos Quadrados que consiste em achar um vetor  $\hat{y} \in C(X)$  (espaço gerado pelas colunas da matriz  $X$ ), tal que

$$\min_{\eta \in C(X)} \|\eta - y\|^2 = \min_{\eta \in C(X)} (y - X\beta)^t (y - X\beta) = \|\eta - \hat{y}\|^2.$$

Gauss (1821) e Markoff (1912) ocuparam-se do problema adicionando ao modelo linear a condição de que, o erro médio quadrático para cada observação  $y_i$ ,  $i=1, \dots, n$ , fosse igual a  $\sigma^2$  onde,  $\sigma^2$  é uma constante real positiva e desconhecida. Além disso consideraram que a correlação existente entre cada par de observações fosse nula.

Tais restrições reduziram bastante a gama de situações nas quais o modelo pudesse ser aplicado.

A partir de 1935, vários trabalhos foram desenvolvidos, (ver, por exemplo Aitken (1935)) com o objetivo de estudar uma forma de encontrar o "melhor" estimador linear de uma função  $\lambda^t \beta$ ,  $\lambda \in R^p$ , admitindo que a matriz de variância e covariância do vetor das observações,  $y$ , fosse dada por

$$D(y) = \sigma^2 V$$

onde

$\sigma^2 > 0$  é uma constante real desconhecida

e

$V$  é uma matriz  $n \times n$  de constantes reais conhecidas e de posto  $n$ .

A partir de 1940 vários autores entre os quais, Goldman e Zelen (1964), mostram que a situação geral ( $X$  e  $V$  não necessariamente de posto completo) pode ser reduzida através de transformações adequadas à situação inicial proposta por Gauss-Markoff.

Entretanto, como tais reduções são complexas, tornou-se necessário encontrar-se um modo mais simples de se obter um "melhor" estimador linear de uma função paramétrica,  $\lambda^t \beta$ ,  $\lambda \in \mathbb{R}^p$ , cuja representação seja válida para todas as situações do modelo linear.

Zyskind e Martin (1969) assim como Rao (1971, 1972, 1973, 1975, 1978) e outros ocuparam-se em obter uma teoria unificada para a representação de tais estimadores no modelo linear cuja situação fosse geral.

Entretanto, nestes artigos, os autores tiveram que se preocupar em obter também um suporte computacional eficiente sobretudo para o cálculo de "Inversas Generalizadas" o que, ainda tornam tais representações um tanto difíceis de serem obtidas.

Considerando a importância prática do tema, procuraremos apresentar de forma didática uma caracterização do "melhor" estimador de  $X \beta$ , sem fazer referência a inversas generalizadas, utilizando o argumento apresentado por Rao (1967) denominado ajustamento por covariância.

Este trabalho foi organizado em quatro capítulos, da seguinte forma:

A notação e os pré-requisitos necessários para uma melhor compreensão do texto, foram apresentados no Capítulo 1.

O segundo capítulo é dedicado a um estudo detalhado da Aproximação dos Mínimos Quadrados sugerido por Legendre e Gauss, e, onde, obtemos que o vetor ajustado,  $\hat{y}$ , de  $y$  por vetores de  $C(X)$  (espaço gerado pelas colunas da matriz  $X$ ) é igual à projeção ortogonal de  $y$  sobre esse espaço.

Ainda neste segundo capítulo, admitindo  $E(e) = \emptyset$  observamos que o conjunto de estimadores de uma função paramétrica  $\lambda^t \beta$ ,  $\lambda \in R^p$ , é dado por funções lineares das observações,  $y$ , da forma

$$a^t y + \rho^t y \quad \text{onde,}$$

$a$  é um vetor  $n \times 1$  pertencente a  $C(X)$

e

$\rho$  é um vetor  $n \times 1$  pertencente a  $C(X)^\perp$  (espaço complementar ortogonal do espaço  $C(X)$  em relação a  $R^n$ ). Completando a estrutura do modelo linear  $y = X\beta + e$  com as restrições do Modelo Linear de Gauss-Markoff ( $E(e e^t) = \sigma^2 I_n$ ) obtemos que o "melhor" estimador de  $X\beta$  é único e, é igual ao vetor ajustado  $\hat{y}$  de  $y$  por vetores de  $C(X)$  obtido pela aproximação dos mínimos quadrados.

No terceiro capítulo mostramos que, com as restrições  $E(e) = \emptyset$ ,  $E(e e^t) = \sigma^2 V$ , a singularidade de  $V$  induz em algumas restrições no vetor das observações,  $y$ , e no vetor dos parâmetros,  $\beta$ . Além disso, com essas restrições, é possível encontrarmos um conjunto de funções lineares da forma  $c^t y$ ,  $c \in R^n$ ,  $c \neq \emptyset$ , tais que



$$E(c^t y) = 0$$

e

$$\text{var}(c^t y) = 0$$

Assim, como poderemos observar uma função paramétrica  $\lambda^t \beta$ ,  $\lambda \in R^p$ , pode admitir distintos "melhores" estimadores como função das observações embora, o valor numérico de todos eles sejam iguais.

Ainda, neste terceiro capítulo mostramos que, dependendo da relação existente entre a matriz  $X_{n \times p}$  e a matriz  $V_{n \times n}$  o "melhor" estimador de uma função paramétrica  $\lambda^t \beta$ ,  $\lambda \in R^p$ , pode ser obtido através da solução dos mínimos quadrados.

Utilizando o argumento apresentado por Rao (1973) finalizamos o terceiro capítulo caracterizando o "melhor" estimador de  $X\beta$  como sendo a projeção das observações,  $y$ , sobre o espaço  $C(X)$  segundo a direção dos vetores do espaço  $C(VZ)$  onde,  $Z$  é uma matriz de posto coluna completo tal que  $C(Z) = C(X)^\perp$ .

Finalmente no quarto capítulo, com o objetivo de facilitar o entendimento da teoria, apresentamos dois exemplos de modelos lineares obtidos em experimentos aleatorizados.

## CAPÍTULO 1

### ALGUNS RESULTADOS DE ÁLGEBRA LINEAR

Com o objetivo de facilitarmos o entendimento dos capítulos subseqüentes, descreveremos aqui alguns resultados da teoria das matrizes, assim como também alguns resultados de Álgebra Linear relacionada com projetores e projetores ortogonais.

Para atingirmos o propósito deste capítulo, por conveniência, admitiremos que os espaços vetoriais sejam todos espaços vetoriais reais com produto interno denotado por  $(x,y)$  onde  $x$  e  $y$  são ambos vetores do mesmo espaço.

#### 1.1 - ALGUMAS DEFINIÇÕES E NOTAÇÕES

DEFINIÇÃO 1.1 - Seja  $E$  um espaço vetorial, onde

$$E \subset \mathbb{R}^n.$$

Então, para todo vetor  $y \in E$

$$y = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} \text{ com } y_i \in \mathbb{R}, \quad i = 1, \dots, n \quad (1.1)$$

e ainda

$$y^t = \text{vetor transposto de } y \longleftrightarrow y^t = (y_1 : \dots : y_n) \quad (1.2)$$

DEFINIÇÃO 1.2 - Sejam  $E_1$  e  $E_2$  dois espaços vetoriais.

Chama-se operador linear ou transformação linear de  $E_1$  em  $E_2$  a toda aplicação

$$T: E_1 \longrightarrow E_2 \text{ tal que}$$

a.  $T(x,y) = T(x) + T(y)$  para todo  $x$  e  $y \in E_1$ ;

b.  $T(\alpha x) = \alpha T(x)$  para todo  $x \in E_1$  e  $\alpha \in \mathbb{R}$ .

OBSERVAÇÃO - Um operador linear

$$T: E_1 \longrightarrow E_1 \text{ é também chamada de} \\ \text{endomorfismo de } E_1 \quad (1.3)$$

DEFINIÇÃO 1.3 - Chama-se núcleo de um operador linear

$$T: E_1 \longrightarrow E_2,$$

ao conjunto de todos os vetores  $x \in E_1$ , tais que

$$T(x) = \emptyset \text{ (vetor nulo)} \quad (1.4)$$

NOTAÇÃO -

$$\text{núcleo de } T = \text{Ker}(T) = \{x \in E_1 \mid T(x) = \emptyset\} \quad (1.5)$$

o conjunto

$$\text{Im}(T) = \left\{ y \in E_2 \mid \text{existe } x \in E_1 \text{ tal que} \right. \\ \left. T(x) = y \right\} \text{ é denominado imagem de } T \quad (1.6)$$

Observe que  $\text{Ker}(T)$  e a  $\text{Im}(T)$

são sub-espços de  $E_1$  e  $E_2$ , respectivamente. . (1.7)

DEFINIÇÃO 1.4 - Seja  $E$  um espaço vetorial e  $T$  um endomorfismo de  $E$ .

Chamamos de transformação adjunta de  $T$  à transformação  $T^t$  tal que

$$(T(x), y) = (x, T^t(y)) \text{ para todo } x \text{ e } y \in E$$

e ainda, se  $[T]_{\beta} = A =$  matriz de  $T$  com relação à base  $\beta$  de  $E$  (ver Halmos (1978), pg. 109, temos

$$[T^t]_{\beta} = A^t$$

onde

$$A^t = \text{matriz transposta de } A. \quad (1.8)$$

DEFINIÇÃO 1.5 - Seja  $E$  um espaço vetorial e  $T$  um endomorfismo de  $E$ .

Dizemos que  $T$  é auto-adjunta (ou simétrica) se, e somente se,

$$T = T^t$$

ou equivalentemente  $[T]_{\beta} = A = A^t$ , ou seja, a matriz de  $T$  com relação a

$$\text{uma base } \beta \text{ de } E \text{ é uma matriz simétrica.} \quad (1.9)$$

DEFINIÇÃO 1.6 - Dizemos que um endomorfismo  $T$  de  $E$  é idempotente se, e somente se,

$$T^2 = T \circ T = T \quad (1.10)$$

ou equivalentemente se

$$[T]_{\beta} = A$$

então  $T$  é idempotente se, e somente se,

$$A^2 = A \text{ ou seja, a matriz } A \text{ é idempotente.} \quad (1.11)$$

DEFINIÇÃO 1.7 - Seja  $E$  um espaço vetorial de dimensão finita e  $T$  um endomorfismo de  $E$ .

Dizemos que  $T$  é positiva definida (p.d.) (ou positiva semi-definida (p.s.d.)) se

$$T = T^t$$

e para todo  $y \in E$   $(T(y), y) \geq 0$ , onde

$$(T(y), y) = 0 \iff y = \emptyset \quad (1.12)$$

(ou  $T = T^t$  e para todo  $y \in E$   $(T(y), y) \geq 0$ , onde

$$(T(y), y) = 0 \text{ para algum } y \neq 0). \quad (1.13)$$

DEFINIÇÃO 1.8 - Seja  $E$  um espaço vetorial de dimensão finita e  $T$  um endomorfismo de  $E$ .

Dizemos que  $T$  é positiva se, e somente se,

$$T \text{ é positiva definida ou positiva semi-definida.} \quad (1.14)$$

Equivalentemente se

$$[T]_{\beta} = A$$

então  $T$  é positiva se, e somente se,

$A = B^t B$  para alguma matriz  $B$  tal que

$$\text{posto } (B) = \text{posto } (A)$$

e neste caso, diremos também que

$$A \text{ é uma matriz positiva.} \quad (1.15)$$

DEFINIÇÃO 1.9 - Seja  $E$  um espaço vetorial e  $T$  um endomorfismo de  $E$ . Um auto valor de  $T$  é um escalar  $\lambda \in \mathbb{R}$  tal que exista um vetor não nulo  $x \in E$  com

$$T(x) = \lambda x. \quad (1.16)$$

Se  $\lambda$  é um auto valor de  $T$  então para todo  $x \in E$  tal que

$$T(x) = \lambda x \text{ dizemos que } x \text{ é um auto vetor} \\ \text{de } T \text{ associado ao auto valor } \lambda \quad (1.17)$$

Equivalentemente, se  $[T]_{\beta} = A$  então  $\lambda$  é um auto valor de  $T$  e  $x \in E$  é um auto vetor de  $T$  associado ao auto valor  $\lambda$  se, e somente se,  $Ax = \lambda x$ .

Neste caso, costumamos dizer também que  $\lambda$  é um auto valor da matriz  $A$  e  $x$  é um auto vetor de  $A$  associado ao auto valor  $\lambda$  (1.18)

DEFINIÇÃO 1.10 - Seja  $E$  um espaço vetorial e  $x$  e  $y$  dois vetores de  $E$ .

Dizemos que  $x$  e  $y$  são ortogonais se, e somente se

$$(x, y) = 0. \quad (1.19)$$

Se  $S$  é um conjunto de vetores em  $E$ , dizemos que  $S$  é um conjunto ortonormal se, dois quaisquer vetores distintos de  $S$

são ortogonais e para todo vetor  $x \in S$  temos que

$$(x, x) = 1 \quad (1.20)$$

DEFINIÇÃO 1.11 - Seja  $E$  um espaço vetorial e  $S$  um sub-espaço de  $E$ .

Dizemos que o vetor  $x \in E$  é ortogonal a  $S$  se e somente, se

$$(x, y) = 0 \text{ para todo vetor } y \in S. \quad (1.21)$$

DEFINIÇÃO 1.12 - Seja  $E$  um espaço vetorial e  $S$  um sub-espaço de  $E$ .

Dizemos que o sub-espaço  $S^\perp$  de  $E$  é o espaço complemento ortogonal de  $S$  em  $E$  se e somente se,

$$\text{para todo } y \in S^\perp \rightarrow y \text{ é ortogonal a } S. \quad (1.22)$$

## 1.2 - ALGUNS ASPECTOS SOBRE MATRIZES

Considerando  $A$  uma matriz  $m \times n$  de números reais, temos

DEFINIÇÃO 2.1 - O espaço vetorial gerado pelas colunas da matriz  $A$  (espaço coluna de  $A$ ) é igual ao conjunto de vetores  $y \in \mathbb{R}^m$  tal que

$$y = Ax \text{ para algum vetor } x \in \mathbb{R}^n$$

simbolicamente

$$C(A) = \{y \in \mathbb{R}^m / y = Ax \text{ para algum } x \in \mathbb{R}^n\}.$$

DEFINIÇÃO 2.2 - O espaço vetorial gerado pelas linhas de  $A$  (espaço linha de  $A$ ) é igual ao conjunto de vetores  $y \in \mathbb{R}^n$  tal que

$$y^t = x^t A \text{ para algum } x \in \mathbb{R}^m$$

simbolicamente

$$L(A) = \left\{ y \in \mathbb{R}^n \mid y^t = x^t A \text{ para algum } x \in \mathbb{R}^m \right\}.$$

Observemos que

$$L(A) = C(A^t) \tag{1.23}$$

e também, se  $T$  é uma aplicação linear de  $\mathbb{R}^n$  em  $\mathbb{R}^m$  tal que a matriz de  $T$  com relação as bases  $\beta_n$  e  $\beta_m$  de  $\mathbb{R}^n$  e  $\mathbb{R}^m$  respectivamente, é dada por  $A$ , então  $\text{Im}(T) = C(A)$ .

DEFINIÇÃO 2.3 - O núcleo da matriz  $A$  é igual ao conjunto dos vetores  $x \in \mathbb{R}^n$  tal que  $Ax = \emptyset$ , simbolicamente

$$\text{Ker}(A) = \left\{ x \in \mathbb{R}^n \mid Ax = \emptyset \right\}.$$

PROPOSIÇÃO 2.1 - O  $\text{Ker}(A)$  é igual ao espaço complemento ortogonal de  $L(A)$  (1.24)

PROVA - Como, para todo  $y \in \text{Ker}(A) \rightarrow Ay = \emptyset$  e para todo

$$x \in L(A) \longleftrightarrow (\text{por 1.22})$$

existe  $z \in \mathbb{R}^m$  tal que  $x = A^t z$ , temos

$$(y, x) = (y, A^t z) = (Ay, z) = (\emptyset, z) = 0 \longleftrightarrow$$

$$y \in (L(A))^{\perp} = (C(A^t))^{\perp}$$

e portanto

$$\text{Ker}(A) = (C(A^t))^{\perp}.$$



COROLÁRIO 2.1 - Se  $A$  é uma matriz  $m \times n$  de números reais, então

$$\mathbb{R}^n = L(A) \overset{\perp}{\oplus} \text{Ker}(A) \quad (1.25)$$

onde  $\overset{\perp}{\oplus}$  = soma direta de sub-espços ortogonais.

COROLÁRIO 2.2 - Se  $A$  é uma matriz  $m \times n$  simétrica, então,

$$a) \ C(A^t) = L(A) = C(A) \quad (1.26)$$

$$b) \ \text{Ker}(A) = (C(A))^{\perp} \quad (1.27)$$

e assim

$$\mathbb{R}^m = C(A) \overset{\perp}{\oplus} \text{Ker}(A). \quad (1.28)$$

PROVA - Trivial.

COROLÁRIO 2.3 - Se  $A$  é uma matriz  $m \times n$ , então

$$\text{Ker}(A^t) = C(A)^{\perp} \quad (1.29)$$

e assim

$$\mathbb{R}^m = C(A) \overset{\perp}{\oplus} \text{Ker}(A^t). \quad (1.30)$$

PROVA - Trivial.

PROPOSIÇÃO 2.2 - Se  $E_1$  e  $E_2$  são dois sub-espços de  $\mathbb{R}^n$ , então

$$a) \ - \ (E_1 + E_2)^{\perp} = E_1^{\perp} \cap E_2^{\perp} \quad (1.31)$$

$$b) \ - \ (E_1^{\perp} + E_2^{\perp}) = (E_1 \cap E_2)^{\perp} \quad (1.32)$$

PROVA

$$a) \ - \ \text{como } E_1 \subset E_1 + E_2 \text{ e } E_2 \subset E_1 + E_2 \rightarrow (E_1 + E_2)^{\perp} \subset E_1^{\perp} \text{ e}$$

$$(E_1 + E_2)^\perp \subset E_2^\perp \rightarrow (E_1 + E_2)^\perp \subset E_1^\perp \cap E_2^\perp.$$

inversamente, como para todo vetor

$$y \in E_1^\perp \cap E_2^\perp \rightarrow y \in E_1^\perp \text{ e } y \in E_2^\perp$$

e para todo vetor  $x \in E_1 + E_2 \rightarrow$  existe  $x_1 \in E_1$  e  $x_2 \in E_2$  tal que

$$x = x_1 + x_2$$

e (por (1.21))  $(y, x_1) = 0$ ,  $(y, x_2) = 0$ , então

$$(y, x) = (y, x_1 + x_2) = (y, x_1) + (y, x_2) = 0 \rightarrow$$

$$\text{(por (1.21)) } y \in (E_1 + E_2)^\perp$$

e portanto, concluímos que

$$(E_1 + E_2)^\perp = E_1^\perp \cap E_2^\perp.$$

b - Substituindo  $E_1$  por  $E_1^\perp$  e  $E_2$  por  $E_2^\perp$  em a) temos

$$(E_1^\perp + E_2^\perp)^\perp = (E_1^\perp)^\perp \cap (E_2^\perp)^\perp$$

e como  $E_1$  e  $E_2$  são sub-espacos de  $\mathbb{R}^n$ ,  $n$ : finito, então

$$(E_1^\perp + E_2^\perp)^\perp = E_1 \cap E_2$$

e portanto

$$E_1^\perp + E_2^\perp = (E_1 \cap E_2)^\perp.$$

PROPOSIÇÃO 2.3 - Se  $A$  e  $B$  são matrizes  $n \times p$  e  $p \times m$ , respectivamente, então

$$\text{posto}(AB) = \text{posto}(A) - \dim(C(A^t) \cap (C(B))^{\perp}). \quad (1.33)$$

PROVA - Sendo  $AB$  uma matriz  $n \times m$ , então

$$\dim(C(A)) = \text{posto}(A) = n - \dim(C(A)^{\perp})$$

e

$$\dim(C(AB)) = \text{posto}(AB) = n - \dim(C(AB)^{\perp})$$

mas, como

$$\begin{aligned} C(AB)^{\perp} &= \text{Ker}(AB)^t = \{x \in \mathbb{R}^n \mid x^t AB = \emptyset\} = \\ &= \{x \in \mathbb{R}^n \mid x^t A = \emptyset\} \cup \{x \in \mathbb{R}^n \mid x^t A \neq \emptyset \text{ e } x^t AB = \emptyset\} \end{aligned}$$

onde esses dois conjuntos são disjuntos e

$$\{x \in \mathbb{R}^n \mid x^t A = \emptyset\} = C(A)^{\perp}$$

$$\begin{aligned} \{x \in \mathbb{R}^n \mid x^t A \neq \emptyset \text{ e } x^t AB = \emptyset\} &= \{x \in \mathbb{R}^n \mid A^t x \neq \emptyset \rightarrow (A^t x)^t B = \emptyset\} \iff \\ &A^t x \in C(A^t) \text{ e } A^t x \in C(B)^{\perp} \end{aligned}$$

temos que

$$\dim(C(AB)^{\perp}) = \dim C(A)^{\perp} + \dim\{x \in \mathbb{R}^n \mid A^t x \in C(A^t) \cap C(B)^{\perp}\}$$

e portanto

$$\begin{aligned} \text{posto}(AB) &= n - \dim(C(A)^{\perp}) - \dim(C(A^t) \cap C(B)^{\perp}) = \\ &= \text{posto}(A) - \dim(C(A^t) \cap C(B)^{\perp}). \end{aligned}$$

EXEMPLO 2.1 - Se  $A$  é uma matriz  $m \times n$ , então

$$\text{posto}(A^t A) = \text{posto}(A) = \text{posto}(A^t) = \text{posto}(AA^t)$$

pois

$$\text{posto}(A^t A) = \text{posto}(A^t) - \dim(C(A) \cap C(A)^\perp) = \text{posto}(A^t)$$

e

$$\text{posto}(A A^t) = \text{posto}(A) - \dim(C(A^t) \cap C(A^t)^\perp) = \text{posto}(A)$$

e como  $\text{posto}(A) = \text{posto}(A^t)$ , então

$$\text{posto}(A^t A) = \text{posto}(A) = \text{posto}(A^t) = \text{posto}(A A^t).$$

PROPOSIÇÃO 2.4 - Supondo as matrizes  $\mathbb{C}^p \times m$  e  $A^m \times n$  onde

$$\text{posto}(A) = n \leq m.$$

Se  $E_1 = C(A) \cap \text{Ker}(\mathbb{C})$  então  $E_1^\perp \cap C(A) = C(P_A \mathbb{C}^t)$ , onde

$$P_A = A(A^t A)^{-1} A^t \tag{1.34}$$

PROVA - Sendo  $E_1^\perp =$  complemento ortogonal de  $E_1$  em  $\mathbb{R}^m$ , então

$$\begin{aligned} E_1 &= C(A) \cap \text{Ker}(\mathbb{C}) \iff E_1^\perp = (C(A) \cap \text{Ker}(\mathbb{C}))^\perp = \text{por (1.32)} = \\ &= C(A)^\perp + (\text{Ker}(\mathbb{C}))^\perp = \text{por (1.24)} = C(A)^\perp + C(\mathbb{C}^t) \end{aligned}$$

e

$$\begin{aligned} E_1^\perp \cap C(A) &= (C(A)^\perp + C(\mathbb{C}^t)) \cap C(A) = \\ &= C(A)^\perp \cap C(A) + C(\mathbb{C}^t) \cap C(A) = C(\mathbb{C}^t) \cap C(A) \end{aligned}$$

assim, como para todo  $y \in \mathbb{R}^m, y \in C(A) \iff y = Ax$  para algum

$$x \in \mathbb{R}^n \iff y = P_A y \text{ e } y - P_A y = (I_m - P_A)y = \emptyset$$

onde  $I_m$  é a matriz identidade de ordem  $m$ , e

$$P_A = A(A^t A)^{-1} A^t, \text{ temos,}$$

$$y \in E_1^\perp \cap C(A) \iff y \in E_1^\perp \text{ e } y \in C(A) \iff$$

$$y \in C(C^t) \text{ e } y \in C(A) \iff$$

$$y = P_A y \text{ e } y = (I_m - P_A)y + C^t \beta$$

para algum  $\beta \in \mathbb{R}^m \iff$

$$y = P_A y = P_A (I_m - P_A)y + P_A (C^t \beta) \iff y = (P_A C^t) \beta$$

para algum vetor  $\beta \in \mathbb{R}^m$  e portanto  $E_1^\perp \cap C(A) = C(P_A C^t)$ , onde

$$P_A = A(A^t A)^{-1} A^t.$$

PROPOSIÇÃO 2.5 - Para toda matriz  $A_{m \times n}$  temos

$$a_0) C(A^t A) = C(A^t) \tag{1.35}$$

$$b_0) C(AA^t) = C(A) \tag{1.36}$$

PROVA - Trivial usando o Exemplo 2.1 anterior lembrando que  $C(A^t A) \subset C(A^t)$  e também  $C(AA^t) \subset C(A)$ .

### 1.3 - PROJETORES E PROJETORES ORTOGONAIS

Definição 3.1 Projeções - Sejam  $E_1$  e  $E_2$  dois sub-espacos do espaco vetorial  $E$  tal que  $E = E_1 \oplus E_2$ .

Seja  $P$  um endomorfismo de  $E$ .

Dizemos que  $P$  é uma projeção de  $E$  no sub-espaco  $E_1$  segundo

a direção dos vetores e  $E_2$  se, e somente se,

para todo vetor  $y \in E$  tal que  $y = y_1 + y_2$  com  $y_1 \in E_1$  e  $y_2 \in E_2$

$$P(y) = y_1.$$

É claro que  $I_m(P) = E_1$  e o  $\text{Ker}(P) = E_2$ .

TEOREMA 3.1 - Seja  $E$  um espaço vetorial e  $P$  um endomorfismo de  $E$ . Então,

$$P \text{ é uma projeção de } E \iff P \text{ é idempotente.} \quad (1.37)$$

PROVA - Supondo  $E_1$  e  $E_2$  dois sub-espacos de  $E$  tal que

$$E = E_1 \oplus E_2$$

e  $P$  projeção de  $E$  em  $E_1$  segundo  $E_2$ . Temos,

$$\text{para todo } y_1 \in E_1 \text{ que } P(y_1) = y_1$$

e

$$\text{para todo } y_2 \in E_2 \text{ que } P(y_2) = \emptyset,$$

assim, como para todo  $y \in E$ ,  $y$  é univocamente determinado por

$$y = y_1 + y_2 \text{ com } y_1 \in E_1 \text{ e } y_2 \in E_2$$

então

$$P^2(y) = P(P(y)) = P(P(y_1 + y_2)) = P(y_1) = y_1 = P(y)$$

ou seja  $P^2 = P$ .

Reciprocamente, supondo de  $P^2 = P$ , mostremos que  $P$  é uma projeção.

Seja

$$E_1 = \{y \in E / P(y) = y\} \quad \text{e} \quad E_2 = \text{Ker}(P).$$

Claramente,  $E_1$  e  $E_2$  são sub-espacos de  $E$  tais que  $E = E_1 \oplus E_2$  e  $\text{Im}(P) = E_1$ , pois, para todo  $y \in E$  vale a identidade

$$y = P(y) + y - P(y) = P(y) + (I_E - P)(y)$$

$I_E$  = operador identidade de  $E$ , escrevendo

$$y_1 = P(y) \quad \text{e} \quad y_2 = (I_E - P)(y)$$

temos

$$P(y_1) = P(P(y)) = P^2(y) = P(y) = y_1$$

e

$$P(y_2) = P(I_E - P)(y) = P(y) - P^2(y) = \emptyset$$

ou seja,

$$y = y_1 + y_2 \quad \text{com} \quad y_1 \in E_1 \quad \text{e} \quad y_2 \in E_2$$

e ainda para todo  $y \in E_1 \cap E_2$  tem-se que

$$y \in E_1 \quad \text{e} \quad y \in E_2 \rightarrow \text{por definic\~{a}o} \rightarrow P(y) = y \quad \text{e} \quad P(y) = \emptyset$$

e portanto  $y = \emptyset \rightarrow E = E_1 \oplus E_2$  onde  $P(E) = \text{Im}(E) = E_1$ , ou seja  $P$  é uma projeção de  $E$  na  $\text{Im}(P) = E_1$  segundo a direção de vetores de  $E_2 = \text{Ker}(P)$ .

TEOREMA 3.2 - Se  $P$  é uma projeção de um espaco vetorial  $E$ , en-

tão,  $E$  é a soma direta da  $\text{Im}(P)$  e do  $\text{Ker}(P)$ . Reciprocamente, se  $E$  é a soma direta de dois sub-espacos  $E_1$  e  $E_2$ , então, existe uma única projeção  $P$ , de  $E$ , cuja imagem é  $E_1$  e cujo núcleo é  $E_2$ .

PROVA - Supondo  $P$  uma projeção de  $E$  então por (1.37)  $P^2 = P$  e assim demonstrado de maneira idêntica à recíproca do Teorema 3.1 obteremos que a recíproca do Teorema 3.1, obteremos que

$$E = \text{Im}(P) \oplus \text{Ker}(P)$$

reciprocamente.

Se  $E = E_1 \oplus E_2$  e  $P$  é uma aplicação de  $E$  em  $E$  tal que

$$\text{Im}(P) = E_1 \quad \text{e} \quad \text{Ker}(P) = E_2$$

é trivial que  $P$  é um endomorfismo de  $E$  tal que  $P^2 = P$  e portanto  $P$  é uma projeção de  $E$  em  $E_1$  segundo a direção de vetores de  $E_2$ .

Supondo  $P^*$  uma outra projeção de  $E = E_1 \oplus E_2$  tal que

$$\text{Im}(P^*) = E_1 \quad \text{e} \quad \text{Ker}(P^*) = E_2,$$

temos, para todo  $y \in E$ ,  $y$  é univocamente determinado para

$$y = y_1 + y_2 \quad \text{com} \quad y_1 \in E_1 \quad \text{e} \quad y_2 \in E_2$$

e

$$P^*(y) = y_1 = P(y) \quad \text{para todo} \quad y \in E \quad \longleftrightarrow \quad P^* = P$$

ou seja  $P$  é a única projeção de  $E$  tal que  $\text{Im}(P) = E_1$  e  $\text{Ker}(P) = E_2$ .



PROPRIEDADE 3.1 - Seja  $E$  um espaço vetorial. Um endomorfismo  $P$  de  $E$  é uma projeção  $\iff (I_E - P)$  é também uma projeção de  $E$ .

(1.38)

Além disso, se

$$E_1 = \text{Im}(P) \quad \text{e} \quad E_2 = \text{Ker}(P)$$

então

$$E_1 = \text{Ker}(I_E - P) \quad \text{e} \quad E_2 = \text{Im}(I_E - P) \quad (1.39)$$

PROVA - Como  $P$  é uma projeção  $\iff P^2 = P$  (por 1.37), então

$$P^2 = P \iff P(I_E - P) = \emptyset \iff (I_E - P)^2 = (I_E - P) \iff I_E - P$$

é uma projeção de  $E$ , além disso, se  $\text{Im}(P) = E_1$  e  $\text{Ker}(P) = E_2$ , temos  $P(E_1) = E_1$  e  $P(E_2) = \emptyset$ , assim

$$(I_E - P)(E_1) = I_E(E_1) - P(E_1) = \emptyset$$

e

$$(I_E - P)(E_2) = I_E(E_2) - P(E_2) = E_2$$

ou seja

$$\text{Im}(I_E - P) = E_2 \quad \text{e} \quad \text{Ker}(I_E - P) = E_1.$$

TEOREMA 3.3 - Se um espaço vetorial  $E$  é a soma direta de uma família  $(M_i)_{i=1, \dots, s}$  de sub-espaços de  $E$ , então existe uma família  $(P_i)_{i=1, \dots, s}$  de endomorfismo de  $E$  que satisfaz as condições

- a)  $P_i^2 = P_i, i = 1, \dots, s$
- b)  $\text{Im}(P_i) = M_i, i = 1, \dots, s$
- c)  $P_i P_j = \emptyset, \text{ se } i \neq j, i \text{ e } j = 1, \dots, s$
- d)  $\sum_{i=1}^s P_i = I_E.$

PROVA - Supondo  $E = M_1 \oplus M_2 \oplus \dots \oplus M_s$  temos que para todo  $y \in E$  existe um único  $y_i \in M_i$  tal que

$$y = \sum_{i=1}^s y_i.$$

Definindo  $P_i, i=1, \dots, s$  uma aplicação de  $E$  em  $E$ , tal que  $P_i(y) = y_i$  é fácil de ver que  $P_i, i=1, \dots, s$  é um endomorfismo de  $E$ , e satisfaz

- a)  $P_i^2 = P_i (i=1, \dots, s)$  pois  
 $P_i^2(y) = P_i(P_i(y)) = P_i(y_i) = y_i = P_i(y)$  para todo  $y \in E$
- b)  $\text{Im}(P_i) = M_i$ , pois,  $P_i(y) = y_i \in M_i$  para todo  $y \in E \rightarrow$   
 $P_i(E) = \sum_{i=1}^s P_i(M_i) = P_i(M_i) = M_i$

e ainda, o  $\text{Ker}(P_i) = M_1 \oplus \dots \oplus M_{i-1} \oplus M_{i+1} \oplus \dots \oplus M_s$ , pois como para todo  $y \in E \rightarrow P_i(y) = y_i \in M_i$  então se  $P_i(y) = \emptyset$ , temos que  $y_i = 0$  e reciprocamente se  $y_i = 0$  e  $y = y_1 + \dots + y_{i-1} + y_{i+1} + \dots + y_n$  com  $y_j \in M_j, j=1, \dots, s$  e  $j \neq i$  então  $P_i(y) = \emptyset$ , isto é, o vetor  $y \in \text{Ker}(P_i)$  é na realidade uma soma de vetores dos sub-espacos  $M_j$  com  $j = 1, \dots, s; j \neq i$ .

Assim, como

$$\text{Im}(P_j) = M_j, \text{ para } j = 1, \dots, s$$

e

$$\text{Ker}(P_i) = \bigoplus_{\substack{j=1 \\ j \neq i}}^s M_j$$

então para todo  $y \in E$  temos

$$c) \quad P_i P_j(y) = P_i(y_j) = \emptyset \rightarrow P_i P_j = \emptyset$$

para  $i$  e  $j = 1, \dots, s$ ,  $i \neq j$ , e também, como

$$d) \quad y = P_1(y) + \dots + P_s(y) \leftrightarrow y = \left( \sum_{i=1}^s P_i \right)(y), \text{ temos}$$

$$I_E = \sum_{i=1}^s P_i.$$

TEOREMA 3.4 - Seja  $E$  um espaço vetorial e  $(P_i)_{i=1, \dots, s}$  uma família de endomorfismo de  $E$  tal que

$$a) \quad P_i^2 = P_i, \quad i=1, \dots, s$$

$$b) \quad P_i P_j = \emptyset \text{ se } i \neq j, \quad i \text{ e } j=1, \dots, s$$

$$c) \quad I_E = \sum_{i=1}^s P_i$$

Se,  $M_i = \text{Im}(P_i)$  temos

$$d_1) \quad E = M_1 \oplus \dots \oplus M_s$$

$d_2)$  a família de projeções associada à decomposição do

espaço  $E = M_1 \oplus \dots \oplus M_s$  é a própria família  $(P_i)_{i=1, \dots, s}$ .

PROVA - Supondo  $P_i$ ,  $i=1, \dots, s$  endomorfismos de  $E$  que satisfazem as condições a), b) e c) e

$$\text{Im}(P_i) = M_i$$

certamente  $E = \sum_{i=1}^s M_i$ , pois, por c)  $I_E = \sum_{i=1}^s P_i$ , então para todo  $y \in E$

$$I_E(y) = y = \left( \sum_{i=1}^s P_i \right) (y) = \sum_{i=1}^s P_i(y)$$

onde  $P_i(y) \in M_i$ ,  $i=1, \dots, s$ , e esta expressão para  $y$  é única, pois, se

$$y = \sum_{i=1}^s y_i$$

com  $y_i \in M_i$ , digamos  $y_i = P_i(y_i)$ , então, usando a) e b), temos

$$P_j^2(y_j) = P_j(P_j(y_j)) = P_j(y_j) = y_j$$

e

$$P_j(y) = \sum_{i=1}^s P_j(y_i) = \sum_{i=1}^s P_j(P_i(y_i)) = P_j^2(y_j) = y_j$$

o que prova que  $E = M_1 \oplus \dots \oplus M_s$  e ainda, como

$$\text{Ker}(P_i) = \oplus_{j=1}^s M_j, \text{ para } j \neq i$$

e por a)  $P_i^2 = P_i$  onde  $M_i = \text{Im}(P_i)$  temos que

$P_i$  é a projeção de  $E$  sobre  $M_i$  segundo a direção dos vetores do

$$\text{Ker}(P_i) = \bigoplus_{j=1}^s M_j, \text{ para } j \neq i.$$

Geometricamente observamos então que projeções podem ser usadas para descrever decomposições do espaço vetorial  $E$  em somas diretas e vice-versa, ou seja, a família de decomposições em soma direta estão associadas a famílias de projeções.

Prosseguindo no espírito do Teorema 3.2 e Propriedade 3.1, apresentamos, sem demonstração, condições sob as quais algumas combinações algébricas de projeções são elas próprias projeções. A demonstração pode ser encontrada por exemplo, em Halmos (1978) pg. 81 e Jacy Monteiro (1969), pg. 118.

TEOREMA 3.5 - Seja  $E$  um espaço vetorial.

Se  $P_1$  e  $P_2$  são projeções de  $E$ , então

$$\text{a) } \text{Im}(P_1) \subset \text{Im}(P_2) \iff P_2 P_1 = P_1 \quad (1.40)$$

b)  $P_1 + P_2$  é uma projeção  $\iff P_2 P_1 = P_1 P_2 = \emptyset$  e, satisfeita esta condição, então

$$\begin{aligned} \text{Im}(P_1 + P_2) &= \text{Im}(P_1) \oplus \text{Im}(P_2) \\ \text{Ker}(P_1 + P_2) &= \text{Ker}(P_1) \cap \text{Ker}(P_2). \end{aligned} \quad (1.41)$$

c)  $P_1 - P_2$  é uma projeção  $\iff P_1 P_2 = P_2 P_1 = P_2$ , e, satisfeita esta condição, então

$$\begin{aligned} \text{Im}(P_1 - P_2) &= \text{Im}(P_1) \cap \text{Ker}(P_2) \\ \text{Ker}(P_1 - P_2) &= \text{Ker}(P_1) \oplus \text{Im}(P_2) \end{aligned} \quad (1.42)$$

d) Se  $P_1 P_2 = P_2 P_1 = P$ , então,

d<sub>1</sub>)  $P$  é uma projeção de  $E$ , onde

$$\text{Im}(P) = \text{Im}(P_1) \cap \text{Im}(P_2)$$

e o

$$\text{Ker}(P) = \text{Ker}(P_1) + \text{Ker}(P_2) \quad (1.43)$$

d<sub>2</sub>)  $P_1 + P_2 - P$  é uma projeção de  $E$  onde

$$\text{Im}(P_1 + P_2 - P) = \text{Im}(P_1) + \text{Im}(P_2)$$

e o

$$\text{Ker}(P_1 + P_2 - P) = \text{Ker}(P_1) \cap \text{Ker}(P_2) \quad (1.44)$$

Enunciaremos agora um teorema de grande importância no estudo de estimação em modelos lineares no qual utilizaremos os sub-espacos gerados pelas colunas ou linhas de uma matriz.

TEOREMA 3.6 - Se  $E_1$  e  $E_2$  são sub-espacos de  $E$  tal que  $E = E_1 \oplus E_2$ , então, uma condição necessária e suficiente para que  $E_1$  e  $E_2$  sejam invariantes sob um endomorfismo  $V$  de  $E$  é que

$$PV = VP \text{ ou seja, } V \text{ e } P \text{ comutam,}$$

onde

$$P \text{ é uma projeção de } E \text{ em } E_1 \text{ segundo } E_2. \quad (1.45)$$

PROVA - Supondo que  $PV = VP$  onde  $P$  é uma projeção de  $E$  em  $E_1$  segundo  $E_2$  temos,

$$\text{se } y \in E_1, V(y) = VP(y) = PV(y) \rightarrow V(y) \in E_1$$

$$\text{se } y \in E_2, V(y) = VP(y) = V(\emptyset) = \emptyset \rightarrow V(y) \in E_2$$

e portanto,  $E_1$  e  $E_2$  são invariantes sob  $V$ .

Admitindo agora que  $E_1$  e  $E_2$  são invariantes sob  $V$  temos

$$\begin{aligned} \text{para todo } y \in E_1 \rightarrow V(y) \in E_1 \text{ e } P(y) = y \rightarrow PV(y) &= \\ &= V(y) = VP(y) \end{aligned}$$

$$\begin{aligned} \text{para todo } y \in E_2; V(y) \in E_2 \text{ e } P(y) = \emptyset \rightarrow P(V(y)) &= \\ &= PV(y) = \emptyset = VP(y), \end{aligned}$$

assim, como para todo  $y \in E$ ,  $y = y_1 + y_2$  com  $y_1 \in E_1$  e  $y_2 \in E_2$ , então

$$PV(y) = PV(y_1) + PV(y_2) = VP(y_1) + VP(y_2) = VP(y)$$

e portanto

$$PV = VP$$

Halmos (1978) pg. 98 afirma que

TEOREMA 3.7 - Se  $E$  é um espaço vetorial de dimensão finita. Correspondente a qualquer endomorfismo  $V$  em  $E$ , existe uma transformação linear inversível  $T$  em  $E$  tal que

$TV$  é uma projeção de  $E$  sobre a  $\text{Im}(TV)$  segundo a direção dos vetores do  $\text{Ker}(V)$ .

Uma classe especial de projetores poderá ser encontrada quando o espaço vetorial  $E$  é decomposto em soma direta de um sub-espaço  $E_1$  de  $E$  e do seu complemento ortogonal em  $E$ .

Tal classe é definida por:

DEFINIÇÃO 3.2 Projetores Ortogonais - Seja  $E$  um espaço vetorial com produto interno e  $E_1$  um sub-espaço de  $E$ .

Então, se  $E = E_1 \oplus E_2$  onde  $E_2 = E_1^\perp$  é o único sub-espaço de

$E$  que completa ortogonalmente  $E_1$  em  $E$  e,  $P$  é um endomorfismo de  $E$ .

Dizemos que  $P$  é uma projeção ortogonal de  $E$  em  $E_1$  se, e somente se,

$P$  projeta vetores de  $E$  em  $E_1$  segundo a direção dos vetores de  $E_1^\perp$ .

PROPRIEDADE 3.2 -  $P$  é uma projeção ortogonal de  $E$  no sub-espaço  $E_1$  de  $E \iff (I-P)$  é uma projeção ortogonal de  $E$  no sub-

$$\text{espaço } E_1^\perp \quad (1.46)$$

PROVA - Imediata usando a Propriedade 3.1.

TEOREMA 3.8 - Seja  $E$  um espaço vetorial com produto interno e  $P$  um endomorfismo de  $E$ .

Então,  $P$  é uma projeção ortogonal de  $E$  se, e somente se,  $P^2 = P$  e  $P = P^t$ , ou seja,

$$P \text{ é simétrica e Idempotente,} \quad (1.47)$$

e ainda, se  $P$  é uma projeção ortogonal de  $E$ , então

$$\forall y \in E \quad \|P(y)\| \leq \|y\|, \quad (1.48)$$

onde  $\| \cdot \|$  = norma do vetor.

PROVA - Supondo  $P$  uma projeção ortogonal de  $E$ , temos por (1.37)  $P^2 = P$  e ainda, como  $\forall y \in E$  temos

$$(P(y), y_2) = 0, \text{ para todo } y_2 \in (\text{Im}(P))^\perp$$

então,



$$(P(y), y_2) = (y, P^t(y_2)) = 0 \quad (\forall y \in E) \iff P^t(y_2) = \emptyset$$

para todo  $y_2 \in (\text{Im } P)^\perp$

de modo análogo, como por (1.46)  $I-P$  é também uma projeção ortogonal de  $E$  sobre o  $\text{Ker } P = (\text{Im } P)^\perp$  segundo a direção dos vetores da  $(\text{Im } P)$ , temos

$$\forall y \in E \quad \text{e} \quad y_1 \in \text{Im}(P)$$

$$((I-P)(y), y_1) = (y, (I-P)^t(y_1)) = 0 \iff$$

$$(I-P)^t(y_1) = y_1 - P^t(y_1) = 0 \iff P^t(y_1) = y_1$$

logo, como para todo  $y \in E \rightarrow y = y_1 + y_2$  com  $y_1 \in \text{Im}(P)$  e  $y_2 \in (\text{Im } P)^\perp$  temos

$$P^t(y) = P^t(y_1 + y_2) = P^t(y_1) + P^t(y_2) = P^t(y) = y_1 = P(y)$$

para todo  $y \in E \iff P^t = P$ ,

inversamente, supondo  $P^2 = P = P^t$  temos,  $P^2 = P \iff$  por (1.31)  $P$  é uma projeção de  $E$  na  $\text{Im}(P)$  segundo a direção dos vetores do  $\text{Ker}(P)$ .

Mostrando que  $\text{Ker } P = (\text{Im } P)^\perp$  temos: se

$$y \in \text{Im}(P) \quad \text{e} \quad x \in \text{Ker}(P)$$

então,

$$(x, y) = (x, P(y)) = (P^t(x), y) = (P(x), y) = (\emptyset, y) = 0$$

ou seja  $(\text{Ker } P) = (\text{Im } P)^\perp$ , ainda,

Supondo  $P$  uma projeção ortogonal de  $E$  temos

$$\forall y \in E, 0 \leq \|P(y)\|^2 = (P(y), P(y)) = (P(y), y)$$

e portanto por (1.14)  $P$  é positiva.

Como  $I - P$  é também uma projeção ortogonal de  $E$  então  $I - P$  é positiva e portanto

$$\begin{aligned} \|y\|^2 - \|P(y)\|^2 &= (y, y) - (P(y), P(y)) = (y, y) - (P(y), y) = \\ &= ((I - P)(y), y) \geq 0 \rightarrow \|P(y)\|^2 \leq \|y\|^2. \end{aligned}$$

**COROLÁRIO 3.1** - Se  $E$  é um espaço vetorial com produto interno e  $P$  é uma projeção ortogonal de  $E$  então os auto valores de  $P$  são iguais a zero ou um e, os auto vetores de  $P$  associados a auto valores distintos são ortogonais. (1.49)

**PROVA** - Supondo  $P$  uma projeção ortogonal de  $E$  e  $\lambda \in \mathbb{R}$  temos que, se  $\lambda$  é tal que

$$Px = \lambda x \text{ onde } x \neq \emptyset, x \in E \rightarrow P(P(x)) = P^2x = Px = \lambda x$$

e

$$P(P(x)) = P(\lambda x) = \lambda P(x) = \lambda^2 x \iff \lambda x = \lambda^2 x \iff$$

$$(\lambda - \lambda^2)x = \emptyset \iff \lambda - \lambda^2 = 0$$

(pois,

$$x \neq \emptyset) \iff \lambda = \lambda^2 \iff \lambda = 1 \text{ ou } \lambda = 0$$

e também, se

$$P(x_1) = \lambda_1 x_1 \text{ para algum } x_1 \in E \text{ e } x_1 \neq \emptyset$$

e

$$P(x_2) = \lambda_2 x_2 \text{ para algum } x_2 \in E \text{ e } x_2 \neq \emptyset$$

temos

$$\begin{aligned}\lambda_1(x_1, x_2) &= (\lambda_1 x_1, x_2) = (P(x_1), x_2) = (x_1, P(x_2)) = \\ &= (x_1, \lambda_2 x_2) = \lambda_2(x_1, x_2),\end{aligned}$$

assim,

se  $\lambda_1 \neq \lambda_2$  então  $(x_1, x_2) = 0$  ou seja os auto vetores de  $P$  associado a auto valores distintos são ortogonais.

TEOREMA 3.9 - Seja  $E$  um espaço vetorial com produto interno. Se  $P$  é um endomorfismo de  $E$  tal que

$$P^2 = P \text{ e } \|P(y)\| \leq \|y\| \text{ para todo } y \in E \text{ então } P = P^t. \quad (1.50)$$

PROVA - Como  $P^2 = P \rightarrow$  (por 1.37)  $P$  é uma projeção de  $E$  na  $\text{Im}(P)$  segundo o  $\text{Ker}(P)$  basta então mostrarmos que

$$(\text{Im } P)^\perp = \text{Ker}(P) \text{ ou } (\text{Ker}(P))^\perp = \text{Im}(P).$$

Para este propósito, temos:

$$\forall x \in (\text{Ker } P)^\perp \text{ e } y = P(x) - x$$

temos que  $x \in (\text{Ker } P)^\perp$  e  $y \in \text{Ker}(P)$  assim

$$\begin{aligned}P(x) &= x + y \text{ com } (x, y) = 0 \longrightarrow \|P(x)\|^2 = \\ &= (P(x), P(x)) = (x+y, x+y) = (x, x) + \\ &+ (y, y) = \|x\|^2 + \|y\|^2 \leq \|x\|^2 \iff \|y\| \leq \\ &\leq 0 \iff y = \emptyset\end{aligned}$$

ou seja  $\|P(x)\| = \|x\| \iff x \in \text{Im}(P)$  e portanto  $(\text{Ker}(P))^\perp \subset \text{Im}(P)$ .

Como  $\dim(\text{Im}(B)) = \dim(E) - \dim(\text{Ker}(B))$  e a

$$\dim(\text{Ker}(P))^\perp = \dim(E) - \dim(\text{Ker}(P))$$

temos  $\dim(\text{Im}(P)) = \dim(\text{Ker}(P))$

e portanto  $\text{Im}(P) = (\text{Ker}(P))^\perp$ .

Observe que o Teorema 3.5 permanece válido se a palavra projeção é qualificada no contexto como ortogonal.

Isto é uma consequência imediata da caracterização precedente de projeções ortogonais e do fato que soma e diferença de transformações auto-adjuntas é auto-adjunta, enquanto o produto de duas transformações auto-adjunta é auto-adjunta se, e somente se elas comutam. (1.51)

Generalizando o teorema da soma para projeções ortogonais, temos  
TEOREMA 3.10 - Seja E um espaço vetorial com produto interno. Seja ainda  $P_1, \dots, P_s$  projeções ortogonais de E.

Uma condição necessária e suficiente para que

$$P = \sum_{i=1}^s P_i \text{ seja uma projeção ortogonal de E}$$

é que  $P_i P_j = \emptyset$ , para  $i \neq j$ ,  $i$  e  $j = 1, \dots, s$

ou seja, a imagem de  $P_i$  e  $P_j$  para  $i \neq j$  são ortogonais (1.52)

PROVA - Supondo  $P_i$ ,  $i = 1, \dots, s$  e  $P = \sum_{i=1}^s P_i$  projeções ortogonais de E, temos por (1.48) para todo  $x \in E$

$$\|P(x)\| \leq \|x\|$$

mas, como

$$\|P(x)\| \leq \|x\| \iff \|P(x)\|^2 \leq \|x\|^2 \iff$$

$$\begin{aligned} \|P(x)\|^2 &= (P(x), P(x)) = (P^t P(x), x) = \\ &= (P^2(x), x) = (P(x), x) = \left( \sum_{i=1}^s P_i(x), x \right) = \\ &= \sum_{i=1}^s (P_i(x), x) = \sum_{i=1}^s \|P_i(x)\|^2 \leq \|x\|^2 \end{aligned}$$

então, se  $x \in \text{Im}(P_i)$  para algum  $i$ ,  $i = 1, \dots, s$  temos

$P_i(x) = x$  e portanto

$$\sum_{\substack{j=1 \\ j \neq i}}^s \|P_j(x)\|^2 \leq 0 \iff$$

$$\|P_j(x)\|^2 = 0 \text{ para todo } j, j \neq i, i \text{ e } j = 1, \dots, s \iff$$

$$P_j(x) = 0 \iff x \in \text{Ker}(P_j) = (\text{Im}(P_j))^\perp$$

para todo  $j$ ,  $j \neq i$ ,  $i$  e  $j = 1, \dots, s$

ou seja,  $\text{Im}(P_i) \subset (\text{Im}(P_j))^\perp$  para todo  $j$ ,  $j \neq i$ ,  $i$  e  $j = 1, \dots, s$  reciprocamente,

é imediata usando indução finita sobre  $s \geq 2$  e o teorema 3.5 para projeções ortogonais.

Finalizando nosso estudo de projeções temos,

TEOREMA 3.11 - Se  $P_1$  e  $P_2$  são projeções ortogonais de  $E$ , então as seguintes condições são mutuamente equivalentes

a)  $\|P_1(x)\| \leq \|P_2(x)\|$  para todo  $x \in E$

b)  $\text{Im}(P_1) \subset \text{Im}(P_2)$

$$c) P_2 P_1 = P_1$$

$$d) P_1 P_2 = P_1.$$

PROVA - Supondo,  $P_1$  e  $P_2$  projeções ortogonais de  $E$  temos

$$\text{pelo Teorema 3.8 } P_1 = P_1^t \text{ e } P_2 = P_2^t$$

pelo Teorema 3.5  $\text{Im}(P_1) \subset \text{Im}(P_2) \iff P_2 P_1 = P_1$  e portanto, é trivial que

$$\text{Im}(P_1) \subset \text{Im}(P_2) \iff P_2 P_1 = P_1 \iff P_1 P_2 = P_1$$

mostremos que a)  $\iff$  b).

Supondo que  $\|P_1(x)\| \leq \|P_2(x)\|$  para todo  $x \in E$ , então, se

$$x \in \text{Ker}(P_2) \longrightarrow P_2(x) = \emptyset$$

$$\longrightarrow \|P_2(x)\| = 0 \geq \|P_1(x)\| \longrightarrow \|P_1(x)\| = 0 \longrightarrow$$

$$\longrightarrow P_1(x) = 0 \longrightarrow x \in (P_1) \text{ ou seja } \text{Ker}(P_2) \subset \text{Ker}(P_1)$$

e portanto

$$\text{Im}(P_1) = (\text{Ker}(P_1))^\perp \subset (\text{Ker}(P_2))^\perp = \text{Im}(P_2)$$

supondo que  $\text{Im}(P_1) \subset \text{Im}(P_2)$ ,

então, por a) b) e c)

$$P_2 P_1 = P_1 P_2 = P_1 \iff (\text{por 1.42})$$

$P_2 - P_1$  é uma projeção e também satisfaz por hipótese

$$(P_2 - P_1)^t = P_2^t - P_1^t = P_2 - P_1$$

assim, para todo  $y \in E$

$$\begin{aligned}\|P_2(y)\|^2 - \|P_1(y)\|^2 &= (P_2(y), P_2(y)) - (P_1(y), P_1(y)) = \\ &= (P_2(y), y) - (P_1(y), y) = ((P_2 - P_1)(y), y) = \\ &= ((P_2 - P_1)(y), (P_2 - P_1)(y)) = \|(P_2 - P_1)(y)\|^2 \geq 0 \longrightarrow \\ \|P_2(y)\|^2 &\geq \|P_1(y)\|^2 \text{ para todo } y \in E,\end{aligned}$$

ou seja

$$\|P_2(y)\| \geq \|P_1(y)\| \text{ para todo } y \in E.$$

#### 1.4 - PROJETOR ORTOGONAL ASSOCIADO A UMA MATRIZ

DEFINIÇÃO 4.1 - Considerando uma matriz  $X_{n \times p}$ ;  $X = (x_{(j)})$ , onde  $x_{(j)}$ ,  $j = 1, \dots, p$ , são vetores  $n \times 1 \in \mathbb{R}^n$ , e

$P: \mathbb{R}^n \longrightarrow \mathbb{R}^n$  um operador projeção ortogonal de  $\mathbb{R}^n$ .

Então, se

$\text{Im}(P) = C(X)$  dizemos que  $P$  é uma projeção ortogonal de  $\mathbb{R}^n$  sobre o espaço coluna de  $X$

DEFINIÇÃO 4.2 - Seja  $X$  uma matriz  $n \times p$  e  $P$  um operador projeção ortogonal de  $\mathbb{R}^n$  sobre  $C(X)$ .

Define-se  $\cos(y, C(X))$  para todo  $y \in \mathbb{R}^n$  ao cosseno do ângulo entre o vetor  $y$  e a sua projeção ortogonal sobre  $C(X)$ , ou seja

$$\cos(y, C(X)) = \cos(y, P(y)).$$

Uma forma matricial para apresentar o operador projeção orto-

gonal sobre  $C(X)$  é dada por:

TEOREMA 4.1 - Para toda matriz  $X$   $n \times p$  de posto  $r \leq \min(n,p)$  existe uma matriz  $B$   $p \times n$  tal que

$$X^t X B = X^t$$

e, se

$$P_X = X B$$

então

$P_X$  representa a matriz do operador projeção ortogonal sobre  $C(X)$  e ainda,  $P_X = X B$  é única (1.53)

PROVA - Como, por (1.35) temos

$C(X^t X) = C(X^t)$  então, para todo  $y \in \mathbb{R}^n$ ,  
existe  $b \in \mathbb{R}^p$  tal que  $X^t X b = X^t y$ .

Fazendo  $y$  sucessivamente igual a

$$y_j = (d_{ij}), \quad j=1, \dots, n, \quad \text{onde } d_{ij} = \begin{cases} 1 & \text{se } i = j \\ 0 & \text{se } i \neq j \end{cases}$$

temos que existe  $b_j, j = 1, \dots, n, \in \mathbb{R}^p$  tal que

$$X^t y_j = X^t b_j = x_{(j)}^t$$

onde  $x_{(j)}$  =  $j$ -ésima linha de  $x$ , assim, tomando  $B = (b_1 : \dots : b_n)$

temos que existe uma matriz  $B$   $p \times n$  tal que

$$X^t X B = X^t.$$



Fazendo  $P_X = XB$  temos que  $P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)$ , pois,

a)  $P_X^t = P_X$  pois,

$$X^tXB = X^t \iff B^tX^tX = X$$

assim,

$$P_X = XB = B^tX^tXB = B^tX^t = (XB)^t = P_X^tX$$

b)  $P_X^2 = P_X$ , pois

$$(P_X)^2 = (XB)(XB) = (XB)^t(XB) = B^tX^tXB = B^tX^t = P_X$$

c)  $\text{posto}(P_X) = \text{posto } X$ , pois

como

$$\begin{aligned} \text{posto}(X) &= \text{posto}(X^t) = \text{posto}(X^tXB) \leq \\ &\leq \text{posto}(XB) \leq \text{posto}(X), \end{aligned}$$

então

$$\text{posto}(BX) = \text{posto}(X)$$

e como  $C(P_X) \subset C(X)$  concluímos que  $C(P_X) = C(X)$  e portanto, por a), b) e c) concluímos que  $P_X = XB$  é a matriz do operador projeção ortogonal sobre  $C(X)$ .

Supondo que exista uma outra matriz  $P_X^* = XB_1$  onde  $B_1$  é uma matriz  $p \times n$  tal que  $X^tXB_1 = X^t$ , temos então que,  $P_X^*$  é também uma matriz do operador projeção ortogonal sobre  $C(X)$ . Temos para todo  $y \in \mathbb{R}^n$ .

$$\begin{aligned} X^t P_X^* y &= X^t y = X^t P_X y \iff \\ \iff X^t (P_X^* y - P_X y) &= \emptyset \iff \\ \iff P_X^* y - P_X y &\in \text{Ker}(X^t) = C(X)^\perp \end{aligned}$$

e como

$$P_X^* y - P_X y = X B_1 y = X(B_1 y - B y) \in C(X)$$

temos

$$P_X^* y - P_X y = \emptyset \implies P_X^* y = P_X y \text{ para todo } y \in \mathbb{R}^n$$

então, concluímos que  $P_X^* = P_X$ .

DEFINIÇÃO 4.3 - Seja  $X$  uma matriz  $n \times p$ .

Define-se matriz do operador projeção ortogonal sobre  $C(X)$  a matriz

$P_X = XB$  onde  $B$  é uma matriz  $p \times n$  tal que

$$X^t XB = X^t.$$

Como, a relação entre  $X$  e  $B$  é tal que

$$(XB)^t = XB \text{ e}$$

$$XBX = (XB)^t X = B^t X^t X = X$$

então, concluímos que  $B$  é uma inversa generalizada de  $X$  de mínimos quadrados (ver Rao & Mitra (1969)). (1.54)

Assim, um aspecto importante da matriz do operador projeção ortogonal sobre  $C(X)$  é que ela é obtida da aproximação

de mínimos quadrados e portanto aproxima o vetor  $y \in \mathbb{R}^n$  por vetores pertencentes ao sub-espço  $C(X)$  de  $\mathbb{R}^n$ . Tal fato, será estudado com detalhes no Capítulo 2.

Algumas das propriedades a respeito de  $P_X = XB$  são consequências imediatas das propriedades dos operadores projeção ortogonal e portanto faremos apenas citá-las.

PROPRIEDADES DE  $P_X$  - Se  $X$  é uma matriz  $n \times p$  de posto  $r \leq \min(n, p)$  e  $P_X = XB$  é a matriz do operador projeção ortogonal sobre  $C(X)$  então,  $P_X$  satisfaz as seguintes propriedades:

I)  $I - P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)^\perp$  (1.55)

II) Para todo vetor  $y \in \mathbb{R}^n$

$P_X y$  é a projeção ortogonal de  $y$  em  $C(X)$  (1.56)

e

$(I - P_X)y$  é a projeção ortogonal de  $y$  em  $C(X)^\perp$  (1.57)

III) Se  $A$  é uma matriz  $n \times r$  de posto  $r$  tal que  $C(A) = C(X)$  então

$P_A = P_X$  (1.58)

PROVA - Supondo  $C(X) = C(A)$  onde  $A$  é uma matriz  $n \times r$  de posto  $r$  temos

$$C(X) = C(A) \implies C(X)^\perp = C(A)^\perp$$

e como para todo vetor  $y \in \mathbb{R}^n$ ,  $y$  é univocamente determinado por

$$y = P_X y + (I - P_X) y = P_A y + (I - P_A) y$$

(usando (1.56) e (1.57))

onde  $P_X y \in C(X)$  e  $P_A y \in C(A)$

e  $(I - P_X) y \in C(X)^\perp$  e  $(I - P_A) y \in C(A)^\perp$

então por hipótese vale a igualdade acima apenas quando

$$P_X y = P_A y \text{ para todo } y \in \mathbb{R}^n \text{ ou seja } P_X = P_A.$$

IV) Se as colunas da matriz A formam uma base ortonormal de  $C(X)$  então,  $P_X = AA^t$  (1.59)

PROVA - Supondo que as colunas da matriz A formam uma base ortogonal de  $C(X)$  temos

$$A^t A = I_r \text{ e } C(A) = C(X).$$

Como por definição  $P_A = AE$  é a matriz do operador projeção ortogonal sobre  $C(A)$  apenas quando  $E$  satisfaz  $A^t AE = A^t$ , então, se  $P_A$  é a matriz do operador projeção ortogonal sobre  $C(A)$  temos que

$$P_A = AA^t$$

e assim, como  $C(X) = C(A)$  onde

$$P_A = AA^t \longrightarrow \text{(por 1.58)}$$

$$P_X = AA^t.$$

V) Os auto-valores de  $P_X$  são iguais a zero ou um. (1.60)

Estudemos agora as partições de  $C(X)$  como fonte geradora

de sub-espacos que decompõem este  $C(X)$  em soma direta de sub-espacos ortogonais.

PROPOSIÇÃO 4.1 - Se  $X$  é uma matriz  $n \times p$  e  $X_i, i=1, \dots, s$ , são matrizes  $n \times p_i$  respectivamente onde  $p = \sum_{i=1}^s p_i$ , então,

$$X = (X_1 : X_2 : \dots : X_s) \leftrightarrow C(X) = \sum_{i=1}^s C(X_i) \quad (1.61)$$

PROVA - Supondo  $X = (X_1 : \dots : X_s)$  temos, para todo  $\lambda \in \mathbb{R}^n$  tal que  $\lambda \in C^\perp(X)$  então,

$$\begin{aligned} \lambda^t &= \lambda^t (X_1 : \dots : X_s) = \emptyset \leftrightarrow \\ &\leftrightarrow (\lambda^t X_1 : \dots : \lambda^t X_2 : \dots : \lambda^t X_s) = \emptyset \leftrightarrow \\ &\leftrightarrow \lambda^t X_i = \emptyset \text{ para todo } i=1, \dots, s \leftrightarrow \\ &\leftrightarrow \lambda \in \prod_{i=1}^s C(X_i)^\perp \leftrightarrow (\text{por (1.31)}) \end{aligned}$$

$$\lambda \in \left( \sum_{i=1}^s C(X_i) \right)^\perp$$

e portanto  $\sum_{i=1}^s C(X_i) \subset C(X)$   
Como

$$\begin{aligned} \dim \left( \sum_{i=1}^s C(X_i) \right) &= \sum_{i=1}^s \dim C(X_i) - \sum_{i=1}^{s-1} \sum_{j=i+1}^s \dim(C(X_i) \cap C(X_j)) = \\ &= \sum_{i=1}^s \text{posto}(X_i) - \sum_{i=1}^s \sum_{j=i+1}^s \dim(C(X_i) \cap C(X_j)) = \\ &= \text{posto}(X) = \dim(C(X)) \end{aligned}$$

concluimos que  $C(X) = \sum_{i=1}^s C(X_i)$  reciprocamente é trivial que

$X = (X_1 : \dots : X_s)$  onde  $X_i$  são matrizes  $n \times p_i$  com

$$p = \sum_{i=1}^s p_i.$$

TEOREMA 4.2 - Se  $X = (X_1 : X_2)$  onde  $X_i$ ,  $i=1,2$ , são matrizes  $n \times p_i$  respectivamente, com  $p_1 + p_2 = p$  então; se

$P_{12}$  é o operador projeção ortogonal de  $R^n$  sobre  $C(X)$

e

$P_1$  é o operador projeção ortogonal de  $R^n$  sobre  $C(X_1)$

temos que

$$C(X) = \text{Im}(P_1) \overset{\perp}{\oplus} \text{Im}(P_{12} - P_1)$$

onde

$$\text{Im}(P_{12} - P_1) = \text{Im}(P_{12}) \cap \text{Ker}(P_1)$$

e

$$\text{Ker}(P_{12} - P_1) = \text{Im}(I - P_{12}) \overset{\perp}{\oplus} \text{Im}(P_1). \quad (1.62)$$

PROVA - Supondo  $X = (X_1 : X_2)$  e

$P_{12}$  o operador projeção ortogonal de  $R^n$  sobre  $C(X)$

e

$P_1$  o operador projeção ortogonal de  $R^n$  sobre  $C(X_1)$

temos

$$\begin{aligned} \text{Como } X = (X_1 : X_2) &\longrightarrow C(X_1) \subset C(X) \longrightarrow \text{Im}(P_1) \subset \text{Im}(P_{12}) \longrightarrow \\ &\longrightarrow (\text{teor 3.11}) \end{aligned}$$

$$P_{12}P_1 = P_1P_{12} = P_1 \longrightarrow \text{(extensão de (1.42))}$$

para projeções ortogonais)

$P_{12}-P_1$  é uma projeção ortogonal onde

$$\text{Im}(P_{12}-P_1) = \text{Im}(P_{12}) \cap \text{Ker}(P_1)$$

e

$$\text{Ker}(P_{12}-P_1) = \text{Im}(I-P_{12}) \overset{\perp}{\oplus} \text{Im}(P_1)$$

e ainda, como

$$P_{12}P_1 = P_1P_{12} = P_1 \longleftrightarrow$$

$$\longleftrightarrow (I-P_{12})P_1 = P_1(I-P_{12}) = \emptyset \longrightarrow \text{(extensão de (1.41) para projeções ortogonais)}$$

$P_1+(P_{12}-P_1) = P_{12}$  é uma projeção ortogonal sobre a

$$\text{Im}(P_1+(P_{12}-P_1)) = \text{Im}(P_1) \overset{\perp}{\oplus} \text{Im}(P_{12}-P_1)$$

e como

$$\text{Im}(P_1+(P_{12}-P_1)) = \text{Im}(P_{12}) = C(X)$$

então concluímos que

$$C(X) = \text{Im}(P_1) \overset{\perp}{\oplus} \text{Im}(P_{12}-P_1)$$

onde

$$\text{Im}(P_{12}-P_1) = \text{Im}(P_{12}) \cap \text{Ker}(P_1).$$

Observe que tal decomposição pode ser estendida para uma partição de  $C(X)$  em mais de dois sub-espacos de  $C(X)$  como por exemplo:

PROPOSIÇÃO 4.2 - Se  $X = (X_1 : X_2 : X_3)$ , onde  $X_i$ ,  $i=1,2,3$ , são matrizes  $n \times p_i$  respectivamente, com

$$\sum_{i=1}^3 p_i = p$$

então, se

$P_{123}$  é o operador projeção ortogonal sobre  $C(X)$

$P_{12}$  é o operador projeção ortogonal sobre  $C(X_1 : X_2)$

$P_1$  é operador projeção ortogonal sobre  $C(X_1)$ ,

temos que

$$C(X) = \text{Im}(P_1) \overset{\perp}{\oplus} \text{Im}(P_{12} - P_1) \overset{\perp}{\oplus} \text{Im}(P_{123} - P_{12})$$

onde

$$\text{Im}(P_{12} - P_1) = \text{Im}(P_{12}) \cap \text{Ker}(P_1)$$

$$\text{Im}(P_{123} - P_{12}) = \text{Im}(P_{123}) \cap \text{Ker}(P_{12}). \quad (1.63)$$

PROVA - Análoga ao Teorema 4.2.

Da mesma forma que existe  $B_{p \times n}$  tal que  $X^t = XB = X^t$  podemos demonstrar que existe uma matriz  $C_{p \times n}$  tal que

$$XX^t C^t = X$$



e

$P_X^t = X^t C^t$  é a única matriz do operador projeção ortogonal sobre  $C(X^t) = L(X)$ . (1.64)

DEFINIÇÃO 4.4 - Seja  $X$  uma matriz  $n \times p$ .

Define-se matriz do operador projeção ortogonal sobre  $C(X^t) = L(X) =$  espaço linha de  $X$  a matriz  $P_X^t = X^t C^t$ , onde  $C$  é uma matriz  $p \times n$  tal que  $XX^t C^t = X$ . (1.65)

Considerando, a matriz  $G = CXB$ , onde  $B$  e  $C$  são matrizes  $p \times n$  satisfazendo  $X^t X B = X^t$  e  $XX^t C^t = X$ , respectivamente (1.66) temos

PROPOSIÇÃO 4.3 - A matriz  $G$  definida em (1.65) é única para qualquer escolha de  $B$  e  $C$ . (1.67)

PROVA - Supondo  $B_1$  e  $B_2$  quaisquer duas matrizes tais que

$$X^t X B_1 = X^t \text{ e } X^t X B_2 = X^t$$

a  $C_1$  e  $C_2$  quaisquer duas matrizes tais que

$$XX^t C_1^t = X \text{ e } XX^t C_2^t = X$$

temos por (1.53) e (1.64) que

$$X B_1 = X B_2 \text{ e } C_1 X = C_2 X$$

assim, se  $G_{ij} = C_i X B_j$  para  $i, j = 1, 2$ , então

$$C_1 X B_1 = C_2 X B_1 = C_2 X B_2 = C_1 X B_2$$

ou seja,

$G_{ij} = G_{i'j'}$ , para todo  $i, j, i', j' = 1, 2$  e assim prova-se que  $G$  é única. Mas, ainda  $G$  satisfaz as seguintes propriedades:

I)  $XGX = X$  pois

como para toda matriz  $C$  tal que

$$XX^t C^t = X \quad (1.68)$$

e para toda matriz  $B$  tal que

$$X^t XB = X^t \quad (1.69)$$

então se  $G = CB$  como em (1.66) temos

$$XGX = XCXB = \text{por (1.68)} XB = \text{por (1.69)} X.$$

II)  $GXG = G$  pois

$$G = CXB \longrightarrow CXBXCXB = (1.69) CXCXB = (1.68) CXB = G$$

III)  $(XG)^t = XG$  pois

$$(XG)^t = G^t X^t = B^t X^t C^t X^t = B^t X^t = XB = XCXB = XG$$

IV)  $(GX)^t = GX$ , pois

$$(GX)^t = X^t G^t = X^t B^t X^t C^t = X^t C^t = CX = CXBX = GX$$

que são as condições para a única inversa de Moore-Penrose (ver Rao & Mitra (1971)).

A inversa de Moore-Penrose é importante na solução de sistema lineares consistentes, como veremos:

PROPRIEDADE 4.1 - Seja  $X$  uma matriz  $n \times p$  se,  $XY = c$  é um sistema linear consistente então a solução geral de  $XY = c$  é dado por

$$y = X^+c + (I_p - X^+X)z \text{ para todo vetor } z \in R^p, \text{ e onde}$$

$X^+ = CXB$  é a única inversa de Moore-Penrose.

PROVA - Sabe-se que a solução geral do sistema  $XY = c$  consiste de uma solução particular arbitrária combinada com cada solução de  $XY = \emptyset$  que são os vetores pertencentes ao núcleo de  $X$ . Assim, se posto  $X = r$  então, posto  $(I_p - X^+X) = p - r$  e portanto o espaço coluna de  $(I_p - X^+X)$  é de dimensão  $p - r$ , e assim como

$$x(I_p - X^+X) = \emptyset \text{ e a } \dim(C(I_p - X^+X)) = \dim N(X)$$

então, podemos concluir que

$$C(I_p - X^+X) = N(X)$$

e portanto, a solução geral de  $XY = c$  é

$$y = X^+c + (I_p - X^+X)z \text{ para qualquer vetor } z \in R^p.$$

Um outro aspecto de grande importância de  $X^+$  é dado por (Rao & Mitra (1971) onde eles mostram que  $X^+ = CXB$  é a solução de Mínima Norma do sistema de equações consistente  $XY = c$ .

CAPÍTULO 2  
CARACTERIZAÇÃO DO BLUE  
NO MODELO DE GAUSS-MARKOFF

2.1 - APROXIMAÇÃO DOS MÍNIMOS QUADRADOS - Seja

$y = (y_i)$ ,  $i=1 \dots n$ , um vetor de  $R^n$

$X = (x_{(j)})$  uma matriz  $n \times p$  conhecida de posto  $r < p$

onde

$x_{(j)}$ ,  $j=1, \dots, p$ , são vetor  $n \times 1$  de  $R^n$

e

$\beta = (\beta_j)$ ,  $j=1, \dots, p$ , um vetor de  $R^p$

Considerando o modelo

$$y = X \beta + e \quad \text{onde } e \text{ é um vetor } n \times 1 \text{ de perturbação ou erro} \quad (2.1)$$

temos

DEFINIÇÃO 1.1 - A aproximação dos mínimos quadrados de  $y$  por vetores de  $C(X)$  consiste em achar um vetor  $\eta \in C(X)$  tal que

$$\min_{\eta \in C(X)} ||y - \hat{\eta}||^2 = ||y - \hat{\eta}||^2 \quad (2.2)$$

Tal aproximação é dada por

TEOREMA 1.1 - Considerando uma matriz  $X_{n \times p} = (x_{(j)})$  onde,  $x_{(j)}$ ,  $j=1, \dots, p$ , são vetores de  $R^n$ .

e

$P_X$  uma matriz do operador projeção ortogonal de  $R^n$  sobre  $C(X)$

Então, para todo  $y \in R^n$

$$\min_{\eta \in C(X)} \|y - \eta\|^2 = y^t (I - P_X) y$$

e este mínimo é atingido quando

$$\hat{\eta} = P_X y = \text{projeção ortogonal de } y \text{ sobre } C(X) \quad (2.3)$$

PROVA - Por Cauchy-Schwarz, para qualquer vetor  $c \in R^n$  e  $\eta \in C(X)$

$$\|y - \eta\|^2 \geq \frac{[c^t (y - \eta)]^2}{c^t c} \quad (2.4)$$

Fazendo  $c = (I - P_X) y$  onde

$P_X$  é uma matriz do operador projeção ortogonal de  $R^n$  sobre  $C(X)$  temos, por (1.55) que

$I - P_X$  é uma matriz do operador projeção ortogonal de  $R^n$  sobre  $C(X)^\perp$

e portanto

$$c^t c = y^t (I - P_X)^t (I - P_X) y = y^t (I - P_X) y \quad (2.5)$$

e

$$\begin{aligned} c^t (y - \eta) &= y^t (I - P_X) (y - \eta) = \\ &= y^t [(I - P_X) y - (I - P_X) \eta] = \end{aligned}$$

$$= y^t (I - P_X) y \quad (2.6)$$

Substituindo (2.5) e (2.6) em (2.4)

(2.4) fica

$$\|y - \eta\|^2 \geq \frac{(y^t (I - P_X) y)^2}{y^t (I - P_X) y} = y^t (I - P_X) y \quad (2.7)$$

Fazendo  $\hat{\eta} = P_X y =$  projeção ortogonal de

$y$  sobre  $C(X)$  então

$$\begin{aligned} \|y - \hat{\eta}\|^2 &= \|y - P_X y\|^2 = \|(I - P) y\|^2 = \\ &= ((I - P_X) y, (I - P_X) y) = (y, (I - P_X) y) = \\ &= y^t (I - P_X) y \end{aligned} \quad (2.8)$$

assim, por (2.7) e (2.8)

$$\min_{\eta \in C(X)} \|y - \eta\|^2 = \|y - \hat{\eta}\|^2 = y^t (I - P_X) y$$

onde

$\hat{\eta} = P_X y =$  projeção ortogonal de

$y$  sobre  $C(X)$

Apesar deste resultado ser matematicamente elegante, podemos notar que esta formulação independe da base gerada pelos vetores coluna de  $X$ , portanto, despreza aspectos do problema nos quais envolve os atuais vetores  $x(j)$ ,  $j = 1, \dots, p$ , que são de grande importância, como por exemplo, nos problemas de regressão.

Considerando, a aproximação dos mínimos quadrados dos vetores  $y \in R^n$  por vetores de  $C(X)$  ao vetor

$$\hat{y} = X \hat{\beta} \in C(X) \text{ temos}$$

DEFINIÇÃO 2.2 - Seja o modelo  $y = X\beta + e$  dado por (2.1)

A aproximação dos mínimos quadrados de  $y$  por uma combinação linear das colunas da matriz  $X - \sum_{j=1}^p x(j) \beta_j$  - consiste em achar aqueles coeficientes  $\hat{\beta}_1, \dots, \hat{\beta}_p$  os quais minimizam a soma dos quadrados dos desvios de  $y$  pela sua aproximação ou seja, os  $\hat{\beta}_1, \dots, \hat{\beta}_p$  escolhidos de tal forma que

$$\begin{aligned} \min_{\beta_1, \dots, \beta_p} \sum_{i=1}^n (y_i - \sum_{j=1}^p x_{ij} \beta_j)^2 &= \\ &= \sum_{i=1}^n (y_i - \sum_{j=1}^p x_{ij} \hat{\beta}_j)^2 \end{aligned} \quad (2.9)$$

Em forma matricial temos,

$$\text{Se } \min_{\eta \in C(X)} \|y - \eta\|^2 = \min_{\beta \in R^p} \|y - X\beta\|^2 = \|y - X\hat{\beta}\|^2$$

então a aproximação dos mínimos quadrados de  $y$  por vetores de  $C(X)$  é dado por  $X \hat{\beta} = \hat{y}$  (2.10)

## 2.2 - COMPUTAÇÃO DOS COEFICIENTES DE MÍNIMOS QUADRADOS E EQUAÇÕES NORMAIS

Considerando a função

$$Q(\beta) = (y - X\beta)^t (y - X\beta) \text{ onde}$$

$y, X$  e  $\beta$  são dados pelo modelo (2.1)

temos que

$$Q(\beta) = \sum_{i=1}^n (y_i - \sum_{j=1}^p x_{ij} \beta_j)^2 \geq 0$$

e é contínua para todo vetor  $\beta \in \mathbb{R}^p$ .

Assim, derivando  $Q(\beta)$  com relação a  $\beta_k$ ,  $k = 1, \dots, p$ , e, igualando a zero cada uma dessas derivadas parciais temos

$$\frac{\partial Q(\beta)}{\partial \beta_k} = -2 \sum_{i=1}^n x_{ik} (y_i - \sum_{j=1}^p x_{ij} \beta_j) = 0 \quad \leftrightarrow$$

$$\sum_{i=1}^n x_{ij} y_i = \sum_{i=1}^n x_{ik} \left( \sum_{j=1}^p x_{ij} \beta_j \right) \quad \leftrightarrow$$

$$X_{(k)}^t y = X_{(k)}^t X \beta$$

onde  $X_{(k)}$  = k-ésima coluna de  $X$ , ( $k = 1, \dots, p$ ).

Em forma matricial, se

$$\frac{\partial (Q(\beta))}{\partial \beta} = 0 \quad \text{então } \beta \text{ satisfaz o sistema de e-}$$

quações  $X^t X \beta = X^t y$

que é denominado de equações normais que é sempre consistente desde que por (1.35) temos  $C(X^t X) = C(X^t)$ .

Ainda, como  $\forall \beta \in \mathbb{R}^p$  e  $\hat{\beta} \in \mathbb{R}^p$  tal que  $X^t X \hat{\beta} = X^t y$

$$\begin{aligned} Q(\beta) &= (y - X\beta)^t (y - X\beta) = (y - X\hat{\beta} + X(\hat{\beta} - \beta))^t (y - X\hat{\beta} + X(\hat{\beta} - \beta)) = \\ &= (y - X\hat{\beta})^t (y - X\beta) + (\hat{\beta} - \beta)^t X^t X (\hat{\beta} - \beta) \geq Q(\hat{\beta}) \end{aligned}$$

concluimos que  $Q(\beta)$  admite um mínimo em  $\beta$  dado por  $\hat{\beta}$  para todo  $\hat{\beta} \in \mathbb{R}^p$  tal que satisfaz as equações normais  $X^t X \hat{\beta} = X^t y$



e também, se  $\hat{\beta}_1$  e  $\hat{\beta}_2$  são dois vetores de  $R^p$  tais que

$$X^t X \hat{\beta}_1 = X^t y \quad \text{e} \quad X^t X \hat{\beta}_2 = X^t y$$

então

$$X^t X \hat{\beta}_1 = X^t X \hat{\beta}_2 = X^t y \leftrightarrow$$

$$X^t X (\hat{\beta}_1 - \hat{\beta}_2) = 0 \rightarrow (\hat{\beta}_1 - \hat{\beta}_2)^t X^t X (\hat{\beta}_1 - \hat{\beta}_2) = 0 \leftrightarrow$$

$$(X(\hat{\beta}_1 - \hat{\beta}_2))^t (X(\hat{\beta}_1 - \hat{\beta}_2)) = 0 \leftrightarrow X(\hat{\beta}_1 - \hat{\beta}_2) = 0 \leftrightarrow$$

$$X \hat{\beta}_1 = X \hat{\beta}_2$$

ou seja,  $Q(\beta)$  é invariante para toda solução das equações normais  $X^t X \beta = X^t y$  (2.12)

Reciprocamente, supondo que  $Xt = \bar{y}$  onde  $t = \hat{\beta} + \rho$  com  $\rho \in R^p$  e  $\hat{\beta} \in R^p$  qualquer solução das equações normais seja ou tra aproximação do vetor  $y$  então,

$$\begin{aligned} Q(t) &= (y - X(\hat{\beta} + \rho))^t (y - X(\hat{\beta} + \rho)) = \\ &= [(y - X\hat{\beta}) - X\rho]^t [(y - X\hat{\beta}) - X\rho] = \\ &= (y - X\hat{\beta})^t (y - X\hat{\beta}) - 2(y - X\hat{\beta})^t X\rho + \rho^t X^t X\rho = \\ &= (y - X\hat{\beta})^t (y - X\hat{\beta}) + \rho^t X^t X\rho \text{ pois } (y - X\hat{\beta})^t X = 0 \end{aligned}$$

e assim,  $Q(t) \geq Q(\hat{\beta})$

onde

$$Q(t) = Q(\hat{\beta}) \leftrightarrow \rho^t X^t X\rho = 0 \leftrightarrow X\rho = 0$$

e neste caso

$$\bar{y} = X^t t = X \hat{\beta} = \hat{y} \quad (2.13)$$

Assim, por (2.11), (2.12) e (2.13) podemos concluir que

— TEOREMA 2.1 - Considerando a função  $Q(\beta) = (y - X\beta)^t (y - X\beta)$  onde  $y$ ,  $X$  e  $\beta$  são dados pelo modelo (2.1) então

$$\min_{\beta \in R^p} Q(\beta) = Q(\hat{\beta}) \leftrightarrow \hat{\beta}$$

é solução das equações normais  $X^t X \beta = X^t y$  que são sempre consistentes e ainda,  $X \hat{\beta}$  é o único vetor em  $C(X)$  tal que

$$\min_{\beta \in R^p} Q(\beta) = Q(\hat{\beta}) \quad (2.14)$$

COROLÁRIO 2.1 - Quando a matriz  $X_{n \times p}$  do modelo linear (2.1) é de posto  $p$ , então, o vetor invariante  $X \hat{\beta}$  é explicitamente dado por um conjunto de funções lineares das coordenadas do vetor  $y$  da forma

$$X \hat{\beta} = X (X^t X)^{-1} X^t y \quad (2.15)$$

PROVA - Trivial

Expressões análogas para o vetor  $X \hat{\beta}$  no caso de posto  $X = r < p$  poderão ser obtidas por:

PROPOSIÇÃO 2.1 - Considerando a matriz  $X_{n \times p}$  do modelo linear (2.1) e,

$P_X = X(X^t X)^{-1} X^t$  a matriz do operador projeção ortogonal sobre  $C(X)$  temos então que,

$B y$  é solução das equações normais e portanto,

$$\begin{aligned} X \hat{\beta} &= X \hat{B} y \quad \text{para todo } \hat{\beta} \in \mathbb{R}^p \text{ tal que} \\ &\quad \hat{B} y \\ X^t X \hat{\beta} &= X^t y \end{aligned} \tag{2.16}$$

PROVA - Como por definição  $P_X = XB$  é a matriz do operador projeção ortogonal sobre  $C(X)$  se e somente se  $X$  é uma matriz  $p \times n$  tal que

$$X^t X B = X^t$$

então, para todo  $y \in \mathbb{R}^n$  temos

$$X^t X B y = X^t y \quad \text{onde } B y \in \mathbb{R}^p \tag{2.17}$$

Observando que as estruturas das equações (2.17) coincidem com a estrutura das equações normais, temos que, se

$$y = X \beta + e \quad \text{como em (2.1)}$$

então 
$$X^t X B y = X^t y \quad \rightarrow$$

$B y$  é solução das equações normais e por (2.12)

$$X B y = X \hat{\beta} \quad \text{para todo vetor}$$

$$\hat{\beta} \in \mathbb{R}^p \quad \text{tal que } X^t X \hat{\beta} = X^t y$$

PROPOSIÇÃO 2.2 - A aproximação dos mínimos quadrados  $\hat{y} = X \hat{\beta}$  para o vetor de dados  $y$  é a projeção ortogonal de  $y$  sobre  $C(X)$ .

O vetor de resíduos é a projeção ortogonal de  $y$  sobre o complemento ortogonal de  $C(X)$ .

PROVA - por (2.16)  $X\hat{\beta} = X B y = P_X y$  onde  $P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)$

e

$\hat{e} = y - X\hat{\beta} = (I - P_X) y$  onde  $I - P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)^\perp$

Geometricamente, falando a linguagem de espaços vetoriais, começa-se com um vetor  $y \in R^n$  e  $p$  vetores  $x_{(1)}, \dots, x_{(p)} \in R^p$  tal que  $C(X) = C(x_{(1)} : \dots : x_{(p)})$ .

O problema é então escolher um vetor  $\hat{y} = X\hat{\beta} \in C(X)$  tal que  $\hat{y}$  esteja o mais próximo de  $y$ . Note que a distância mínima requerida é a Euclidiana de um vetor em relação a um sub-espaço. Portanto,  $X\hat{\beta}$  é a projeção ortogonal de  $y$  em  $C(X)$ .

Considerando

$$X\hat{\beta} = P_X y \quad e$$

$$y - X\hat{\beta} = (I - P_X) y$$

como anteriormente obviamente temos que  $(X\hat{\beta})^t (y - X\hat{\beta}) = 0$  e assim, como para todo vetor  $y \in R^n$

$$y = P_X y + (I - P_X) y = X\hat{\beta} + (y - X\hat{\beta})$$

então

$$\|y\|^2 = y^t y = \|X\hat{\beta}\|^2 + \|y - X\hat{\beta}\|^2$$

que é o teorema de Pitágoras.

Esta decomposição é importante em prover uma medida de ajustamento de  $X\hat{\beta}$  para  $y$ .

Evidentemente o ajuste é "melhor" quando os desvios  $y - X\hat{\beta}$  são pequenos, isto é, quando a perpendicular a  $C(X)$ ,  $y - X\hat{\beta}$ , é pequena.

Para uma medida absoluta do ajustamento faz-se uma relação entre o comprimento desta perpendicular e o comprimento de  $y$ .

Uma medida óbvia é:

$$\frac{\|X\hat{\beta}\|^2}{\|y\|^2} = 1 - \frac{\|y - X\hat{\beta}\|^2}{\|y\|^2} = \cos(y, C(X))$$

(ver 1.4 ) o qual está sempre entre zero e um.

Evidentemente quando o ângulo entre  $y$  e  $C(X)$  é pequeno, o cosseno é grande e assim  $y$  está bem ajustado por  $P_X y = X\hat{\beta}$

Nos casos extremos, quando o ângulo entre  $y$  e  $C(X)$  é zero significa que  $y \in C(X)$  e assim  $y$  é perfeitamente ajustado por  $P_X y = y$ ; por outro lado um ângulo reto significa que  $y$  é perpendicular a  $C(X)$  e a aproximação trivial e  $X\hat{\beta} = \emptyset$  e neste caso a aproximação é sem utilidade.

### 2.3 - ESTIMABILIDADE

Quais combinações lineares dos parâmetros  $\beta, \lambda^t \beta$ , são determináveis através de combinações lineares dos dados?

Para responder esta questão, defina-se

DEFINIÇÃO 3.1 - A função linear paramétrica  $\lambda^t \beta$  onde  $\lambda$  é um vetor de  $R^p$  é linearmente estimável se, e somente se, existe um vetor  $a \in R^n$  tal que

$$E(a^t y) = \lambda^t \beta \text{ para todo } \beta \in R^p \quad (2.18)$$

Assim, dizemos que  $\lambda^t \beta$  é linearmente estimável se existir um vetor  $a \in R^n$  tal que a esperança de  $a^t y$  é igual a  $\lambda^t \beta$  independente do valor do parâmetro  $\beta$ .

Se tal uma função não existir então  $\lambda^t \beta$  é dita ser não estimável.

Supondo que no modelo linear  $y = X \beta + e$  e dado por (2.1) temos  $E(e) = \emptyset$  (ou seja, a média dos erros é nula) então,

PROPOSIÇÃO 3.1 -  $\lambda^t \beta$  é linearmente estimável se, e somente se  $\lambda^t = a^t X$  para algum vetor  $a \in R^n$ . (2.19)

PROVA - Supondo  $\lambda^t \beta$  uma função linear linearmente estimável então por (2.18) existe  $a \in R^n$  tal que

$$E(a^t y) = \lambda^t \beta \text{ para todo } \beta \in R^p$$

mas

$$E(a^t y) = E(a^t (X \beta + e)) =$$

$$= E(a^t X \beta + a^t e) = a^t X \beta + a^t E(e) = a^t X \beta = \lambda^t \beta$$

para todo  $\beta \in R^p \leftrightarrow a^t X = \lambda^t$

Formas equivalentes de enunciarmos esta proposição são:

COROLARIO 3.1 -  $\lambda^t \beta$  é linearmente estimável se, e somente se  
 $\lambda \in C(X^t)$  (2.20)

COROLARIO 3.2 -  $\lambda^t \beta$  é linearmente estimável se, e somente se ,  
posto (X) = posto (X<sup>t</sup>:λ) (2.21)

COROLARIO 3.3 - O número de funções paramétricas linearmente es  
timáveis e independentes é igual ao posto de X (2.22)

PROVA - Imediata lembrando que qualquer base para  $C(X^t)$  consisis  
te exatamente de posto (X) vetores linearmente independentes.

COROLARIO 3.4 - Qualquer função linear de funções paramétricas  
linearmente estimáveis é estimável. (2.23)

PROVA - Supondo que  $\lambda_i^t \beta$ ,  $i = 1, \dots, m$ , sejam funções paramê-  
tricas linearmente estimáveis

e

$$\lambda^t \beta = \sum_{i=1}^m b_i (\lambda_i^t \beta) \text{ com } b_i \in R, i=1, \dots, m \text{ te}$$

mos, como  $\lambda_i^t \beta$  é linearmente estimável  $\rightarrow$  por (2.20)  $\lambda_i \in C(X^t)$   
para todo  $i=1, \dots, m$  mas

$$\lambda_i \in C(X^t) \rightarrow \sum_{i=1}^m b_i \lambda_i \in C(X^t)$$

para todo  $b_i \in R, i=1, \dots, m$

assim como

$$\left( \sum_{i=1}^m b_i \lambda_i \right)^t \beta = \left( \sum_{i=1}^m b_i \lambda_i^t \right) \beta =$$

$$= \sum_{i=1}^m b_i (\lambda_i^t \beta) = \lambda^t \beta \text{ para todo } \beta \in \mathbb{R}^p$$

onde

$$\sum_{i=1}^m b_i \lambda_i \in C(X^t) \text{ então, por (2.20) temos que}$$

$$\lambda^t \beta = \sum_{i=1}^m b_i (\lambda_i^t \beta) \text{ é}$$

é uma função paramétrica linearmente estimável.

COROLÁRIO 3.5 - Se  $\text{posto}(X) = p$  então,  $\beta$  é estimável e portanto cada  $\beta_i$  é também estimável (2.24)

PROVA - Como, por (1.33) temos  $\text{posto}(X) = \text{posto}(X^t X) = p$  onde  $X^t X$  é uma matriz  $p \times p$ , então,

$$\beta = (X^t X)^{-1} (X^t X) \beta = ((X^t X)^{-1} X^t) X \beta$$

e portanto, existe uma matriz

$$A_{n \times p} = X(X^t X)^{-1}$$

tal que  $E(A^t y) = A^t X \beta = X \beta$

ou seja  $\beta$  é linearmente estimável e ainda, como, para cada  $j=1, \dots, p$

$$\beta_j = (\delta_{ij}) \beta \quad \text{onde} \quad \delta_{ij} = \begin{cases} 1 & \text{se } i=j \\ 0 & \text{se } i \neq j \end{cases} \quad j=1, \dots, p$$

então por (2.23) temos que



$\beta_j$  é linearmente estimável

PROPOSIÇÃO 3.2 - A função  $\lambda^t \beta$ ,  $\lambda \in \mathbb{R}^p$ , é linearmente estimável  $\leftrightarrow$  existe um único

$X \rho \in C(X)$  tal que

$$X^t X \rho = \lambda \quad \text{é consistente} \quad (2.25)$$

PROVA - Supondo  $\lambda^t \beta$  uma função paramétrica linearmente estimável então, por (2.19) existe um vetor  $a \in \mathbb{R}^n$  tal que

$$\lambda^t = a^t X \quad \text{ou}$$

$$\lambda = X^t a \quad \in C(X^t)$$

mas como por (1.35) temos

$$C(X^t) = C(X^t X)$$

então

$$\lambda = X^t a \in C(X^t) \rightarrow \exists \rho \in \mathbb{R}^p$$

tal que

$$\lambda = X^t a = X^t X \rho \quad (2.26)$$

Observando que o conjunto de equações (2.26) é um conjunto de equações cuja estrutura coincide com o das equações normais que é sempre consistente e ainda  $X \rho$  é o único vetor em

$C(X)$  tal que

$$X^t X \rho = X^t a \quad (\text{ver 2.14})$$

concluimos então, que, se  $\lambda^t \beta$  é estimável então existe um único  $X\rho \in C(X)$  tal que  $X^t X \rho = \lambda$  é consistente

Inversamente

Supondo que existe um único  $b = X\rho \in C(X)$  tal que  $X^t X\rho = X^t b = \lambda$  é consistente então, como

$X^t b = \lambda$  onde  $b \in C(X) \in \mathbb{R}^n$  temos por (2.19) que  $\lambda^t \beta$  é estimável.

PROPOSIÇÃO 3.3 - A aproximação de mínimos quadrados para  $\lambda^t \beta$  onde,  $\lambda^t \beta$  é uma função paramétrica linearmente estimável, é dada por

$$\widehat{\lambda^t \beta} = \lambda^t \hat{\beta} = \rho^t X^t y \quad \text{com}$$

$$X^t X \rho = \lambda \quad e$$

$\widehat{\lambda^t \beta}$  é não tendencioso para  $\lambda^t \beta$ .

PROVA - Supondo  $\lambda^t \beta$  uma função paramétrica linearmente estimável então, por (2.26) existe um único  $X\rho \in C(X)$  tal que

$$X^t X\rho = \lambda \quad \text{é consistente}$$

assim, se  $\hat{\beta}$  é tal que  $X^t X \hat{\beta} = X^t y$ .

então

$$X^t X \rho = \lambda \rightarrow \lambda^t \hat{\beta} = \rho^t X^t X \hat{\beta} = \rho^t X^t y$$

e

$$\widehat{\lambda^t \beta} = \widehat{\rho^t X^t X \beta} = \rho^t X^t y$$

e ainda

$$\begin{aligned} E(\lambda^t \hat{\beta}) &= E(\widehat{\lambda^t \beta}) = E(\rho^t X^t y) = \rho^t X^t E(y) = \\ &= \rho^t X^t X \beta = \lambda^t \beta \quad \text{para} \\ &\text{todo } \beta \in R^p. \end{aligned}$$

PROPOSIÇÃO 3.4 - Para todo vetor  $c \in R^n$  temos que

$$E(c^t y) = 0 \quad (\forall \beta \in R^p) \leftrightarrow c \in C(X)^\perp \quad (2.27)$$

PROVA -  $E(c^t y) = 0 \quad (\forall \beta \in R^p) \leftrightarrow c^t X \beta = 0 \leftrightarrow c^t X = \emptyset$  para todo  $\beta \in R^p \leftrightarrow$

$$X^t c = \emptyset \leftrightarrow \text{por (1.29) } c \in C(X)^\perp$$

Assim, observando os resultados das proposições 3.2 e 3.4 segue que a classe total de estimadores não tendencioso para u ma função paramétrica linearmente estimável,  $\lambda^t \beta$ ,  $\lambda \in R^p$ , é da da por

$$\begin{aligned} \rho^t X^t y + c^t y \quad \text{onde } X\rho \text{ é o único vetor em } C(X) \text{ tal} \\ \text{que } X^t X \rho = \lambda \text{ é consistente e } c \in C(X)^\perp \end{aligned} \quad (2.28)$$

2.4 - Completando agora a estrutura do modelo  $y = X\beta + e$  impondo as condições de Gauss-Markoff:-

$X, \beta$  fixo onde

$X$  é uma matriz  $n \times p$  de constantes conhecidas

$e$  é um vetor  $p \times 1$  desconhecido tal que

$$E(e) = \emptyset$$

e

$$E(e e^t) = \sigma^2 I_n > 0$$

(assim os  $e_i, i=1, \dots, n$ , são não correlacionados e tem a mesma variância  $\sigma^2$ )

Pergunta-se qual é o "melhor" estimador da função paramétrica linearmente estimável  $\lambda^t \beta, \lambda \in R^p$ , na classe dos estimadores não tendenciosos para  $\lambda^t \beta$ ?

Para responder esta questão, defina-se

DEFINIÇÃO 4.1 - (BLUE)

Um estimador linear não tendencioso  $a^t y$  é dito ser o melhor estimador não tendencioso (BLUE) da sua esperança se, e somente se, sua variância não excede a variância de qualquer outro estimador não tendencioso da esperança de  $a^t y$ .

Considerando, então, a função linear

$$\rho^t X^t y + c^t y \text{ com } c \in C(X)^\perp \text{ e } X^t X \rho = \lambda \text{ consistente}$$

temos

$$a) E(\rho^t X^t y + c^t y) = E(\rho^t X^t y) + E(c^t y) =$$

$$= \rho^t X^t X \beta + c^t X \beta = \lambda^t \beta \quad \text{para todo } \beta \in \mathbb{R}^p \quad (2.29)$$

$$b) \text{ cov}(\rho^t X^t y, c^t y) = \rho^t X^t (I_n \sigma^2) c = \sigma^2 \rho^t X^t c = 0 \quad (2.30)$$

$$c) \text{ var}(\rho^t X^t y + c^t y) = \text{var}(\rho^t X^t y) + \text{var}(c^t y)$$

e portanto  $\text{var}(\rho^t X^t y + c^t y) \geq \text{var}(\rho^t X^t y)$

onde

$$\text{var}(\rho^t X^t y + c^t y) = \text{var}(\rho^t X^t y) \quad \leftrightarrow$$

$$\text{var}(c^t y) = \sigma^2 c^t c = 0 \quad \leftrightarrow \quad c^t c = 0 \quad \leftrightarrow c = 0$$

e neste caso, temos que

$$\rho^t X^t y + c^t y = \rho^t X^t y \quad (2.31)$$

assim por (2.29), (2.30) e (2.31) concluímos que o BLUE de  $\lambda^t \beta$  é dado por um único vetor da forma  $\rho^t X^t y$  onde  $\rho$  é tal que  $X^t X \rho = \lambda$  é consistente (2.32)

Como, pela proposição 3.3,  $\rho^t X^t y = \lambda^t \hat{\beta}$  onde  $\hat{\beta}$  é qualquer solução das equações normais concluí-se que

**TEOREMA 4.1 - TEOREMA DE GAUSS-MARKOFF** - O BLUE de uma função paramétrica linearmente estimável,  $\lambda^t \beta$ ,  $\lambda \in \mathbb{R}^p$ , é o único vetor  $\lambda^t \hat{\beta} = \widehat{\lambda^t \beta}$  onde  $\hat{\beta}$  é qualquer vetor que minimiza  $Q(\beta)$ , isto é,  $\hat{\beta}$  é qualquer solução das equações normais

$$X^t X \beta = X^t y \quad (2.33)$$

**COROLÁRIO 4.1** - O BLUE de uma combinação linear de funções estimáveis é igual a mesma combinação linear dos BLUE's das funções

estimáveis , (2.34)

PROVA - Trivial

COROLARIO 4.2 - O BLUE de  $X\beta$  é  $X\hat{\beta}$  onde  $\hat{\beta}$  é tal que  $X^t X \hat{\beta} = X^t y$  (2.35)

PROVA - Sendo 
$$X\beta = \begin{pmatrix} x_{(1)} \\ \cdot \\ \cdot \\ \cdot \\ x_{(n)} \end{pmatrix} \beta = \begin{pmatrix} x_{(1)}\beta \\ \cdot \\ \cdot \\ \cdot \\ x_{(n)}\beta \end{pmatrix} = (x_{(i)}\beta)$$

onde  $x_{(i)} = (x_{i1} : \dots : x_{ip})$ ,  $i=1, \dots, n$ , é a  $i$ -ésima linha de  $X$  temos

como  $x_{(i)} \in C(X^t)$  por (2.20)

$x_{(i)}\beta$  é linearmente estimável para todo  $i=1, \dots, n$

e, por (2.33) o

BLUE de  $x_{(i)}\beta$ ,  $i=1, \dots, n$ , é igual a  $\widehat{x_{(i)}\beta} = x_{(i)}\hat{\beta}$

onde

$\hat{\beta}$  é tal que  $X^t X \hat{\beta} = X^t y$

então

O BLUE de  $X\beta = (x_{(i)}\beta)$  é dado por

$(x_{(i)}\hat{\beta}) = (x_{(i)})\hat{\beta} = X\hat{\beta}$  onde  $\hat{\beta}$  é tal que

$X^t X \hat{\beta} = X^t y$

Como, por (2.16) para todo  $\hat{\beta}$  tal que  $X^t X \hat{\beta} = X^t y \rightarrow X \hat{\beta} = P_X y$  onde  $P_X$  é a matriz do operador projeção ortogonal de  $R^n$  sobre  $C(X)$  então, uma forma equivalente de enunciarmos o corolário 4.2 é

COROLÁRIO 4.3 - O BLUE de  $X\beta$  é igual a projeção ortogonal de  $y$  em  $C(X)$  ou seja

$$X \hat{\beta} = P_X y = \hat{y}, \text{ que é o vetor ajustado}$$

e onde,  $P_X$  é a matriz do operador projeção ortogonal de  $R^n$  sobre  $C(X)$ . (2.36)

COROLARIO 4.4 - Se  $\lambda^t \beta$  e  $\mu^t \beta$  são funções paramétricas linearmente estimáveis então, a covariância de seus BLUE's é dada por

$$\text{cov} (\mu^t \hat{\beta}, \lambda^t \hat{\beta}) = \sigma^2 \rho_1^t \lambda = \sigma^2 \mu^t \rho_2 \quad \text{onde}$$

$\rho_1$  e  $\rho_2$  são tais que

$$X^t X \rho_1 = \mu$$

$$X^t X \rho_2 = \lambda \quad (2.37)$$

e

$$\text{cov} (\mu^t \hat{\beta}, \lambda^t \hat{\beta}) = 0 \quad \leftrightarrow$$

$(X \rho_1)^t (X \rho_2) = 0$ , ou seja, os projetados do vetor  $y$  sobre  $C(X)$  para as combinações lineares  $\lambda^t \beta$  e  $\mu^t \beta$  são ortogonais. (2.38)

PROVA - Supondo  $\lambda^t \beta$  e  $\mu^t \beta$  funções paramétricas linearmente estimáveis temos por (2.32) e (2.33) que o BLUE de  $\lambda^t \beta$  e  $\mu^t \beta$  são dados respectivamente por

$$\rho_2^t X^t y = \lambda^t \hat{\beta} \quad e$$

$$\rho_1^t X^t y = \mu^t \hat{\beta}$$

para todo  $\hat{\beta}$  tal que  $X^t X \hat{\beta} = X^t y$

e para  $\rho_1$  e  $\rho_2 \in R^p$  tal que

$$X^t X \rho_1 = \mu \text{ é consistente}$$

e

$$X^t X \rho_2 = \lambda \text{ é consistente}$$

e portanto,

$$\text{cov} (\mu^t \hat{\beta}, \lambda^t \hat{\beta}) = \text{cov} (\rho_1^t X^t y, \rho_2^t X^t y) =$$

$$= \rho_1^t X^t (\sigma^2 I_n) X \rho_2 = \sigma^2 \rho_1^t X^t X \rho_2 =$$

$$= \sigma^2 \mu^t \rho_2 = \sigma^2 \rho_1^t \lambda$$

e

$$\text{cov} (\mu^t \hat{\beta}, \lambda^t \beta) = 0 \quad \leftrightarrow$$

$$\sigma^2 \rho_1^t X^t X \rho_2 = 0 \leftrightarrow (X \rho_1)^t (X \rho_2) = \rho_1^t X^t X \rho_2 = 0$$

assim como

$$X \hat{\beta} = P_X y \text{ temos}$$

$$\mu^t \hat{\beta} = \rho_1^t X^t X \hat{\beta} = \rho_1^t X^t X \hat{\beta} = \rho_1^t X^t (P_X y) =$$

$$= (X \rho_1)^t (P_X y)$$



e

$$\lambda^t \hat{\beta} = \rho_2^t X^t X \hat{\beta} = \rho_2^t X^t (P_X y) = (X \rho_2)^t (P_X y)$$

onde  $P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)$

então

$\text{cov}(\mu^t \hat{\beta}, \lambda^t \hat{\beta}) = 0 \leftrightarrow$  os projetados de  $y$  sobre  $C(X)$  para as combinações lineares  $\lambda^t \beta$  e  $\mu^t \beta$  são ortogonais.

000o000

### CAPÍTULO 3

#### CARACTERIZAÇÃO DE BLUE'S NO MODELO DE GAUSS - MARKOFF GENERALIZADO (GMG)

Considerando o modelo linear

$$y = X \beta + e$$

onde

$X$  é uma matriz  $n \times p$  conhecida de posto  $r \leq p$

$\beta$  é um vetor  $p \times 1$  de parâmetros

$e$  é um vetor  $n \times 1$  de perturbação ou erro

então, se

$$E(e) = \emptyset$$

e

$$E(e e^t) = \sigma^2 V$$

onde

$\sigma^2 \in \mathbb{R}$  é não conhecido

$V$  é uma matriz  $n \times n$  conhecida, simétrica e positiva de posto  $s \leq n$

(3.1)

temos, que o modelo acima denomina-se modelo de Gauss-Markoff Geral (G.M.F.).

Simbolicamente temos o modelo de G.M.G. dado por  
 $y, X\beta, \sigma^2 V)$

### 3.1 - CONSIDERAÇÕES A RESPEITO DO MODELO DE G.M.G.

Considerando o modelo de G.M.G.  $(y, X\beta, \sigma^2 V)$  temos

$$E(y) = X\beta \quad e$$

$$D(y) = E[(y - X\beta)(y - X\beta)^t] = \sigma^2 V$$

$(D(y))$  = matriz de variância e covariância de  $y$

Como  $V$  é singular temos então que as variáveis  $y$  são linearmente dependentes e portanto, deverá ocorrer certas restrições lineares sobre a variável dependente  $y$ , o qual terão que ser observadas certificando-se então a consistência (ou admissibilidade) do modelo.

Uma tal restrição é dada por

LEMA 1.1 - Se  $(y, X\beta, \sigma^2 V)$  é um modelo de G.M.G. então

$$y \in C(V:X) \text{ com probabilidade } 1 \quad (3.2)$$

PROVA - Considerando o modelo linear  $y = X\beta + e$  dado em (3.1) temos, para todo vetor  $c_{n \times 1} \in C(V)^\perp \rightarrow$

$$c^t V = V c = \emptyset$$

assim

$$E(c^t e) = \emptyset$$

e

$$\text{var}(c^t e) = \sigma^2 c^t V c = \emptyset. \quad (\sigma^2 > 0)$$

então  $c^t e = 0$  com probabilidade 1 para todo vetor  $c \in C(V)^\perp$  ou seja, o vetor  $e \in C(V)$  com probabilidade 1.

Logo, como  $y = X\beta + e$  então  $y \in C(V:X)$  com probabilidade 1.

O lema 3.1 especifica então que  $y \in C(V:X)$  que é a única afirmação que pode ser feita quando  $y$  é não observado. Porém, quando temos uma observação de  $y$ , então na sua estrutura teremos que

$$y = X\beta + P_V e$$

onde

$P_V$  é a matriz do operador projeção ortogonal sobre  $C(V)$  e portanto o modelo é admissível se  $y$  e  $\beta$  são tais que

$$y - X\beta \in C(V) \quad (3.3)$$

o qual é automaticamente satisfeito quando  $V$  é não singular.

Observando que se  $Z$  é uma matriz  $n \times n-r$  ( $r = \text{posto } X$ ) tal que  $C(Z) = C(X)^\perp$  temos

$$C(V:X) = C(VZ:X) = C(VZ) \oplus C(X) \quad (3.4)$$

pois, para todo  $\lambda \in R^n$  tal que  $\lambda \in C(V:X)^\perp$

$$\rightarrow \lambda^t V = 0 \text{ e } \lambda^t X = 0 \rightarrow \lambda^t VZ = 0 \text{ e } \lambda^t X = 0$$

$$\rightarrow \lambda \in C(VZ:X)^\perp$$

e, para todo vetor  $\lambda \in R^n$  tal que  $\lambda \in (VZ) \cap C(X) \rightarrow$  existe  $\lambda_1 \in R^p$  e  $\lambda_2 \in R^{n-r}$  tal que

$$\lambda = X \lambda_1 \quad \text{e} \quad \lambda = VZ \lambda_2 \quad \leftrightarrow \quad \left| \begin{array}{l} Z^t \lambda = Z^t X \lambda_1 = \emptyset \\ e \\ \lambda = VZ \lambda_2 \end{array} \right.$$

$$\rightarrow \lambda_2^t Z^t \lambda = \lambda_2^t Z^t V Z \lambda_2 = \emptyset \quad \leftrightarrow \quad C^t Z \lambda_2 = \emptyset$$

onde  $C$  é uma matriz  $n \times s$  tal que  $V = CC^t$  ( $V$ : é positiva)

$$\leftrightarrow \lambda = V Z \lambda_2 = \emptyset$$

assim, temos  $C(VZ:X) = C(VZ) \oplus C(X) \subset C(V:X)$  e

$$\dim C(VZ:X) = \dim C(VZ) + \dim C(X) = \text{por (1.33)}$$

$$\dim C(V) - \dim(C(V) \cap C(Z)^{\perp}) + \dim(C(X)) =$$

$$= \dim C(V) + \dim(C(X)) - \dim(C(V) \cap C(X)) =$$

$$= \dim C(V:X)$$

se, e somente se,

$$C(V:X) = C(VZ) \oplus C(X)$$

Considerando, também que  $K$  é uma matriz  $n \times n-s$ , ( $s = \text{posto}(V)$ ) tal que as colunas de  $K$  formam uma base ortonormal para

$$C(V)^{\perp} \tag{3.5}$$

então, temos que

$$C(V:X) = C(V) \overset{1}{\otimes} C(K K^t X) \quad (3.6)$$

pois,

Considerando  $P_V$  a matriz do operador projeção ortogonal sobre  $C(V)$  e

$P_{(V:X)}$  a matriz do operador projeção ortogonal sobre  $C(V:X)$  temos

por (1.55)  $I - P_V$  é a matriz do operador projeção ortogonal sobre  $C(V)^\perp$  e portanto,

$$\text{por (1.59) } I - P_V = K K^t$$

assim, como por (1.62)

$$C(V:X) = C(P_V) \overset{1}{\otimes} C(P_{(V:X)} - P_V)$$

onde, sendo  $(P_{(V:X)} - P_V)(V:X) =$

$$= P_{(V:X)}(V:X) - P_V(V:X) =$$

$$= (V:X) - (P_V(V) : P_V X) = (V:X) - (V : P_V X) =$$

$$= (\emptyset : X - P_V X) = (\emptyset : (I - P_V)(X)) =$$

$$= (\emptyset : K K^t X) \text{ então.}$$

$$C(P_{(V:X)} - P_V) = C(K K^t X)$$

e portanto

$$C(V:X) = C(V) \overset{1}{\otimes} C(K K^t X)$$

Assim por (3.4) e (3.6) concluimos que

LEMA 1.2 - Se  $(y, X\beta, \sigma^2V)$  é um modelo de G.M.G. e  $Z$  é uma matriz  $n \times n-r$  ( $r = \text{posto } X$ ) tal que  $C(Z) = C(X)^\perp$  e  $K$  é uma matriz  $n \times n-s$  ( $s = \text{posto } V$ ) tal que as colunas de  $K$  formam uma base ortonormal para  $C(V)^\perp$  então

$$y \in C(X) \oplus C(VZ) = C(K K^t X) \oplus C(V)$$

com probabilidade 1

(3.7)

PROVA - use (3.2), (3.4) e (3.6):

Vejamos o que ocorre com o modelo de G.M.G. se o transformarmos pela matriz  $K^t$  onde  $K$  é dada por (3.5).

LEMA 1.3 - Se  $(y, X\beta, \sigma^2V)$  é um modelo de G.M.G. e  $K$  é uma matriz como especificada em (3.5) então

$$K^t y = d \text{ constante com probabilidade 1} \quad (3.8)$$

e

$$K^t X\beta = d \text{ para todo } \beta \in R^p \text{ se}$$

$$C(K) \neq C(X)^\perp \quad (3.9)$$

PROVA - Como  $K$  é uma matriz tal que as colunas de  $K$  formam uma base ortonormal para  $C(V)^\perp$  então temos que

$$VK = K^t V = \emptyset \quad (3.10)$$

assim, como

$$E(K^t y) = K^t X \beta \text{ para todo } \beta \in R^p$$

e

$$\text{var}(K^t y) = K^t V K \sigma^2 = \emptyset \text{ (por 3.10)}$$

então

$$K^t y = K^t X \beta = d \text{ constante com probabilidade 1.}$$

Note que se  $C(K) \subset C(X)^\perp$  então  $K^t X = \emptyset$  e portanto não haveria restrição sobre o parâmetro  $\beta$ .

Assim, o resultado (3.8) e (3.9) mostram que quando  $V$  é singular existe uma restrição na variável aleatória  $y$  e no vetor dos parâmetros  $\beta$ .

Contudo, elas são conhecidas apenas quando temos uma observação de  $y$ .

LEMA 1.4 - Para todo vetor  $q \in R^{n-s}$  tal que

$$q^t d = 0 \quad \text{e} \quad Kq \neq \emptyset$$

onde

$K$  é uma matriz dada por (3.5) e  $d$  satisfaz (3.8) e (3.9)

então

$$q^t K^t y = 0 \text{ com probabilidade 1} \quad (3.10)$$

e

$$q^t K^t X \beta = 0 \quad (3.11)$$



PROVA - use (3.8) e (3.9).

Como  $q^t K^t y = 0$  com probabilidade 1

$$y \in C(Kq)^1$$

então, o lema 1.4 mostra que de fato  $y$  está ligado a um determinado sub-espço e também, como as únicas restrições sobre o parâmetro  $\beta$  são dadas através de (3.9) segue-se que as únicas funções de  $\beta$  que são iguais a zero são aquelas cujas expressões são dadas por (3.11).

Assim, se  $\lambda^t \beta = 0$  para todo  $\beta \in R^P$  tal que

$$K^t X \beta = d \quad (\text{constante})$$

então  $\lambda^t = q^t K^t X$  para algum  $q \in R^{n-s}$  tal que  $q^t d = 0$  e

$$Kq \neq \emptyset \tag{3.12}$$

Observar que

$$\text{posto}(Kq) = \begin{cases} \text{posto}(K) - 1 & \text{se } d \neq \emptyset \\ \text{ou} \\ \text{posto}(K) & \text{se } d = \emptyset \end{cases}$$

$$\text{pois } \text{posto}(Kq) = \text{posto}(K) - \dim(C(K^t) \cap C(K^t y))$$

$$= \text{posto}(K) - \dim(C(K^t y))$$

Como a singularidade de  $V$  induz restrições no vetor de parâmetros  $\beta$ , como fica então o problema de estimabilidade?

Zyskind e Martin (1969) provam que

TEOREMA 1.1 - Se  $(y, X\beta, \sigma^2V)$  é um modelo de G.M.G. então, toda função linear dos parâmetros,  $\lambda^t \beta$ , ( $\lambda \in R^p$ ) é linearmente estimável se, e somente se,  $\lambda \in C(X^t)$

PROVA - Se,  $\lambda \in R^p$  é tal que  $\lambda \in C(X^t)$  então, existe um vetor  $a \in R^n$  tal que  $\lambda^t = a^t X$ . Assim,  $E(a^t y) = a^t X \beta = \lambda^t \beta \rightarrow$

$\lambda^t \beta$  é estimável

inversamente,

Supondo  $\lambda^t \beta$  uma função paramétrica linearmente estimável então, existe um vetor  $a \in R^n$  tal que  $E(a^t y) = \lambda^t \beta$  para todo  $\beta \in R^p$ , tal que

$$K^t X \beta = d$$

assim, como

$$E(a^t y) = a^t X \beta = \lambda^t \beta \leftrightarrow (a^t X - \lambda^t) \beta = 0$$

por (3.12) temos  $a^t X - \lambda^t = q^t K^t$  para algum  $q \in R^{n-s}$  onde

$$q^t d = 0 \quad e \quad Kq \neq \emptyset \quad (3.13)$$

assim (3.13)  $\rightarrow a^t X - \lambda^t = q^t K^t X \leftrightarrow$

$$\lambda^t = (a^t - q^t K^t) X \leftrightarrow \lambda \in C(X^t)$$

COROLÁRIO 1.1 - Se  $E(a^t y) = \lambda^t \beta$  para todo vetor  $\beta \in R^p$  tal que  $K^t X \beta = d$  (constante), então,  $X^t a - \lambda \in C(X^t K)$ .

PROVA - imediata usando (3.13)

Deste modo, observamos que a condição  $a^t X = \lambda^t$  é apenas necessária para que  $E(a^t y) = \lambda^t \beta$  que é bastante diferente da condição usual que estabelece que se  $a^t y$  é não tendencioso para  $\lambda^t \beta \rightarrow X^t a = \lambda$ ; condição válida apenas quando  $\beta$  é não restrito.

Tal afirmação foi usada erroneamente por Rao (1971).

A falsidade desta afirmação foi verificada por Zyskind(1967) e no trabalho de Zyskind e Martin (1969) como citado anteriormente.

Uma nota interessante no modelo quando  $V$  é singular é

PROPRIEDADE 1.1 - Se  $E(a^t y) = \lambda^t \beta$  para todo  $\beta \in R^p$  tal que  $K^t X \beta = d$  (constante), então, existe  $b \in R^n$

$$b = a - Kq \quad (K \text{ e } q \text{ dados no lema 1.4})$$

tal que

$$b^t X = \lambda^t \quad (\text{e portanto } E(b^t y) = \lambda^t \beta) \quad (3.14)$$

e

$$a^t y = b^t y \quad \text{com probabilidade 1} \quad (3.15)$$

PROVA - Supondo  $b = a - Kq$  então

$$b^t X = a^t X - q^t K^t X$$

$$b^t X - \lambda^t = a^t X - q^t K^t X - \lambda^t = (a^t - q^t K^t) X - \lambda^t = 0 \quad \text{por (3.13) e}$$

portanto,  $b^t X = \lambda^t \rightarrow b^t X\beta = \lambda^t \beta$  para todo  $\beta \in R^P$

$$\rightarrow E(b^t y) = \lambda^t \beta$$

assim,  $E(a^t y - b^t y) = E(a^t y) - E(b^t y) = 0$

e

$$\text{var}(a^t y - b^t y) = \text{var}((a^t - b^t)y) =$$

$$= \text{var}(q^t K^t y) = 0$$

então,  $a^t y = b^t y$  com probabilidade 1.

Assim, quando  $V$  é singular temos que uma particular função paramétrica linearmente estimável,  $\lambda^t \beta$ , pode admitir distintos BLUE's como função das observações embora, o valor numérico de todos êles sejam iguais.

Dito de outra forma, com  $V$  singular podemos ter um conjunto de funções lineares das observações identicamente nulas que, quando adicionadas ou subtraídas do BLUE de  $\lambda^t \beta$  o novo funcional linear também será BLUE de  $\lambda^t \beta$ .

Portanto, para acharmos um BLUE da função paramétrica linearmente estimável,  $\lambda^t \beta$ , é suficiente determinarmos um vetor  $b \in R^n$  tal que

$$b^t X = \lambda^t$$

e

$$b^t V b \text{ seja mínimo}$$

embora, esta condição não seja uma condição necessária.

TEOREMA 1.2 - Se  $\lambda \in R^P$  é tal que  $\lambda^t \beta$  é uma função paramétrica linearmente estimável no modelo de G.M.G.  $(y, X\beta, \sigma^2 V)$ , então,

existem vetores  $b \in R^n$  e  $m \in R^p$  tal que

$$V b + X m = \emptyset \quad (3.16)$$

e

$$X^t b = \lambda \quad (3.17)$$

e neste caso  $b^t y$  é um BLUE de  $\lambda^t \beta$ .

PROVA - Supondo  $\lambda^t \beta$  uma função paramétrica linearmente estimável, então, pelo teorema 1.1 existe um vetor  $b \in R^n$  tal que  $X^t b = \lambda$ . Mas, como  $X^t b = \lambda \rightarrow b^t y$  é um estimador não tendencioso de  $\lambda^t \beta$  então, utilizando o processo de Multiplicador de Lagrange para determinar

$$b \in R^n \text{ tal que}$$

$$b^t V b \text{ é mínimo}$$

sujeito à condição de

$$X^t b = \lambda^t$$

temos,

O Lagrangiano  $L$  com um vetor de multiplicador  $2m \in R^p$  é

$$L = b^t V b + 2(b^t X - \lambda^t)m = \\ = \sum_{i=1}^n \sum_{j=1}^n b_i b_j \sigma_{ij} + 2 \sum_{i=1}^n \sum_{k=1}^p b_i x_{ik} m_k - 2 \sum_{k=1}^p \lambda_k m_k$$

onde  $\sigma_{ij}$  pertence a  $i$ -ésima linha e  $j$ -ésima coluna de  $V$ .

assim, sendo

$$\frac{\partial L}{\partial b_u} = 0 \quad \text{para } u=1, \dots, n$$

dado por

$$2 \sum_{k=1}^n \sigma_{uj} b_j + 2 \sum_{k=1}^p x u_k m_k = 0 \quad \text{para } u=1, \dots, n$$

em forma matricial temos

$$V b + X m = \emptyset$$

Considerando o sistema de equações

$$\left| \begin{array}{l} Vb + Xm = \emptyset \\ X^t b = \lambda \end{array} \right.$$

temos que (3.16) e (3.17) satisfazem,

1 - O sistema de equações é consistente pois, para todo vetor  $v_1$  e  $v_2 \in \mathbb{R}^n$  tal que

$$(v_1^t : v_2^t) \begin{pmatrix} V & X \\ X^t & \emptyset \end{pmatrix} = \emptyset \quad \rightarrow$$

$$\rightarrow \left| \begin{array}{l} v_1^t V + v_2^t X^t = \emptyset \\ e \end{array} \right. \quad (3.18)$$

$$\left| \begin{array}{l} v_1^t X \\ \phantom{v_1^t X} \end{array} \right. = \emptyset \quad (3.19)$$

multiplicando (3.18) por  $v_1$  à esquerda

$$\rightarrow \left| \begin{array}{l} v_1^t V v_1 + v_2^t X^t v_1 = \emptyset \\ e \\ v_1^t X \phantom{v_1} = \emptyset \end{array} \right.$$

$$\rightarrow v_1^t V v_1 = \emptyset \quad (3.20)$$

mas, como  $V$  é positiva, então existe uma matriz  $C_{n \times s}$  tal que  $V=C^t C$  assim, (3.20) fica

$$v_1^t V v_1 = \emptyset \leftrightarrow (C v_1)^t (C v_1) = \emptyset \leftrightarrow C v_1 = \emptyset$$

e portanto  $V v_1 = \emptyset$  ou  $v_1^t V = \emptyset$  (3.21)

Substituindo (3.21) em (3.18) temos

$$v_2^t X^t = \emptyset \quad (3.22)$$

como, por hipótese  $X^t b = \lambda$  é consistente então, por (3.22)

$$v_2^t X^t = \emptyset \rightarrow v_2^t \lambda = 0$$

Logo

$$(v_1^t : v_2^t) \begin{pmatrix} V & X \\ X^t & \emptyset \end{pmatrix} = \emptyset \rightarrow (v_1^t : v_2^t) \begin{pmatrix} \emptyset \\ \lambda \end{pmatrix} = \emptyset$$

assim, existe  $b \in R^n$  e  $m \in R^p$  tal que satisfazem (3.16) e (3.17) e neste caso, como  $b$  é tal que

$$E(b^t y) = \lambda^t \beta$$

então  $b^t y$  é um BLUE de  $\lambda^t \beta$  pois

## 2 - Invariância das Soluções

Supondo  $b_1$  e  $b_2 \in R^n$  e

$$m_1 \text{ e } m_2 \in \mathbb{R}^p$$

tais que satisfazem

$$\begin{cases} V b_1 + X m_1 = \emptyset \\ X^t b_1 = \lambda \end{cases}$$

e

$$\begin{cases} V b_2 + X m_2 = \emptyset \\ X^t b_2 = \lambda \end{cases}$$

$$\text{então, } V(b_1 - b_2) + X(m_1 - m_2) = \emptyset \quad (3.23)$$

$$\text{e } X^t(b_1 - b_2) = \emptyset \quad (3.24)$$

multiplicando (3.23) à esquerda por  $(b_1^t - b_2^t)$  temos

$$(b_1^t - b_2^t)V(b_1 - b_2) + (b_1^t - b_2^t)X(m_1 - m_2) = \emptyset \quad (3.25)$$

mas, como por (3.24)  $X^t(b_1 - b_2) = 0 \rightarrow$

$$\rightarrow (b_1^t - b_2^t) X (m_1 - m_2) = \emptyset \quad (3.26)$$

então, substituindo (3.26) em (3.25) temos

$$(b_1^t - b_2^t) V (b_1 - b_2) = \emptyset \rightarrow V(b_1 - b_2) = \emptyset$$

(usando o mesmo argumento  $V = CC^t$  anterior)

$$\text{Assim } V(b_1 - b_2) = \emptyset \rightarrow V b_1 = V b_2$$

e também por (3.23)



$$V(b_1 - b_2) = \emptyset \rightarrow X(m_1 - m_2) = \emptyset \rightarrow X m_1 = X m_2$$

claramente temos também que

$$b_1^t V b_1 = b_1^t V b_2 = b_2^t V b_1 = b_2^t V b_2 \quad (3.27)$$

### 3 - Minimização Global

Se  $b \in R^n$  satisfaz o sistema de equações (3.16) e (3.17) então, para todo  $\rho \in R^n$  tal que  $X^t(b + \rho) = \lambda$  temos

$$X^t \rho = \emptyset \quad (3.28)$$

e

$$\rho^t V b = -\rho^t X m \rightarrow \rho^t V b = 0 = b^t V \rho \quad (3.29)$$

e portanto

$$\text{cov}(b^t y, \rho^t y) = \sigma^2 b^t V \rho = 0 \quad (3.30)$$

assim,

$$\begin{aligned} \text{var}((b + \rho)^t y) &= \text{var}(b^t y + \rho^t y) = \\ &= \text{var}(b^t y) + 2\text{cov}(b^t y, \rho^t y) + \text{var}(\rho^t y) = \\ &= (\text{por (3.30)}) \text{var}(b^t y) + \text{var}(\rho^t y) \rightarrow \\ &\text{var}((b + \rho)^t y) \geq \text{var}(b^t y) \end{aligned}$$

e portanto  $b^t y$  é um BLUE de  $\lambda^t \beta$  onde

$$\text{var}((b + \rho)^t y) = \text{var}(b^t y) \leftrightarrow \text{var}(\rho^t y) = 0 \leftrightarrow$$

$$\rho^t V = 0 \leftrightarrow V\rho = \emptyset \quad (3.31)$$

assim, por (3.29) e (3.31) temos

$$(b+\rho)^t y \text{ é também um BLUE de } \lambda^t \beta \leftrightarrow$$

$$\rho \in C(X)^{\perp} \cap C(V)^{\perp} \quad (3.32)$$

Como por (3.28) e (3.30) temos que para todo  $b \in R^n$  satisfazendo (3.16) e (3.17) e para todo  $\rho \in R^n$  tal que  $X^t \rho = \emptyset$

$$E(\rho^t y) = \rho^t X \beta = 0 \text{ para todo } \beta \in R^p$$

e

$$\text{cov}(b^t y, \rho^t y) = 0$$

então, podemos concluir que,  $\rho$  não modifica a estimabilidade de  $\lambda^t \beta$  e não aumenta a informação que  $b^t y$  tem sobre  $\lambda^t \beta$ . Tal caso, não é o mesmo que veremos na seção 3.3 deste capítulo em que encontraremos uma forma de melhorar a informação sobre  $\lambda^t \beta$  através de vetores de  $C(X)^{\perp}$  usando o argumento apresentado por Rao(1967) denominado ajustamento por covariância.

Supondo  $b \in R^n$  satisfazendo (3.16) e (3.17) e

$$a \in R^n \text{ tal que } E(a^t y) = \lambda^t \beta$$

temos

$$E((a-b)^t y) = E(a^t y - b^t y) =$$

$$= E(a^t y) - E(b^t y) = 0$$

mas, como por (3.13)

$$E((a-b)^t y) = 0 \leftrightarrow (a-b)^t X = q^t K^t X$$

onde  $K$  é uma matriz tal que as suas colunas formam uma base ortogonal de  $C(V)^\perp$  e  $q$  é tal que  $Kq \neq 0$  e  $q^t K^t X\beta = 0$  temos,

$$(a-b)^t X = q^t K^t X \leftrightarrow$$

$$(a^t - b^t - q^t K^t) X = 0 \leftrightarrow a - b - Kq = \rho$$

onde

$\rho$  é tal que  $X^t \rho = 0$  e portanto,

$$a - b = \rho + Kq \in C(X)^\perp + C(K).$$

Como  $a = b + (a - b)$  onde

$$\begin{aligned} \text{cov}(b^t y, (a-b)^t y) &= \text{cov}(b^t y, \rho^t y + q^t K^t y) = \\ &= \text{cov}(b^t y, \rho^t y) + \text{cov}(b^t y, q^t K^t y) = \text{por (3.29)} \\ &= \text{cov}(b^t y, q^t K^t y) = b^t V Kq \sigma^2 = 0 \end{aligned}$$

então

$$\begin{aligned} \text{var}(a^t y) &= \text{var}(b^t y + (a-b)^t y) = \\ &= \text{var}(b^t y) + \text{var}((a-b)^t y) \geq \text{var}(b^t y) \end{aligned} \quad (3.33)$$

onde,  $a^t y$  é também um BLUE de  $\lambda^t \beta$  se, e somente se

$$\begin{aligned} \text{var}((a-b)^t y) &= (a-b)^t V (a-b) \sigma^2 = 0 \leftrightarrow \\ (a-b)^t V (a-b) &= 0 \leftrightarrow V(a-b) = 0 \end{aligned}$$

$$Va = Vb = -Xm \quad (\text{por (3.17)}) \quad (3.34)$$

(Observe que se  $V$  é não singular então, a única escolha para  $a$  é  $a=b$ )

Portanto, concluimos que

COROLÁRIO 1.2 - Considerando o modelo de G.M.G.  $(y, X\beta, \sigma^2V)$ .

Uma função  $a^t y$  das observações é BLUE da sua esperança se, e somente se,

$$Va \in C(X) \quad (3.35)$$

Tal resultado foi também provado por Zyskind (1967) onde, no seu desenvolvimento ele obtém explicitamente um conjunto de equações para o qual o vetor  $a$  pertence.

Rao (1965) mostra também que uma estatística é um estimador não tendencioso de variância mínima da sua esperança se é não correlacionado com toda estatística não viciada para o zero.

COROLÁRIO 1.3 - Se  $Z$  é uma matriz  $n \times n-r$  ( $r = \text{posto } X$ ) tal que  $C(Z) = C(X)^\perp$  então,  $a^t y$  é BLUE da sua esperança se, e somente se,

$$Z^t V a = \emptyset \quad (3.36)$$

PROVA - Use (3.35)

COROLÁRIO 1.4 - Funções lineares de BLUE's é também BLUE da sua esperança (3.37)

PROVA - trivial.

COROLÁRIO 1.5 - Se  $V$  é não singular então, existe um único  $a = V^{-1} X_m$ ;  $m \in R^p$ , tal que  $a^t y$  é BLUE de  $\lambda^t \beta$  (3.38)

e reciprocamente, se  $E(a^t y) = \lambda^t \beta$  e  $a = V^{-1} X_m$  para algum  $m \in R^p$  então  $a^t y$  é BLUE de  $\lambda^t \beta$ . (3.39)

PROVA - Supondo  $a \in R^n$  tal que

$$a^t X = \lambda^t$$

e

$$V_a = X_m \text{ para algum } m \in R^p$$

como  $V$  é não singular, temos

$$a^t X = \lambda^t \beta$$

e

$$a = V^{-1} X_m$$

onde  $a^t y$  é BLUE de  $\lambda^t$

ainda, como para todo  $\rho \in R^n$  então  $(a + \rho)^t y = (a^t + \rho^t) y$  é também um BLUE de  $\lambda^t \beta \leftrightarrow$  (por (3.32))

$$\rho \in C(X)^\perp \cap C(V)^\perp$$

então  $\rho \in C(V)^\perp \rightarrow V\rho = \emptyset$  mas, como  $V$  é não singular e  $V\rho = \emptyset$  temos que  $\rho = \emptyset$  e portanto  $a = V^{-1} X_m$  é o único vetor em  $C(V^{-1} X)$  tal que  $a^t y$  é BLUE de  $\lambda^t \beta$

reciprocamente

como  $E(a^t y) = \lambda^t \beta$  e  $a = V^{-1} X_m$  para algum  $m \in R^p$  então,

$$Va = V V^{-1} X_m = X_m \in C(X)$$

e portanto por (3.35) temos que

$$a^t y \text{ é BLUE de } \lambda^t \beta .$$

PROPRIEDADE 1.1 - O BLUE de  $X\beta$  é  $A^t y$  onde  $A$  é uma matriz  $n \times n$  satisfazendo

$$VA + XM = \emptyset \text{ para alguma matriz } M_{p \times n}$$

e

$$X^t A = X^t \tag{3.40}$$

PROVA - Considerando  $\lambda_i^t = x_{(i)}$  onde,  $x_{(i)}$ ,  $i = 1, \dots, n$ , é a  $i$ -ésima linha de  $X$  temos pelo teorema 1.1 - 3.1 que  $\lambda_i^t \beta$  é estimável assim, se  $a_{(i)} \in R^n$ ,  $i=1, \dots, n$  é tal que

$$V a_{(i)} + X m_{(i)} = \emptyset \text{ para algum } m_{(i)} \in R^p, i=1, \dots, n$$

e

$$X^t a_{(i)} = \lambda_i$$

temos que  $a_{(i)}^t y$  é BLUE de  $\lambda_i^t \beta = x_{(i)} \beta$  e portanto, tomando

$$A = (a_{(i)}) \text{ que é uma matriz } n \times n$$

e

$$M = (m_{(i)}) \text{ que é uma matriz } n \times p$$

temos que

$$VA + XM = \emptyset$$

e

$$X^t A = X^t$$

onde  $A^t y$  é BLUE de  $X\beta$ .

COROLÁRIO 1.6 - Se  $V$  é inversível e  $A = V^{-1} X M$  onde  $M$  é tal que

$$(X^t V^{-1} X) M = X^t$$

então

$$A^t y \text{ é BLUE de } X\beta$$

onde,  $A^t$  é a matriz do operador projeção sobre  $C(X)$  segundo a direção de vetores de  $C(VZ)$  onde  $Z$  é uma matriz tal que

$$C(Z) = C(X)^{\perp} \quad (3.41)$$

e ainda, se

$$X^t V^{-1} X \text{ é inversível então}$$

$$A^t y = X(X^t V^{-1} X)^{-1} X^t V^{-1} y \quad (\text{Aitken 1934}) \quad (3.42)$$

PROVA - Utilizando (3.40) é trivial que  $A^t y$  é BLUE de  $X\beta$ . Mostrando que  $A^t$  é a matriz do operador sobre  $C(X)$  segundo a direção de  $C(VZ)$  temos,

$$\text{como } (X^t V^{-1} X) M = X^t \leftrightarrow M^t (X^t V^{-1} X) = X$$

$$\text{então } X M = M^t (X^t V^{-1} X) M = M^t X^t = (X M)^t$$

$$\begin{aligned} \text{assim } A^2 &= V^{-1} X M V^{-1} X M = V^{-1} M^t X^t V^{-1} X M = \\ &= V^{-1} M^t X^t = V^{-1} X M = A \end{aligned}$$

$$\text{e portanto } A^2 = A \Rightarrow (A^t)^2 = A^t$$

e ainda, como

$$A^t X = X$$

e

$$A^t VZ = (VA)^t Z = M^t X^t Z = \emptyset$$

temos, que  $A^t$  é a matriz do operador projeção sobre  $C(X)$  segundo a direção de vetores de

$$C(VZ)$$

Assim, como por (3.6)  $C(V:X) = C(X) \ominus C(VZ)$  temos que o BLUE de  $X\beta$  é a projeção de  $y$  em  $C(X)$  segundo a direção de vetores de  $C(VZ)$ .

### 3.2 - CONDIÇÕES EM QUE O MELHOR ESTIMADOR DE MÍNIMOS QUADRADOS SIMPLES (SLSE) É TAMBÉM UM BLUE NO MODELO DE G.M.G.

DEFINIÇÃO 2.1 - Chamamos de Melhor Estimador dos Mínimos Quadrados Simples (SLSE) de uma função paramétrica linearmente estimável,  $\lambda^t \beta$ , ao estimador não tendencioso de menor variância de  $\lambda^t \beta$  no modelo  $(y, X\beta, \sigma^2 I)$ .

Assim, se o BLUE de  $\lambda^t \beta$  é o estimador não tendencioso de menor variância de  $\lambda^t \beta$  no modelo de G.M.G. temos,

TEOREMA 2.1 - O SLSE de  $X\beta$  é também o BLUE de  $X\beta$  se, e somente se,

$$V X = X Q \text{ para alguma matriz } Q(p \times p) \quad (3.43)$$

PROVA - Supondo  $A^t y$  um BLUE de  $X\beta$  onde

$$X^t A = X^t$$

e

$$V A = X M \text{ para alguma matriz } M_{p \times n}$$



e sendo o SLSE de  $X\beta$  dado por  $P_X y$  onde  $P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)$  (ver (2.36)) então, se

SLSE  $\equiv$  BLUE temos (por (3.40)) que

$$P_X X = X$$

e

$$V P_X = X M \text{ para alguma matriz } M_{p \times n}$$

e portanto,

$$V P_X X = V X = X M X = X Q$$

onde  $Q = M X$  é uma matriz  $p \times p$

Inversamente, se  $V X = X Q$ , tomando uma matriz  $B_{p \times n}$  tal que  $P_X = X B$  é a matriz do operador projeção ortogonal sobre  $C(X)$ , então

$$P_X X = X$$

e

$$V P_X = V X B = X Q B = X M$$

onde  $M = Q B$  é uma matriz  $p \times n$

$\rightarrow$  (teor. 1.2, 3.1)  $P_X y$  é o BLUE de  $X\beta$  e portanto por (2.36) o SLSE de  $X\beta$  é também o BLUE de  $X\beta$ .

COROLÁRIO 2.1 - Se  $V$  é não singular então SLSE  $\equiv$  BLUE de  $X\beta$  se, e somente se, existe uma matriz  $R_{p \times p}$  tal que

$$V^{-1} X = X R \tag{3.44}$$

PROVA - trivial

Observando que  $VX = XQ$  se, e somente se,  $C(X)$  é um sub-  
-espaço invariante da matriz  $V$  (Hoffman, Kunze (1979) pg 254) en-  
tão, temos

TEOREMA 2.2 - Para qualquer função das observações,  $\omega^t y$ , temos  
que o BLUE e o SLSE da  $E(\omega^t y)$  são iguais se, e somente se,  $C(X)$  é  
um sub-espaço invariante da matriz  $V$ . (3.45)

PROVA - como,  $\omega^t y$  é SLSE da  $E(\omega^t y) \leftrightarrow \omega \in C(X)$  então, se  $\omega^t y$  é  
também BLUE da  $E(\omega^t y)$  temos por (3.35) que  $V\omega \in C(X)$ .

Assim, se para todo  $\omega \in C(X) \rightarrow V\omega \in C(X)$  então  $C(X)$  é um  
sub-espaço invariante de  $V$ .

Inversamente

como,  $\omega^t y$  é SLSE da  $E(\omega^t y) \leftrightarrow \omega \in C(X)$  e por hipótese

$$\omega \in C(X) \rightarrow V\omega \in C(X)$$

então, se

$\omega^t y$  é SLSE da  $E(\omega^t y)$  temos por (3.35) que  $\omega^t y$  é tam-  
bém BLUE de  $E(\omega^t y)$ .

Zyskind (1967) mostra também que

TEOREMA 2.3 - Para qualquer função paramétrica linearmente esti-  
mável temos que o seu BLUE e o SLSE são iguais se, e somente se  
 $V$  possui  $r$  auto vetores ortogonais que formam uma base ortonomal  
para  $C(X)$ . (3.46)

PROVA - Supondo  $\lambda^t \beta$  uma função paramétrica linearmente estimável temos por (3.45) que o SLSE de  $\lambda^t \beta$  é também o BLUE de  $\lambda^t \beta$  se e somente se  $C(X)$  é um sub-espço invariante através da matriz  $V$  e portanto (Hoffman, Kunze (1979) pg 284)

$C(X)^\perp$  é também um sub-espço invariante através da matriz  $V$ .

Disto, se  $0_1^t$  é uma matriz  $n \times r$  tal que suas colunas formam uma base ortonormal para  $C(X)$  e

$0_0^t$  é uma matriz  $n \times (n-r)$  tal que suas colunas formam uma base ortonormal para  $C(X)^\perp$

temos então que, existem matrizes simétricas  $W_1$   $r \times r$  e  $W_0$   $(n-r) \times (n-r)$  tais que

$$V 0_1^t = 0_1^t W_1 \tag{3.47}$$

e

$$V 0_0^t = 0_0^t W_0$$

mas, como  $0_1 0_1^t = I_r$ ,

$$0_0 0_0^t = I_{n-r} \quad e$$

$$0_1 0_0^t = 0_0 0_1^t = \emptyset$$

então (3.47) é equivalente a

$$\begin{aligned} 0_1 V 0_1^t &= W_1 \\ 0_0 V 0_0^t &= W_0 \\ 0_1 V 0_0^t &= 0_0 V 0_1^t = \emptyset \end{aligned} \tag{3.48}$$

tomando  $0 = (0_1^t : 0_0^t)$  então

$$0^t V 0 = \begin{pmatrix} 0_1^t V 0_1^t & 0_1^t V 0_0^t \\ 0_0^t V 0_1^t & 0_0^t V 0_0^t \end{pmatrix} \quad (3.49)$$

substituindo (3.48) em (3.49) temos

$$0^t V 0 = \begin{pmatrix} W_1 & \emptyset \\ \emptyset & W_0 \end{pmatrix} \quad (3.50)$$

mas, com  $W_1$  e  $W_0$  são matrizes simétricas então existem matrizes ortonormais

$R_1$   $r \times r$  e  $R_0$   $n-r \times n-r$  tais que

$$R_1 W_1 R_1^t = D_1$$

e

$$R_0 W_0 R_0^t = D_0$$

(3.51)

onde  $D_1$  e  $D_0$  são matrizes diagonais.

assim, se

$$S^t = \begin{pmatrix} R_1 & \emptyset \\ \emptyset & R_0 \end{pmatrix} 0^t = \begin{pmatrix} R_1 & 0_1 \\ R_0 & 0_0 \end{pmatrix}$$

temos que  $S^t$  é uma matriz ortonormal e satisfaz

$$S^t V S = \begin{pmatrix} R_1 & \emptyset \\ \emptyset & R_0 \end{pmatrix} 0^t V 0 \begin{pmatrix} R_1^t & \emptyset \\ \emptyset & R_0^t \end{pmatrix} = \text{por (3.50)}$$

$$= \begin{pmatrix} R_1 & \emptyset \\ \emptyset & R_0 \end{pmatrix} \begin{pmatrix} W_1 & \emptyset \\ \emptyset & W_0 \end{pmatrix} \begin{pmatrix} R_1^t & \emptyset \\ \emptyset & R_0^t \end{pmatrix} =$$

$$= \begin{pmatrix} R_1 & W_1 & R_1^t & \emptyset \\ \emptyset & \emptyset & \emptyset & R_0 & W_0 & R_0^t \end{pmatrix} = \text{por (3.51)}$$

$$= \begin{pmatrix} D_1 & \emptyset \\ \emptyset & D_0 \end{pmatrix} \quad \text{que é uma matriz diagonal}$$

e portanto, as colunas de  $S$  formam um conjunto de auto vetores de  $V$  onde,

sendo  $S = (0_1^t \ R_1^t : 0_0^t \ R_0^t)$

então, os primeiros  $r$  auto vetores de  $V$  são combinações lineares de vetores da base de  $C(X)$  e portanto pertencem a  $C(X)$  e, os restantes  $n-r$  são combinações lineares de vetores da base de  $C(X)^\perp$  e portanto pertencem a  $C(X)^\perp$ .

mas, como  $S^t$  é ortonormal  $\rightarrow$

$$S^t S = S S^t = I_n$$

então  $S^t S = I_n \rightarrow (R_1 \ 0_1) (0_1^t \ R_1^t) = I_r \rightarrow$

as colunas de  $0_1^t$   $R_1^t$  são vetores ortonormais e portanto formam uma base ortonormal de  $C(X)$ , e assim, concluímos que  $V$  possui  $r$  auto vetores ortogonais que formam uma base ortonormal para  $C(X)$ .

Inversamente

Supondo que  $V$  possui  $r$  auto vetores ortogonais que formam uma base ortonormal para  $C(X)$

então,  $V$  também possui  $n-r$  auto vetores ortogonais que formam uma base ortonormal para  $C(X)^\perp$ .

Seja  $0 = (0_1 : 0_0)$  a matriz ortonormal cujas colunas de  $0_1$  e  $0_0$  são formadas respectivamente por esses vetores das bases de  $C(X)$  e  $C(X)^\perp$ .

Assim, como

$$0^t V 0 = \begin{pmatrix} D_1 & \emptyset \\ \emptyset & D_0 \end{pmatrix} \quad \text{onde } D_1 \text{ é uma matriz}$$

$r \times r$  diagonal e  $D_0$  é uma matriz

$n-r \times n-r$  diagonal temos

$$V = 0 \begin{pmatrix} D_1 & \emptyset \\ \emptyset & D_0 \end{pmatrix} 0^t \leftrightarrow V = 0_1 D_1 0_1^t + 0_0 D_0 0_0^t \quad (3.52)$$

daí, como para todo vetor  $\omega \in C(X)$

temos

$$0_0^t \omega = \emptyset \quad (3.53)$$

então, aplicando  $V$  em  $\omega$  temos por (3.52) e (3.53) que

$$V_{\omega} = 0_1 D_0 0_1^t \omega + 0_0 D_0 0_0^t \omega = 0_1 D_1 0_1^t \omega = 0_1 \phi$$

onde  $\phi = D_1 0_1^t \omega \in R^r$

e portanto

$$V_{\omega} \in C(X) \tag{3.54}$$

assim, como

$$\omega \in C(X) \rightarrow \omega^t y \text{ é SLSE da } E(\omega^t y)$$

e

$$V_{\omega} \in C(X) \rightarrow \omega^t y \text{ é BLUE da } E(\omega^t y)$$

então, por (3.52) e (3.54) concluímos que

para toda função paramétrica linearmente estimável o seu SLSE e o seu BLUE são iguais.

COROLÁRIO 2.2 - Se  $\omega$  é um vetor de  $C(X)$  e  $\phi$  é uma combinação linear dos auto vetores de  $V$  pertencentes a  $C(X)$  então  $\omega^t y$  são ambos SLSE e BLUE da  $E(\omega^t y)$ . (3.55)

PROVA - trivial

COROLÁRIO 2.3 - Para qualquer função paramétrica linearmente estimável, o seu BLUE e o SLSE são iguais se, e somente se,

$$V = X T_1 X^t + Z T_2 Z^t + a^2 I_n \tag{3.56}$$

onde

$T_1$  e  $T_2$  são matrizes  $p \times p$  e  $n-r \times n-r$  respectivamente e  $a \in R$ .

PROVA - Como, por (3.46)  $SLSE \equiv BLUE \rightarrow$

V possui r auto vetores ortogonais que formam uma base ortonormal para  $C(X)$  e portanto, V também possui n-r auto vetores que formam uma base para  $C(X)^\perp$

então, temos que

$$V = O D O^t \quad \text{onde } O = (O_1 : O_0) \text{ é uma}$$

matriz ortonormal cujas colunas de  $O_1$  e  $O_0$  são formados respectivamente por esses vetores da base de  $C(X)$  e  $C(X)^\perp$  e D é uma matriz n×n diagonal

assim, fazendo  $D = a^2 I_n + Q$  onde  $a \in \mathbb{R}$  e Q é uma matriz diagonal temos que

$$\begin{aligned} V &= O(a^2 I_n + Q) O^t = \\ &= a^2 I_n + O Q O^t \quad \text{pois } O O^t = I_n \end{aligned}$$

e ainda, se  $Q = \begin{pmatrix} Q_1 & \emptyset \\ \emptyset & Q_0 \end{pmatrix}$

onde

$Q_1$  e  $Q_0$  são matrizes diagonais r×r e n-r×n-r respectivamente então

$$V = a^2 I_n + O_1 Q_1 O_1^t + O_0 Q_0 O_0^t$$

e como,  $C(O_1) = C(X) \rightarrow O_1 = X C_1$  onde

$C_1$  é uma matriz p×r de posto r

e

$$C(O_0) = C(X)^\perp = C(Z) \rightarrow O_0 = Z C_0$$



onde  $C_0$  é uma matriz  $n-r \times n-r$  de posto  $n-r$

temos,

$$\begin{aligned} V &= a^2 I_n + X C_1 Q_1 C_1^t X^t + Z C_0 Q_0 C_0^t Z^t = \\ &= X T_1 X^t + Z T_0 Z^t + a^2 I_n \end{aligned}$$

onde

$$T_1 = C_1 Q_1 C_1^t \text{ é uma matriz } p \times p$$

$$T_0 = C_0 Q_0 C_0^t \text{ é uma matriz } n-r \times n-r$$

e  $a \in \mathbb{R}$

Inversamente, supondo

$$V = a^2 I_n + X T_1 X^t + Z T_0 Z^t \text{ onde}$$

$Z$  é uma matriz  $n \times n-r$  tal que  $C(Z) = C(X)^{\oplus}$

$a \in \mathbb{R}$

$T_1$  é uma matriz  $p \times p$

$T_0$  é uma matriz  $n-r \times n-r$

temos,

como  $\omega^t y$  é SLSE da  $E(\omega^t y) \leftrightarrow \omega = X\rho$  para algum  $\rho \in \mathbb{R}^p$

e  $\omega^t y$  é BLUE da  $E(\omega^t y) \leftrightarrow Z^t V \omega = \emptyset$  (ver 3.36)

então, temos que para todo  $\omega \in \mathbb{R}^n$  tal que  $\omega = X\rho$  para algum  $\rho \in \mathbb{R}^p$

$$\rightarrow Z^t V \omega = Z^t V X\rho = a^2 Z^t X\rho + Z^t X T_1 X^t X\rho +$$

$$+ Z^t Z T_0 Z^t X \rho = \beta \quad \text{pois} \quad Z^t X = \beta$$

e portanto SLSE  $\equiv$  BLUE para toda função paramétrica linearmente estimável.

### 3.3 - CARACTERIZAÇÃO DOS BLUE'S NO MODELO DE G.M.G.

O problema presente, pode ser tratado por vários métodos como, por exemplo,

Rao (1971, 72, 75 e 78) apresenta uma Teoria unificada para a representação de BLUE's no Modelo de G.M.G. Nestes artigos, Rao demonstra a existência de uma matriz T tal que  $C(T) = C(V:X)$  e conclui que o BLUE de qualquer função paramétrica linearmente estimável,  $\lambda^t \beta$ , é dado por  $\lambda^t \hat{\beta}$  para todo  $\hat{\beta}$  que satisfaz

$$X^t T^- X \beta = X^t T^- \beta$$

onde

$T^-$  é uma g-inversa de T

Rao (1971, 72) apresenta também um método denominado Método da Inversa da Matriz Particionada

$$M = \begin{pmatrix} V & X \\ X^t & \beta \end{pmatrix} \quad \text{obtida a partir da}$$

minimização de  $b^t V b$  restrito a  $X^t b = \lambda$  pelo método do multiplicador de Lagrange e conclui que,

sendo

$$M^- = \begin{pmatrix} C_1 & C_2 \\ C_3 & -C_4 \end{pmatrix}$$

uma  $g$ -inversa de  $M$ , então, o BLUE de  $\lambda^t \beta$  é  $\lambda^t \hat{\beta}$  onde

$$\hat{\beta} = C_2^t y \quad \text{ou} \quad C_3 y$$

Rao (1973) apresenta um conjunto  $L_p$  tal que para todo  $L \in L_p$  então

$$L^t y \text{ é BLUE da sua esperança.}$$

Zyskind e Martin (1969) constroem uma sub-classe de  $g$ -inversa de  $V$  que depende da relação entre  $X$  e  $V$  e diz que,

se  $V^-$  é uma  $g$ -inversa de  $V$  que pertence a esta sub-classe então, o BLUE de  $\lambda^t \beta$  é  $\lambda^t \hat{\beta}$  para todo  $\hat{\beta}$  tal que

$$X^t V^- X \hat{\beta} = X^t V^- y$$

Goldman e Zelen (1964) mostram que um modelo linear com matriz de covariância singular pode ser transformado através de uma matriz ortonormal para um modelo equivalente ao modelo linear com restrição nos parâmetros e cuja matriz de variância e covariância dos erros é  $\sigma^2 I$ .

Neste trabalho, apresentaremos uma caracterização do BLUE de  $X\beta$ , sem relacionarmos com qualquer inversa generalizada de  $V$  (singular) encontrando, uma forma de melhorar a informação sobre  $X\beta$  através de vetores de  $C(X)^\perp$  usando o argumento apresentado por Rao (1967) denominado ajustamento por covariância.

Para este propósito, supondo

$$a^t y \text{ o SLSE de } \lambda^t \beta = a^t X\beta \tag{3.57}$$

e  
Z uma matriz  $n \times n-r$ ,  $r = \text{posto}(X)$ , tal que  $C(Z) = C(X)^\perp$ , e por  
tanto  $Z^t X = \emptyset$  (3.58)

temos que

$$\text{por (3.57)} \quad E(a^t y) = a^t X \beta = \lambda^t \beta \quad \text{para todo } \beta \in R^p \quad (3.59)$$

e por (3.58), para todo  $\rho \in R^{n-r}$  tal que  $Z \rho \in \sigma(Z) \rightarrow$

$$E(\rho^t Z^t y) = \rho^t Z^t X \beta = 0 \quad \text{para todo } \beta \in R^p. \quad (3.60)$$

assim, por (3.59) e (3.60) o novo funcional linear  $a^t y - \rho^t Z^t y$  é  
tal que

$$E(a^t y - \rho^t Z^t y) = E(a^t y) - E(\rho^t Z^t y) = \lambda^t \beta \quad (3.61)$$

para todo  $\beta \in R^p$

onde, sendo

$$\begin{aligned} \text{var}(a^t y - \rho^t Z^t y) &= \text{var}(a^t y) - 2 \text{cov}(a^t y, \rho^t Z^t y) + \\ &+ \text{var}(\rho^t Z^t y) \end{aligned} \quad (3.62)$$

temos que,

se

$$\text{cov}(a^t y, \rho^t Z^t y) \neq 0 \quad (3.63)$$

então

$$\text{var}(a^t y - \rho^t Z^t y) \leq \text{var}(a^t y) \leftrightarrow$$

$$0 \leq \text{var}(\rho^t Z^t y) \leq 2 \text{cov}(a^t y, \rho^t Z^t y)$$

e neste caso, supondo

$$\text{var}(\rho^t Z^t y) = \text{cov}(a^t y, \rho^t Z^t y)$$

então (3.62) fica

$$\text{var}(a^t y - \rho^t Z^t y) = \text{var}(a^t y) - \text{cov}(a^t y, \rho^t Z^t y)$$

e portanto  $\lambda^t_\beta$  é melhor ajustado por

$$a^t y - \rho^t Z^t y$$

se  $\text{cov}(a^t y, \rho^t Z^t y) = 0$  (3.64)

então (3.62) fica

$$\text{var}(a^t y - \rho^t Z^t y) = \text{var}(a^t y) + \text{var}(\rho^t Z^t y) \geq \text{var}(a^t y)$$

e portanto

$$\lambda^t_\beta \text{ é melhor ajustado por } a^t y$$

e ainda

$$\text{cov}(a^t y, \rho^t Z^t y) = 0 \text{ para todo } \rho \in R^{n-r} \rightarrow$$

$$\rightarrow a^t V Z = \emptyset \tag{3.65}$$

e portanto

(3.65)  $\rightarrow$  (por(3.36)) que o BLUE de  $\lambda^t_\beta$  é o SLSE  $a^t y$  de  $\lambda^t_\beta$ .

Mostrando que existe  $\rho \in R^{n-r}$ ,  $\rho \neq \emptyset$  tal que o BLUE de  $\lambda^t_\beta$  é dado por

$$a^t y - \rho^t Z^t y \text{ temos,}$$

Como, por (3.36) o BLUE de  $\lambda^t \beta$  é

$$\begin{aligned} a^t y - \rho^t Z^t y &\leftrightarrow Z^t V(a - Z\rho) = \beta \leftrightarrow \\ Z^t V Z \rho &= Z^t V a \end{aligned} \quad (3.66)$$

Sendo  $V$  uma matriz positiva e portanto

$$V = CC^t \text{ onde } C \text{ é uma matriz } n \times s \quad (3.67)$$

então, substituindo (3.67) em (3.66) temos

$$\begin{aligned} Z^t C C^t Z \rho &= Z^t C C^t a \leftrightarrow \\ (C^t Z)^t (C^t Z) \rho &= (C^t Z)^t (C^t a) \end{aligned} \quad (3.68)$$

Observando que (3.68) é um conjunto de equações normais que são sempre consistentes para todo  $C^t a \in R^s$  então, podemos concluir que existe

$$\rho \neq \emptyset, \rho \in R^{n-r} \text{ tal que } \rho \text{ satisfaz (3.66)} \quad (3.69)$$

e ainda, como por (2.12)

$$C^t Z \rho_1 = C^t Z \rho_2 \text{ para todo } \rho_1 \text{ e } \rho_2 \in R^{n-r}$$

tal que  $\rho_1$  e  $\rho_2$  satisfazem (3.66)

temos que

$$C^t Z \rho_1 = C^t Z \rho_2 \rightarrow a^t V Z \rho_1 = a^t V Z \rho_2$$

ou seja

$$\text{cov}(a^t y, \rho_1^t Z^t y) = \text{cov}(a^t y, \rho_2^t Z^t y)$$

para todo  $\rho_1$  e  $\rho_2 \in \mathbb{R}^{n-r}$  tal que satisfazem (3.66) (3.70)

e portanto, para todo  $\rho \in \mathbb{R}^{n-r}$  tal que  $\rho$  satisfaz (3.66) temos que

$$\begin{aligned} \text{var}(a^t y) - \text{var}(a^t y - \rho^t Z^t y) &= \\ &= 2 \text{cov}(a^t y, \rho^t Z^t y) - \text{var}(\rho^t Z^t y) = \\ &= 2 \text{cov}(a^t y, \rho^t Z^t y) - \rho^t Z^t V Z \rho \sigma^2 = \\ &= 2 \text{cov}(a^t y, \rho^t Z^t y) - \rho^t Z^t V a \sigma^2 = \\ &= 2 \text{cov}(a^t y, \rho^t Z^t y) - \text{cov}(a^t y, \rho^t Z^t y) = \\ &= \text{cov}(a^t y, \rho^t Z^t y) = \sigma^2 a^t V Z \rho = \sigma^2 \rho^t Z^t V Z \rho \geq 0 \end{aligned}$$

ou seja,

$$\begin{aligned} 0 &\leq \text{var}(a^t y) - \text{var}(a^t y - \rho^t Z^t y) = \\ &= \text{cov}(a^t y, \rho^t Z^t y) \leq \text{var}(a^t y) \end{aligned} \quad (3.71)$$

assim (3.71)  $\rightarrow$

$$0 \leq \text{var}(a^t y - \rho^t Z^t y) = \text{var}(a^t y) - \text{cov}(a^t y, \rho^t Z^t y)$$

e 
$$\text{var}(a^t y - \rho^t Z^t y) \leq \text{var}(a^t y) \quad (3.72)$$

e portanto, por (3.69), (3.70) e (3.72) concluimos que

existe  $\rho \neq 0$ ,  $\rho \in \mathbb{R}^{n-r}$  tal que satisfaz

$$Z^t V(a - Z\rho) = 0$$

e, para todo  $\rho$  satisfazendo a relação acima temos que

$a^t y - \rho^t Z^t y$  será efetivamente o BLUE de  $\lambda^t \beta = a^t X \beta$  quando passamos de  $V=I_n$  para  $V$  singular com a variância ajustada pela  $\text{cov}(a^t y, \rho^t Z^t y)$ .

Da mesma forma, temos

TEOREMA 3.1 - Sob as condições do modelo de G.M.G. o BLUE de  $X\beta$  é dado por  $A^t y$  onde,

$$A = I - ZB \quad (3.73)$$

onde  $Z$  é uma matriz  $n \times n-r$  tal que  $C(Z) = C(X)^\perp$  e

$B$  é uma matriz tal que satisfaz  $Z^t V Z B = Z^t V$

ou

$$A = P_X - (I - P_X) U \quad (3.74)$$

onde  $P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)$ .

e  $U$  é uma matriz tal que satisfaz

$$(I - P_X) V (I - P_X) U = (I - P_X) V P_X$$

PROVA - Vimos por (3.68) que

$Z^t V Z \rho = Z^t V a = Z^t C(C^t a)$  é consistente para todo vetor  $C^t a \in R^s$ .

Assim, tomando  $C^t a_{(i)} = i$ -ésima coluna de  $C^t$   $i=1, \dots, n$

então, existe uma matriz  $B = (\rho_{(i)})$

onde  $\rho_{(i)} \in R^{n-r}$ ;  $\rho_{(i)} \neq \emptyset$   $i=1, \dots, n$



satisfazendo

$$\begin{aligned} Z^t V Z B &= (Z^t V Z \rho_{(i)}) \\ &= (Z^t C C^t a_{(i)}) = Z^t C (C^t a_{(i)}) = Z^t C C^t = Z^t V \quad (3.75) \end{aligned}$$

assim, se

$$A = I - Z B$$

temos que

$$X^t A = X^t - X^t Z B = X^t$$

e

$$V A = V - V Z B \quad (3.76)$$

mas, como por (3.75) temos  $Z^t(V Z B - V) = \emptyset$

e como

$$Z^t(V Z B - V) = \emptyset \leftrightarrow V Z B - V = X M \text{ para}$$

alguma matriz  $M_{p \times n}$

$$\leftrightarrow V Z B = V + X M \quad (3.77)$$

então, substituindo (3.77) em (3.76) temos

$$X^t A = X^t$$

e

$$V A = -X M \text{ para alguma matriz } M_{p \times n}$$

e portanto, por (3.40) concluimos que

$A^t y$  é o BLUE de  $X\beta$  onde

$A = I - ZB$  para toda matriz  $B$  tal que

$$Z^t V Z B = Z^t V$$

Considerando,  $P_X$  a matriz do operador projeção ortogonal  $\underline{\sigma}$  sobre  $C(X)$  temos por (1.55) que  $I-P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)^\perp$

assim tomando  $Z = I-P_X$  (3.75) fica

$$(I-P_X) V(I-P_X)B = (I-P_X)V \quad (3.78)$$

multiplicando à direita de (3.78) por  $P_X$  e fazendo  $BP_X = U$  temos

$$(I-P_X)V(I-P_X)U = (I-P_X)V P_X \quad (3.79)$$

onde, tomando  $A = P_X - (I-P_X)U$

obtemos que

$$X^t A = X^t P_X - X^t (I-P_X)U = (P_X X)^t = X^t$$

e por (3.79)

$$(I-P_X)V A = (I-P_X)V P_X - (I-P_X)V(I-P_X)U = \emptyset \quad (3.80)$$

mas, como  $C(I-P_X) = C(X)^\perp = C((I-P_X)^t)$

então  $(I-P_X)V A = \emptyset \rightarrow V A = X M$  para alguma matriz  $M_{p \times n}$

e portanto

$$X^t A = X^t$$

e  $V A = X M$  para alguma matriz  $M_{p \times n}$

concluimos por (3.40) que

$A^t y$  é BLUE  $X\beta$  onde

$A$  é dada por (3.74)

PROPRIEDADE 3.1 - Sob as condições do modelo de G.M.G.

$$\text{Sendo } A_1 = I-ZB$$

e

$$A_2 = P_X - (I-P_X)U$$

dadas respectivamente por (3.73) e (3.74)

$$\text{então, } A_1^t y = A_2^t y \text{ com probabilidade 1} \quad (3.81)$$

PROVA - Como  $A_1$  e  $A_2$  dadas respectivamente por (3.73) e (3.74) são tais que

$$A_1^t y \text{ e } A_2^t y \text{ são duas representações do BLUE de } X\beta$$

então,

$$E(A_1^t y - A_2^t y) = E(A_1^t y) - E(A_2^t y) = \emptyset \quad (3.82)$$

e ainda,

como

$$\begin{aligned} A_1^t - A_2^t &= (I-ZB)^t - (P_X + (I-P_X)U)^t = \\ &= (I-U)^t (I-P_X) - B^t Z^t \end{aligned}$$

$$\text{onde } C(I-P_X) = C(Z) = C(X)^\perp$$

$$\text{então } C(A_1^t - A_2^t) \subset C(Z^t) = C(I-P_X) \quad (3.83)$$

$$\begin{aligned} \text{e } V(A_1 - A_2) &= V A_1 - V A_2 = X M_1 - X M_2 = \\ &= X(M_1 - M_2) \end{aligned}$$

$$\rightarrow C(V(A_1 - A_2)) \subset C(X) \quad (3.84)$$

então, por (3.83) e (3.84) temos

$$\text{var}((A_1^t - A_2^t)y) = \sigma^2 (A_1^t - A_2^t) V (A_1 - A_2) \emptyset \quad (3.85)$$

e portanto por (3.82) e (3.85) concluimos que

$$A_1^t y = A_2^t y \quad \text{com probabilidade 1.}$$

PROPRIEDADE 3.2 - Sob as condições do modelo de G.M.G.

$$\text{Se} \quad A_1 = P_X - (I - P_X)U_1$$

$$\text{e} \quad A_2 = P_X - (I - P_X)U_2$$

onde  $P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)$  e

$U_1$  e  $U_2$  são duas soluções de

$$(I - P_X)V (I - P_X)U = (I - P_X) V P_X$$

então,

$$A_1^t y = A_2^t y \quad \text{com probabilidade 1} \quad (3.85)$$

PROVA - Como por (3.74) temos que

$A_1^t y$  e  $A_2^t y$  são duas representações do BLUE de  $X\beta$

então,

$$E(A_1^t y - A_2^t y) = E(A_1^t y) - E(A_2^t y) = \emptyset \quad (3.86)$$

e ainda, como

$$A_1 - A_2 = (I - P_X) (U_1 - U_2) \quad \text{então}$$

$$\text{var}((A_1^t - A_2^t)y) = (U_1 - U_2)^t (I - P_X) V (A_1 - A_2)$$

mas, como  $C(I - P_X) = C(X)^\perp$

então, por (3.36) temos que

$$(I - P_X)V (A_1 - A_2) = (I - P_X) V A_1 - (I - P_X) V A_2 = \emptyset$$

$$\text{e portanto } \text{var}(A_1^t y - A_2^t y) = \emptyset \quad (3.87)$$

ou seja,

por (3.86) e (3.87) temos que

$$A_1^t y = A_2^t y \quad \text{com probabilidade 1.}$$

Assim, por (3.81) e (3.85) apesar da falta da unicidade da representação do BLUE de  $X\beta$ , concluímos que a estimativa de  $X\beta$  é sempre a mesma.

Rao (1973) afirma que

COROLÁRIO 3.1 - Sob a condição do modelo de G.M.G. temos que se

$$A_1 = (I - Z B)$$

e

$$A_2 = P_X - (I - P_X)U$$

como definidas por (3.73) e (3.74) respectivamente

então, se

$$\text{posto } (V:X) = n \quad \text{teremos } A_1 = A_2 \quad (3.88)$$

ou seja,

existe uma única representação do BLUE de  $X$  no modelo de G.M.G.

PROVA - Como, por (3.4) observamos que

$$C(V:X) = C(X:VZ) = C(X) \oplus C(VZ)$$

então, se posto  $(V:X) = n \rightarrow$

$$\rightarrow \text{posto } (X:VZ) = n$$

e como por (3.7) posto  $(X:VZ) = \dim (C(X:VZ)) =$

$$= \dim C(X) + \dim (C(VZ)) = \text{posto}(X) + \dim (C(Z^t V)) =$$

$$= \text{posto } X + \text{posto } (Z^t V) = (\text{por 1.33}) \text{ posto}(X) + \text{posto}(Z) +$$

$$- \dim(C(Z) \cap C(V)^\perp) = r+n-r - \dim(C(Z) \cap C(V)^\perp) =$$

$$= n - \dim (C(Z) \cap C(V)^\perp) = n \leftrightarrow$$

$$\dim (C(Z) \cap C(V)^\perp) = 0 \leftrightarrow C(Z) \cap C(V)^\perp = \emptyset$$

e como  $A_1$  e  $A_2$  definidas respectivamente (3.73) e (3.74) são tais que

$$X^t(A_1 - A_2) = \emptyset \leftrightarrow C(A_1 - A_2) \subset C(Z)$$

e, por (3.81)

$$\text{var}((A_1 - A_2)^t y) = (A_1 - A_2)^t V (A_1 - A_2) = \emptyset \leftrightarrow$$

$$V(A_1 - A_2) = \emptyset \text{ pois } V \text{ é uma matriz positiva}$$

$$\text{e, } V(A_1 - A_2) = \emptyset \leftrightarrow C(A_1 - A_2) \subset C(V)^\perp$$

$$\text{temos } C(A_1 - A_2) \subset C(Z) \cap C(V)^\perp = \emptyset \leftrightarrow$$

$$C(A_1 - A_2) = \emptyset \leftrightarrow A_1 = A_2$$

Assim por (3.88) observamos que mesmo quando  $V$  é singular é possível obtermos uma única representação para o BLUE de  $X\beta$ .

PROPRIEDADE 3.3 - Sob as condições do modelo de G.M.G. sendo a BLUE de  $X\beta$  dado por  $A^t y$  onde

$$A = P_X - (I - P_X)U$$

como definida em (3.74)

então

$$E(A^t y) = X\beta$$

$$e \quad \text{var}(A^t y) = \text{var}(P_X y) - \text{cov}(P_X y, U^t (I - P_X) y) \quad (3.89)$$

onde,

$\text{cov}(P_X y, U^t (I - P_X) y)$  independe da solução  $U$  e também é uma matriz positiva (3.90)

PROVA - Sendo  $A = P_X - (I - P_X)U$

onde  $U$  é tal que

$$(I - P_X)V(I - P_X)U = (I - P_X) V P_X \quad (3.91)$$

então, multiplicando à esquerda de (3.91) por  $U^t$  temos,

$$U^t (I - P_X) V (I - P_X) U = U^t (I - P_X) V P_X$$

ou seja,

$$\text{var}(U^t(I-P_X)y) = \text{cov}(U^t(I-P_X)y, P_X y) \quad (3.92)$$

e portanto,

$$\text{cov}(U^t(I-P_X)y, P_X y) = \text{cov}(P_X y, U^t(I-P_X)y) \text{ é}$$

sempre uma matriz positiva para toda solução  $U$  de (3.91).

Mostrando que  $\text{cov}(P_X y, U^t(I-P_X)y)$  independe da solução de (3.91) temos;

como  $V$  é positiva  $\rightarrow V = C \cdot C^t$  para alguma matriz  $C_{n \times s}$ .

temos então que

(3.91) é equivalente ao conjunto de equações.

$$[C^t(I-P_X)]^t [C^t(I-P_X)]U = [C^t(I-P_X)]^t (C^t P_X) \quad (3.93)$$

observando que este conjunto de equações forma um conjunto de  $n$  equações lineares cuja estrutura coincide com o da equações normais que são sempre consistentes e também

$C^t(I-P_X)U$  é invariante para toda solução desse conjunto de sistema de equações então temos que

$$C^t(I-P_X) U_1 = C^t(I-P_X) U_2 \quad (3.94)$$

para toda matriz  $U_1$  e  $U_2$  tais que satisfazem (3.93).

Assim, como  $C^t(I-P_X) U_2 = C^t(I-P_X) U_1 \leftrightarrow$

$$U_2^t (I-P_X) C = U_1^t (I-P_X) C \quad (3.95)$$



então, por (3.94) e (3.95) temos que

$$\begin{aligned} U_2^t (I-P_X) V(I-P_X) U_2 &= U_1^t (I-P_X) V(I-P_X) U_2 = \\ &= U_2^t (I-P_X) V(I-P_X) U_1 = U_1^t (I-P_X) V(I-P_X) U_1 \end{aligned} \quad (3.96)$$

e portanto, por (3.92) e (3.96) temos

$$\text{cov}(P_X y, U_1^t (I-P_X) y) = \text{cov}(P_X y, U_2^t (I-P_X) y)$$

para toda solução  $U_1$  e  $U_2$  de (3.91)

Mostrando agora que

$$\text{var}(A^t y) = \text{var}(P_X y) - \text{cov}(P_X y, U^t (I-P_X) y)$$

temos,

como  $A^t y = P_X y - U^t (I-P_X) y$  onde  $U$  satisfaz (3.91)

então,

$$\text{var}(A^t y) = \text{var}(P_X y) - 2\text{cov}(P_X y, U^t (I-P_X) y) + \text{var}(U^t (I-P_X) y)$$

e, por (3.92) temos

$$\text{var}(A^t y) = \text{var}(P_X y) - 2\text{cov}(P_X y, U^t (I-P_X) y) + \text{cov}(P_X y, U^t (I-P_X) y)$$

ou seja,

$$\text{var}(A^t y) = \text{var}(P_X y) - \text{cov}(P_X y, U^t (I-P_X) y)$$

Assim, sendo o SLSE de  $X\beta$  dado por  $P_X y$  e o BLUE de  $X$  dado por  $A^t y = P_X y - U^t(I-P_X)y$  que podemos considerar como

$$P_X y - (\text{perturbação em } (I-P_X))$$

notamos que, como

$$\text{cov}(P_X y, U^t(I-P_X)y) = \sigma^2 P_X V(I-P_X) U \text{ é}$$

positiva e independe de  $U$

então, existem vetores em  $C(I-P_X)U = C(X)^\perp$  da forma  $(I-P_X)U$  tais que não pertencem ao núcleo de  $V$  e, a imagem desses vetores através de  $V$  são projetados por  $P_X$  em vetores não nulos de  $C(X)$ ;

Assim, na estimação de  $X\beta$  no modelo de G.M.G. há uma contribuição importante associada à perturbação  $(I-P_X)U$  onde, sendo a

$$\text{cov}(P_X y, U^t(I-P_X)y) = \text{var}(P_X y) - \text{var}(A^t y)$$

uma matriz positiva então, temos que realmente o ajustamento de  $P_X y$  por  $U^t(I-P_X)y$  reduz a variância de  $P_X y$ .

Assim, a variância de SLSE de  $X\beta$  com  $V = I_n$  é  $\text{var}(P_X y) = \sigma^2 P_X$ , e quando passamos a  $V$  singular o BLUE de  $X\beta$  é dado por  $A^t y = P_X y - U^t(I-P_X)y$  com a

$$\text{var}(P_X y) = \sigma^2 P_X V P_X \text{ ajustada pela covariância de } (P_X y, U^t(I-P_X)y)$$

COROLÁRIO 3.2 - Sob as condições do modelo de G.M.G. consideran

do

$$A^t y = P_X y - U^t (I - P_X) y \text{ como dado em (3.74) o BLUE de } X\beta$$

então,

$$\text{SLSE} \equiv \text{BLUE se, e somente se, } (I - P_X) V P_X = \emptyset \quad (3.97)$$

PROVA - Sendo o SLSE de  $X\beta$  dado por  $P_X y$  e o

BLUE de  $X\beta$  dado por

$$A^t y = P_X y - U^t (I - P_X) y \text{ onde}$$

$$U \text{ satisfaz } (I - P_X) V (I - P_X) U = (I - P_X) V P_X$$

então, o

SLSE  $\equiv$  BLUE se e somente se

$$\text{var}(A^t y) = \text{var}(P_X y) \leftrightarrow (\text{por (3.89)})$$

$$\text{var}(P_X y) - \text{cov}(P_X y, U^t (I - P_X) y) = \text{var}(P_X y) \leftrightarrow$$

$$\text{cov}(P_X y, U^t (I - P_X) y) = \sigma^2 P_X V (I - P_X) U = \emptyset$$

$$\leftrightarrow (\text{por (3.92)}) U^t (I - P_X) V (I - P_X) U = \emptyset \quad (3.98)$$

mas, como  $V = C C^t$  para alguma matriz  $C_{n \times s}$

então (3.98) fica

$$[C^t (I - P_X) U]^t [C^t (I - P_X) U] = \emptyset \leftrightarrow$$

$$C^t (I - P_X) U = \emptyset \leftrightarrow V (I - P_X) U = \emptyset$$

mas, como  $V(I-P_X)U = \emptyset \rightarrow (I-P_X) V(I-P_X)U = \emptyset$

então, temos que  $(I-P_X) V P_X = \emptyset$

Inversamente, se  $P_X V(I-P_X) = \emptyset$  temos

$$\sigma^2 P_X V(I-P_X)U = \emptyset \quad \text{e por (3.92)}$$

$$\sigma^2 U^t(I-P_X) V(I-P_X)U = \emptyset$$

ou seja  $\text{var}(U^t(I-P_X)y) = \emptyset$

assim, como  $E(U^t(I-P_X)y) = U^t(I-P_X)X\beta = \emptyset$

para todo  $\beta \in R^p$

e  $\text{var}(U^t(I-P_X)y) = \emptyset$

então  $U^t(I-P_X)y = \emptyset$  com probabilidade 1

e portanto

$$A^t y = P_X y + U^t(I-P_X)y = P_X y$$

ou seja, SLSE  $\equiv$  BLUE

COROLÁRIO 3.3 - Sob as condições do modelo de G.M.G. SLSE  $\equiv$  BLUE

se e somente se  $VP_X = P_X V$  (3.99)

onde  $P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)$ .

PROVA - Como, por (3.97) temos

$$\text{SLSE} \equiv \text{BLUE} \leftrightarrow P_X V(I-P_X) = \emptyset \quad \text{então}$$

$$\text{SLSE} \equiv \text{BLUE} \leftrightarrow P_X V (I - P_X) = \emptyset \leftrightarrow$$

$$P_X V = P_X V P_X = (P_X V P_X)^t = (P_X V)^t = V P_X$$

COROLÁRIO 3.4 - Sob as condições do modelo de G.M.G.

$$\text{SLSE} \equiv \text{BLUE} \leftrightarrow V = X T_1 X^t + (I - P_X) T_2 (I - P_X) + a^2 I_n$$

onde  $T_1$  e  $T_2$  são matrizes  $p \times p$  e  $n \times n$  respectivamente,  $a \in \mathbb{R}$  e  $P_X$  é a matriz do operador projeção ortogonal (3.100)

PROVA - Como, por (3.56) vemos que

$$\text{SLSE} \equiv \text{BLUE} \leftrightarrow V = X Q_1 X^t + X Q_2 Z^t + a^2 I_n \quad (3.101)$$

onde  $Q_1$  e  $Q_2$  são matrizes  $p \times p$  e  $n-r \times n-r$  respectivamente,  $a \in \mathbb{R}$  e  $Z$  é uma matriz  $n \times n-r$  tal que  $C(Z) = C(X)^{\perp}$

então, sendo  $P_X$  a matriz do operador projeção ortogonal sobre  $C(X)$  temos, por (1.55) que  $(I - P_X)$  é a matriz do operador projeção ortogonal sobre  $C(X)^{\perp}$ .

e portanto, sendo  $C(I - P_X) = C(X)^{\perp} = C(Z)$

então, existe uma matriz  $F_{n \times n-r}$  de posto  $n-r$  tal que  $(I - P_X)F = Z$  (3.102)

assim, substituindo (3.102) em (3.101) e lembrando que

$$(I - P_X) = (I - P_X)^t \text{ temos}$$

$$\text{SLSE} \equiv \text{BLUE} \leftrightarrow V = X Q_1 X^t + (I - P_X) F T_2 F^t (I - P_X) + a^2 I_n$$

$$\leftrightarrow V = X T_1 X^t + (I - P_X) T_2 (I - P_X) + a^2 I_n$$

onde  $T_1 = Q_1$ ,  $Q_2 = F T_2 F^t$  são matrizes  $p \times p$  e  $n \times n$  respectivamente e  $a \in R$ .

Considerando, novamente o BLUE de  $X\beta$  dado por  $A^t y$  onde

$$A = I - ZB \quad \text{é definida em (3.73)}$$

e, definindo a matriz  $C_{n \times n}$  por

$C = A P_X$  onde  $P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)$

temos,

TEOREMA 3.2 - Sob a condição do modelo de G.M.G. definindo a matriz

$$C = A P_X \quad (3.103)$$

onde,  $P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)$

$$A = I - ZB \quad \text{onde}$$

$B$  satisfaz  $Z^t V Z B = Z^t V$

e  $Z_{n \times n-r}$  e tal que  $C(Z) = C(X)^1$

então

$$C^t y \quad \text{é um BLUE de } X\beta \quad (3.104)$$

e  $C^t y = A^t y$  com probabilidade 1

PROVA - Como  $A = I - ZB$  definida em (3.73) é tal que por (3.76)

$$X^t A = X^t$$

e  $V A = X M$  para alguma matriz  $M_{p \times n}$

então  $C = A P_X \rightarrow C = P_X - Z B P_X$  é tal que

$$X^t C = X^t A P_X = X^t P_X = (P_X X)^t = X^t$$

e

$$V C = V A P_X = X M P_X = X Q \quad (3.105)$$

onde  $a = M P_X$  é uma matriz  $p \times n$  e portanto por (3.40)

temos que  $C^t y$  é também um BLUE de  $X\beta$

mostrando que  $A^t y = C^t y$  com probabilidade 1 temos,

a. como  $E(A^t y) = X\beta = E(C^t y)$

$$\text{então } E(A^t y - C^t y) = E(A^t y) - E(C^t y) = \emptyset$$

b. como

$$\begin{aligned} A - C &= I - ZB - P_X + Z B P_X = \\ &= (I - P_X) (I - ZB) \end{aligned}$$

e

$$\begin{aligned} (A^t - C^t) V &= A^t V - C^t V = M^t X^t - Q^t X^t = \\ &= (M^t - Q^t) X^t \end{aligned}$$

então

$$\begin{aligned} \text{var}(A^t y - C^t y) &= \text{var}((A^t - C^t) y) = \\ &= (A^t - C^t) V (A - C) \sigma^2 = \\ &= (M^t - Q^t) X^t (I - P_X) (I - ZB) \sigma^2 = \emptyset \end{aligned}$$

e portanto, por a. e b. concluimos que

$$\Lambda^t y = C^t y \text{ com probabilidade } 1$$

Observando com mais detalhes a matriz

$$C = P_X - Z B P_X \text{ onde}$$

$$B \text{ é tal que } Z^t V Z B = Z^t V$$

temos que

$$\begin{aligned} C^2 &= (P_X - Z B P_X)(P_X - Z B P_X) = \\ &= P_X^2 - P_X Z B P_X - Z B P_X^2 + Z B P_X Z B P_X = \\ &= P_X - Z B P_X = C \end{aligned}$$

$$\text{mas, como } C^2 = C \leftrightarrow (C^t)^2 = C^t \tag{3.106}$$

$$\text{e } C^t \text{ é tal que por (3.105)}$$

$$C^t X = X$$

$$\text{e } VC = X Q \text{ para alguma matriz } Q$$

$$\rightarrow C^t X = X \text{ e } Z^t V C = C^t V Z = \emptyset \tag{3.107}$$

então, concluimos por (3.106) e (3.107) que

$C^t y$  é a matriz do operador projeção

sobre  $C(X)$  segundo a direção de vetores de  $C(V Z)$  onde,  $Z$  é uma matriz  $n \times n-r$  tal que  $C(Z) = C(X)^\perp$ .



Deste modo, provamos que

COROLÁRIO 3.5 - Sob a condição do modelo de G.M.G. um BLUE de  $X\beta$  é dado pela projeção  $C^t y$  sobre  $C(X)$  segundo a direção de vetores de  $C(VZ)$  (3.108)

onde 
$$C = P_X - Z B P_X$$

onde  $B$  satisfaz  $Z^t V Z B = Z^t V$

$Z$  é uma matriz  $n \times n - r$  tal que  $C(Z) = C(X)^\perp$

e  $P_X$  é a matriz do operador projeção ortogonal sobre  $C(X)$

PROPRIEDADE 3.4 - Sob as condições do modelo de G.M.G., o BLUE de  $X\beta$  dado por

$C^t y$  onde  $C$  é definida em (3.103) é tal que

$$E(C^t y) = X\beta$$

e 
$$\text{var}(C^t y) = \text{var}(P_X y) - \text{cov}(P_X y, P_X B^t Z^t y) \quad (3.109)$$

$\text{cov}(P_X y, P_X B^t Z^t y)$  é uma matriz positiva e é única para todo  $B$  tal que

$$Z^t V Z B = Z^t V$$

PROVA - Mostrando que  $\text{cov}(P_X y, P_X B^t Z^t y)$  é uma matriz positiva e é única para todo  $B$  tal que  $Z^t V Z B = Z^t V$  temos,

$$\begin{aligned} \text{como } \text{cov}(P_X y, P_X B^t Z^t y) &= \\ &= \sigma^2 P_X V Z B P_X = \sigma^2 P_X (Z^t V Z B)^t B P_X = \\ &= \sigma^2 P_X B^t Z^t V Z B P_X = \text{var}(P_X B^t Z^t y) \end{aligned} \quad (3.110)$$

e sendo a  $\text{var}(P_X B^t Z^t y)$  uma matriz positiva então a

$\text{cov}(P_X y, P_X B^t Z^t y)$  é uma matriz positiva.

e ainda, como

$$Z^t V Z B = Z^t V \quad (3.111)$$

onde  $V = S S^t$  para alguma matriz  $S_{n \times s}$  temos que (3.111) é equivalente ao sistema de equações

$$(S^t Z)^t (S^t Z) B = (S^t Z) S^t \quad (3.112)$$

Observando que (3.112) é um conjunto de  $n$  equações lineares cuja estrutura coincidem com o da equações normais, que é sempre consistente e também, se  $B_1$  e  $B_2$  são duas soluções desse sistema então

$$S^t Z B_1 = S^t Z B_2 \quad \text{temos}$$

$$S^t Z B_1 = S^t Z B_2 \rightarrow V Z B_1 = V Z B_2 \rightarrow$$

$$\rightarrow P_X V Z B_1 = P_X V Z B_2$$

$$\rightarrow P_X V B_1 P_X = P_X V Z B_2 P_X$$

$$\rightarrow \text{cov}(P_X y, P_X B_1^t Z^t y) = \text{cov}(P_X y, P_X B_2^t Z^t y)$$

onde,  $B_1$  e  $B_2$  são duas soluções quaisquer de (3.111).

Mostrando que

$$\text{var}(C^t y) = \text{var}(P_X y) - \text{cov}(P_X y, P_X B^t Z^t y)$$

temos,

como  $C^t y) = P_X y - P_X B^t Z^t y$  então

$$\begin{aligned} \text{var}(C^t y) &= \text{var}(P_X y) - 2 \text{cov}(P_X y, P_X B^t Z^t y) + \\ &+ \text{var}(P_X B^t Z^t y) \end{aligned}$$

e como por (3.110)

$$\text{cov}(P_X y, P_X B^t Z^t y) = \text{var}(P_X B^t Z^t y)$$

então,

$$\text{var}(C^t y) = \text{var}(P_X y) - \text{cov}(P_X y, P_X B^t Z^t y)$$

Assim, sendo o SLSE de  $X\beta$  dado por  $P_X y$  e o BLUE de  $X\beta$  da do por

$$C^t y = P_X y - P_X B^t Z^t y$$

que podemos considerar como

$$P_X y - (\text{perturbação em } Z) \text{ onde } Z \text{ é tal que } C(Z) = C(X)^1$$

notamos que, como

$$\text{cov}(P_X y, P_X B^t Z^t y) = \sigma^2 P_X V Z B P_X \text{ é}$$

única e também positiva

então, existem vetores da forma  $Z B P_X$  em  $C(Z)$  tais que a imagem

desses vetores através de  $V$  são projetados por  $P_X$  em vetores não nulos de  $C(X)$  e ainda, como  $\text{cov}(P_X y, P_X B^t Z^t y) = \text{var}(P_X y) - \text{var}(C^t y)$  é uma matriz positiva temos que realmente o ajustamento de  $P_X y$  por  $P_X B^t Z^t y$  reduz a variância de  $P_X y$ .

Assim, a variância do SLSE de  $X\beta$  com  $V = I_n$  é  $\text{var}(P_X y) = \sigma^2 P_X$  e quando passamos a  $V$  singular o BLUE de  $X\beta$  é dado por  $P_X y - P_X B^t Z^t y$  com a  $\text{var}(P_X y) = \sigma^2 P_X V P_X$  ajustada pela covariância de  $(P_X y, P_X B^t Z^t y)$ .

No teorema 3.1 observamos que sendo  $A = P_X - (I - P_X)U$  onde

$$U = B P_X$$

satisfaz  $(I - P_X) V (I - P_X)U = (I - P_X) V P_X$

então,  $A^t y$  é um BLUE de  $X\beta$  e satisfaz

$$A^t X = X$$

e  $A^t V Z = \emptyset$  onde  $Z$  é tal que  $C(Z) = C(X)$ <sup>1</sup>

Assim, notando que

$$\begin{aligned} A^2 &= (P_X - (I - P_X) B P_X)(P_X - (I - P_X) B P_X) = \\ &= P_X^2 - P_X (I - P_X) B P_X - (I - P_X) B P_X^2 + \\ &+ (I - P_X) B P_X (I - P_X) B P_X = P_X - (I - P_X) B P_X = A \end{aligned}$$

então, temos que  $(A^t)^2 = A^t$  e portanto,

$A^t = P_X - U^t(I - P_X)$  é também uma matriz do operador proje-

ção sobre  $C(X)$  segundo a direção dos vetores de  $C(VZ)$ .

Mas, como o operador projeção sobre  $C(X)$  segundo a direção de vetores de  $C(VZ)$  é único, concluímos que

para todo  $y \in C(V:X) = C(X) \oplus C(VZ)$  então

$$A^t y = C^t y$$

onde  $C = P_X - Z B P_X$

para  $B$  satisfazendo  $Z^t V Z B = Z^t V$

e portanto, temos

COROLÁRIO 3.6 - Sob a condição do modelo de G.M.G. sendo  $P_X$  a matriz do operador projeção ortogonal sobre  $C(X)$

$Z_{n \times n-r}$  uma matriz tal que  $C(Z) = C(X)^1$

então, se

$$A = P_X - (I - P_X)U$$

onde  $U = B P_X$  satisfaz

$$(I - P_X) V (I - P_X)U = (I - P_X) V P_X$$

e  $C = P_X - Z B P_X$

onde  $B$  satisfaz  $Z^t V Z B = Z^t V$

temos que  $A^t y = C^t y =$  projeção de  $y$  em  $C(X)$  segundo a direção de vetores de  $C(VZ)$

e ainda

$$A^t y = C^t y \text{ é um BLUE de } X\beta.$$

COROLÁRIO 3.7 - Se no modelo linear  $y = X\beta + e$  temos que

$$E(e e^t) = \sigma^2 I_n$$

então, o BLUE de  $X\beta$  é dado por

$$P_X y = \text{projeção ortogonal de } y \text{ em } C(X)$$

PROVA - Sendo, o BLUE de  $X\beta$  dado por

$$A^t y = P_X y - U^t (I - P_X) y = \text{projeção de } y \text{ em } C(X)$$

segundo a direção de vetores de  $C(VZ)$  onde  $U$  é tal que

$$(I - P_X) V (I - P_X) U = (I - P_X) V P_X$$

então, para  $V = I$  temos,

$$\begin{aligned} (I - P_X) V (I - P_X) U &= (I - P_X)^2 U = (I - P_X) U = \\ &= (I - P_X) P_X = \emptyset \end{aligned}$$

assim,  $A^t y = P_X y = \text{projeção ortogonal de } y \text{ sobre } C(X)$ .

COROLÁRIO 3.8 - Se no modelo linear  $y = X\beta + e$  temos que

$V$  é não singular

então, o BLUE de  $X\beta$  é dado por

$$A^t y = M^t X^t V^{-1} y \quad \text{onde } M \text{ é tal que } X^t V^{-1} X M = X^t$$

e

$A^t y = \text{projeção de } y \text{ sobre } C(X) \text{ segundo a direção de vetores de } C(VZ)$ .

PROVA - como o BLUE de  $X\beta$  é dado por

$A^t y = P_X y - U^t (I - P_X) y =$  projeção de  $y$  sobre  $C(X)$  segundo a direção dos vetores de  $C(VZ)$

onde  $(I - P_X) V (I - P_X) U = (I - P_X) V P_X$

então, se  $V$  é não singular temos

$$(I - P_X) V (I - P_X) U = (I - P_X) V P_X \quad \leftrightarrow$$

$$\leftrightarrow (I - P_X) [V(I - P_X)U - VP_X] = \emptyset \quad \leftrightarrow$$

$$V(I - P_X)U - VP_X = -XM \text{ para alguma matriz } M_{p \times n}$$

$$\leftrightarrow V(I - P_X)U = VP_X - XM \quad \leftrightarrow$$

$$(I - P_X)U = P_X - V^{-1} XM$$

e ainda,

$$X^t P_X - (X^t V^{-1} X)M = X^t - (X^t V^{-1} X)M = X^t (I - P_X)U$$

$$\rightarrow X^t - (X^t V^{-1} X)M = \emptyset \rightarrow (X^t V^{-1} X)M = X^t$$

ou seja, o BLUE de  $X\beta$  é dado por

$$A^t y = P_X y - P_X y + M^t X^t V^{-1} y = M^t X^t V^{-1} y =$$

= projeção de  $y$  em  $C(X)$  segundo a direção de vetores de  $C(VZ)$

onde  $M$  é tal que  $(X^t V^{-1} X)M = X^t$ .

CAPITULO 4  
ESTRUTURA DE COVARIÂNCIA DE  
EXPERIMENTOS ALEATORIZADOS

Com a finalidade de exemplificar a teoria exposta do Modelo Linear Geral, utilizaremos como base a idéia dos experimentos aleatorizados proposta por Fisher (1935) e amplamente estudada por Kempthorne e colaboradores (1961). A motivação é termos possibilidade de evitar o grande número de pressuposições que o modelo infinito exige, ou seja, normalidade, independência, homogeneidade de variância e a imposição do modelo que os dados deverão obedecer. Nesse sentido é que os modelos lineares obtidos em experimentos aleatorizados são ditos derivados, ou seja, não são impostos mas sim obtidos com uma base física estrutural.

Com os exemplos que estudaremos atenderemos a dois objetivos, sendo um deles, uma estrutura de covariância que permite nos obter estimadores ótimos (BLUE) através da solução simples do mínimos quadrados (exemplo do teorema 1, Zyskind (1967), e teorema (4.1) Rao (1973) o outro sendo que os experimentos aleatorizados oferece-nos uma classe de modelos lineares em que a estrutura de covariância é do tipo



$$\sigma^2 V = aI + bJ \quad \text{onde,}$$

$$J = [1] [1]^t$$

([1] representa um vetor cujas coordenadas são iguais a um) ,

e, em alguns casos esta estrutura oferece matrizes singulares.

#### EXEMPLO 1 -

Uma ilustração primitiva de uma estrutura de covariância diferente de  $\sigma^2 I$  é a que ocorre na retirada de uma amostra casual simples de tamanho  $n$  sem reposição de uma população finita de tamanho  $N$ .

Definindo a variável aleatória  $\delta_i^j$  para relacionarmos os elementos amostrais onde,

$$\delta_i^j = \begin{cases} 1 & \text{se a resposta do } j\text{-ésimo elemento da} \\ & \text{população corresponde a } i\text{-ésima obser} \\ & \text{vação amostral} \\ 0 & \text{caso contrário} \end{cases}$$

para  $i=1, \dots, n$  e  $j=1, \dots, N$

temos que as propriedades de  $\delta_i^j$  as quais são necessárias para o nosso propósito são: -

$$1 - \text{prob} (\delta_i^j = 1) = \frac{1}{N} \quad \text{para todo } i=1, \dots, n \\ j=1, \dots, N$$

2 - dado que  $\delta_i^j = 1$  então

$$\text{prob}(\delta_i^{j'} = 1) = 0 \text{ para todo } j' \neq j \quad (4.2)$$

e

$$\text{prob}(\delta_{i'}^j = 1) = 0 \text{ para todo } i' \neq i \quad (4.3)$$

3 - dado que  $\delta_i^j = 1$  então

$$\text{prob}(\delta_{i'}^{j'} = 1) = \frac{1}{N-1} \text{ para todo } i' \neq i \text{ e } j' \neq j \quad (4.4)$$

$$4 - \sum_{j=1}^N \delta_i^j = 1 = \sum_{i=1}^N \delta_i^j \quad (4.5)$$

e portanto,

$$E(\delta_i^j) = E\left[(\delta_i^j)^2\right] = \text{prob}(\delta_i^j = 1) = \frac{1}{N} \quad (4.6)$$

para todo  $i=1, \dots, n$

$j=1, \dots, N$

$$\begin{aligned} E(\delta_i^j \delta_i^{j'}) &= \text{prob}(\delta_i^j \delta_i^{j'} = 1) = \\ &= \text{prob}(\delta_i^{j'} = 1 / \delta_i^j = 1) \text{prob}(\delta_i^j = 1) = \\ &\hspace{15em} (\text{por 4.2}) \end{aligned}$$

$$= 0 \text{ para todo } j' \neq j \quad (4.7)$$

analogamente

por (4.3)

$$E (\delta_i^j \delta_{i'}^{j'}) = 0 \quad (4.8)$$

para todo  $i' \neq i$

por (4.4)

$$E (\delta_i^j \delta_{i'}^{j'}) = \frac{1}{N(N-1)} \quad (4.9)$$

para todo  $i' \neq i$  e  $j' \neq j$

Assim, se

$L_j$  representa a resposta do  $j$ -ésimo elemento da população  
 $j = 1, \dots, N$   
e

$y_i$  representa a resposta da  $i$ -ésima observação amostral,  
 $i=1, \dots, n$   
e denotando por

$$u = \frac{1}{N} \sum_{j=1}^N L_j \quad (\text{média populacional})$$

$$\sigma^2 = \frac{1}{N} \sum_{j=1}^N (L_j - u)^2 \quad (\text{variância populacional})$$

temos que, quando não há erro de medida então,

$$Y_i = \sum_{j=1}^N \delta_i^j L_j \quad (4.10)$$

e como, vale a identidade

$$L_j = u + (L_j - u) \quad (4.11)$$

temos:

Substituindo (4.11) em (4.10) e usando (4.5)

$$y_i = \sum_{j=1}^N \delta_i^j (u + (L_j - u)) = u + \sum_{j=1}^N \delta_i^j (L_j - u)$$

ou seja,

$$y_i = u + e_i \quad \text{para } i=1, \dots, n \quad (4.12)$$

onde

$$e_i = \sum_{j=1}^N \delta_i^j (L_j - u) \text{ representa o}$$

erro aleatório e, é tal que para todo  $i=1, \dots, n$

$$\begin{aligned} E(e_i) &= \sum_{j=1}^N (L_j - u) E(\delta_i^j) = \text{por (4.6)} = \\ &= \frac{1}{N} \sum_{j=1}^N (L_j - u) = 0 \end{aligned} \quad (4.13)$$

$$\begin{aligned} \text{var}(e_i) &= E(e_i^2) = E \left[ \left( \sum_{j=1}^N (L_j - u) \delta_i^j \right)^2 \right] \\ &= \sum_{j=1}^N \sum_{j'=1}^N (L_j - u) (L_{j'} - u) E(\delta_i^j \delta_i^{j'}) = \\ &= (\text{por (4.7)}) = \sum_{j=1}^N (L_j - u)^2 E \left[ (\delta_i^j)^2 \right] = \end{aligned}$$

$$= (\text{por (4.6)}) = \frac{1}{N} \sum_{j=1}^N (L_j - u)^2 = \sigma^2 \quad (4.14)$$

e para todo  $i' \neq i$

$$\begin{aligned} \text{cov}(e_i, e_{i'}) &= E(e_i e_{i'}) = \\ &= E \left| \left( \sum_{j=1}^N \delta_i^j (L_j - u) \right) \left( \sum_{j'=1}^N \delta_{i'}^{j'} (L_{j'} - u) \right) \right| = \end{aligned}$$

$$= \sum_{j=1}^N \sum_{j'=1}^N (L_j - u) (L_{j'} - u) E(\delta_i^j \delta_{i'}^{j'}) =$$

$$\begin{aligned} = \text{por (4.8)} &= \sum_{\substack{j, j' \\ j' \neq i}} (L_j - u) (L_{j'} - u) E(\delta_i^j \delta_{i'}^{j'}) = \end{aligned}$$

$$= \text{por (4.9)} = \frac{1}{N(N-1)} \sum_{\substack{j, j' \\ j' \neq j}} (L_j - u) (L_{j'} - u) =$$

$$= - \frac{1}{N(N-1)} \sum_{j=1}^N (L_j - u)^2 + \frac{N}{N-1} \left( \frac{1}{N} \sum_{j=1}^N (L_j - u) \right)^2 =$$

$$= - \frac{1}{N(N-1)} \sum_{j=1}^N (L_j - u)^2 = - \frac{\sigma^2}{N-1} = \sigma^2 \rho \quad \text{onde}$$

$$\rho = - \frac{1}{N-1} \quad (4.15)$$

Em notação matricial, com

$$y^t = (y_1: \dots : y_n)$$

$$e^t = (e_1: \dots : e_n)$$

temos o modelo linear

$$y = [1] u + e \quad \text{onde}$$

$X = [1]$  representa um vetor  $n \times 1$  cujas coordenadas são todas iguais a um

e,

$$E(e) = \emptyset \quad (\text{usando (4.13)})$$

$$E(e e^t) = \sigma^2 V$$

Sendo  $V = \begin{vmatrix} 1 & \rho & \dots & \rho \\ \rho & 1 & \dots & \rho \\ \vdots & \vdots & \ddots & \vdots \\ \rho & \rho & \dots & 1 \end{vmatrix}$  uma matriz  $n \times n$  de posto  $n$   
(por (4.14) e (4.15))

Observando que

$$V = (1 - \rho) I_n + \rho [1] [1]^t \quad \text{onde } (\rho = -\frac{1}{N-1})$$

e é tal que o vetor  $[1]$  é um auto vetor de  $V$  então, segue que como

$$X = \begin{bmatrix} 1 \end{bmatrix}$$

o S L S E

$$\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i = \frac{1}{n} \left( \begin{bmatrix} 1 \end{bmatrix}^t y \right) \text{ de u}$$

é também o seu BLUE (Zyskind (1967))

onde,

$$\text{var} (\bar{y}) = \frac{N-n}{n-1} \frac{\sigma^2}{n} .$$

De uma forma geral, sempre que a matriz V for da forma

$$V = a I + j b J$$

e a matriz  $X_{n \times p}$  for da forma

$$X = \left( \begin{bmatrix} 1 \end{bmatrix} : \psi \right) \text{ onde}$$

$\psi$  é uma matriz  $n \times (p-1)$

podemos tomar, as matrizes

$$T_1 = b \begin{vmatrix} 1 & \emptyset \\ \emptyset & \emptyset \end{vmatrix}$$

$$T_2 = \emptyset \text{ (matriz nula)}$$

nxn

e

$$K^2 = a \text{ (constante real positiva)}$$

e satisfazem

$$V = K^2 I + X T_1 X^t + (I - P_x) T_2 (I - P_x)$$

que é a condição de Zyskind (1967) e Rao para que o S L S E  $\equiv$  BLUE (4.16)

### EXEMPLO 2 - Planejamento Completamente Casualizado

Admitamos que temos N unidades experimentais as quais aplicaremos aleatoriamente t tratamentos com a condição única que queremos r réplicas de cada tratamento, ou seja,  $N = rt$ .

Denotando a j-ésima réplica do i-ésimo tratamento pelo par  $(i,j)$ ,  $i=1, \dots, t$  e  $j=1, \dots, r$ , então, cada par  $(i,j)$  será aplicado aleatoriamente às unidades experimentais.

A cada possível combinação tratamento e unidade experimental temos uma resposta conceitual  $L_{ik}$ ,  $i=1, \dots, t$ ,  $k=1, \dots, N$ . Ou seja,

$L_{ik}$  é igual a resposta da

k-ésima unidade experimental ao i-ésimo tratamento.

Definindo-se a variável aleatória  $\delta_{ij}^k$  para relacionarmos os resultados experimentais com as respostas conceituais  $L_{ik}$  onde

$$\delta_{ij}^k = \begin{cases} 1 & \text{se a } j\text{-ésima réplica do } i\text{-ésimo tratamento está aplicado na } k\text{-ésima unidade experimental} \\ 0 & \text{caso contrário} \end{cases}$$



para  $i=1, \dots, t, j=1, \dots, r$  e  $k=1, \dots, N$

temos então  $N \cdot t \cdot r = N^2$  dessas variáveis aleatórias, cujas propriedades as quais são necessárias para o nosso propósito são:-

$$1 - \text{prob} (\delta_{ij}^k = 1) = \frac{1}{N}$$

$$\text{para todo } i=1, \dots, t, j=1, \dots, r, k=1, \dots, N \quad (4.17)$$

$$2 - \text{dado que } \delta_{ij}^k = 1 \text{ então}$$

$$\text{prob} (\delta_{i',j'}^k = 1) = 0 \text{ para todo } (i', j') \neq (i, j) \quad (4.18)$$

$$\text{prob} (\delta_{ij}^{k'} = 1) = 0 \text{ para todo } k' \neq k \quad (4.19)$$

$$3 - \text{dado que } \delta_{ij}^k = 1 \text{ então}$$

$$\text{prob} (\delta_{i',j'}^{k'}) = \frac{1}{N-1} \text{ para todo } (i', j') \neq (i, j) \text{ e } k' \neq k \quad (4.20)$$

$$4 - \sum_{k=1}^N \delta_{ij}^k = 1 = \sum_{i=1}^t \sum_{j=1}^r \delta_{ij}^k \quad (4.21)$$

e portanto,

$$E(\delta_{ij}^k) = E(\delta_{ij}^k)^2 = \text{prob}(\delta_{ij}^k = 1) = (\text{por}(4.17)) = \frac{1}{N}$$

$$\text{para todo } i=1, \dots, t, j=1, \dots, r, k=1, \dots, N \quad (4.22)$$

$$\begin{aligned} E(\delta_{ij}^k \delta_{i',j'}^k) &= \text{prob} (\delta_{ij}^k \delta_{i',j'}^k = 1) = \\ &= \text{prob} (\delta_{i',j'}^k = 1 / \delta_{ij}^k = 1) \cdot \text{prob} (\delta_{ij}^k = 1) = \\ &= (\text{por (4.18)}) = 0 \text{ para todo } (i', j') \neq (i, j) \end{aligned} \quad (4.23)$$

analogamente

$$\text{por (4.19)) } E(\delta_{ij}^k \delta_{ij}^{k'}) = 0 \text{ para todo } k' \neq k \quad (4.24)$$

$$\text{por (4.20)) } E(\delta_{ij}^k \delta_{i',j'}^{k'}) = \frac{1}{N(N-1)}$$

para todo  $(i', j') \neq (i, j)$

e

$k' \neq k$

(4.25)

Considerando agora

$L_{..}$  a média sobre o experimento total

$$L_{..} = \frac{1}{Nt} \sum_i \sum_k L_{ik}$$

$L_{i.}$  a média das respostas do  $i$ -ésimo tratamento

$$L_{i.} = \frac{1}{N} \sum_k L_{ik}$$

$L_{.k}$  a média das respostas da  $k$ -ésima unidade experimental

$$L_{.k} = \frac{1}{t} \sum_i L_{ik}$$

temos, a seguinte decomposição, proposta fisicamente, das respostas conceituais

$$\begin{aligned} L_{ik} = & L_{..} + (L_{i.} - L_{..}) + (L_{.k} - L_{..}) + \\ & + (L_{ik} - L_{i.} - L_{.k} + L_{..}) \end{aligned} \quad (4.26)$$

onde

$L_{i.} - L_{..}$  representa o desvio de  $L_{i.}$  com relação à  $L_{..}$  ou seja, o efeito do  $i$ -ésimo tratamento

$L_{.k} - L_{..}$  representa o desvio de  $L_{.k}$  com relação à  $L_{..}$  ou seja, o efeito da  $k$ -ésima unidade experimental e

$$L_{ik} - L_{i.} - L_{.k} + L_{..} =$$

$$= (L_{ik} - L_{..}) - (L_{i.} - L_{..}) + (L_{.k} - L_{..})$$

representa o efeito de interação do  $i$ -ésimo tratamento e da  $k$ -ésima unidade experimental

Supondo, que os efeitos das unidades experimentais e tratamentos são aditivos temos então que, a resposta do  $i$ -ésimo tratamento independe da unidade experimental ou seja,

$$L_{ik} - L_{i.} - L_{.k} + L_{..} = 0$$

e como consequência dessa suposição obtemos que a identidade (4.26) torna-se

$$\begin{aligned} L_{ik} &= L_{..} + (L_{i.} - L_{..}) + (L_{.k} - L_{..}) = \\ &= u + t_i + e_k \end{aligned} \tag{4.27}$$

onde  $u = L_{..}$

$$t_i = L_{i.} - L_{..}$$

$$e_k = L_{.k} - L_{..}$$

Assim, se

$y_{ij}$  representa a observação da  $j$ -ésima réplica do  $i$ -ésimo tratamento então

$$y_{ij} = \sum_{k=1}^N \delta_{ij}^k L_{ik} \tag{4.28}$$

que são variáveis aleatórias obtidas como combinação linear das variáveis aleatórias amostrais  $\delta_{ij}^k$ .

Substituindo a identidade populacional (4.27) na identidade das observações (4.28)

temos que

$$y_{ij} = \sum_{k=1}^N \delta_{ij}^k L_{ik} = u + t_i + \sum_{k=1}^N \delta_{ij}^k e_k$$

ou seja,

tomando  $e_{ij} = \sum_{k=1}^N \delta_{ij}^k e_k$  que representa o erro aleatório da  $i$ -ésima observação na  $j$ -ésima réplica

então

$$y_{ij} = u + t_i + e_{ij} \quad \text{para } i=1, \dots, t \\ j=1, \dots, r$$

onde

$$\sum_{i=1}^t t_i = 0$$

$$\sum_i \sum_j e_{ij} = \sum_k e_k = 0$$

e  $e_{ij}$  para todo  $(i=1, \dots, t, j=1, \dots, r)$  é tal que

por (4.22)

$$E(e_{ij}) = E\left(\sum_{k=1}^N \delta_{ij}^k e_k\right) = \sum_{k=1}^N e_k E(\delta_{ij}^k) = \\ = \frac{1}{N} \sum_{k=1}^N e_k = 0 \quad (4.29)$$

$$\text{var}(e_{ij}) = E\left[(e_{ij})^2\right] = E\left[\left(\sum_{k=1}^N \delta_{ij}^k e_k\right)^2\right] = \\ = \sum_k \sum_{k'} e_k e_{k'} E(\delta_{ij}^k \delta_{ij}^{k'}) = (\text{por (4.24)}) = \\ = \sum_{k=1}^N e_k^2 E\left[(\delta_{ij}^k)^2\right] = \text{por (4.22)} = \frac{1}{N} \sum_k c_k^2 = \sigma^2 \quad (4.30)$$

e para todo par  $(i', j')$  tal que  $(i', j') \neq (i, j)$

$$\begin{aligned}
 \text{cov} (e_{ij}, e_{i',j'}) &= E \left( \left( \sum_{k=1}^N \delta_{ij}^k e_k \right) \left( \sum_{k'=1}^N \delta_{i'j'}^{k'} e_{k'} \right) \right) = \\
 &= \sum_{k=1}^N \sum_{k'=1}^N e_k e_{k'} E(\delta_{ij}^k \delta_{i'j'}^{k'}) = \text{(por (4.23))} \\
 &= \sum_{\substack{k,k' \\ k \neq k'}} e_k e_{k'} E(\delta_{ij}^k \delta_{i'j'}^{k'}) = \text{(por (4.25))} = \\
 &= \frac{1}{N(N-1)} \sum_{\substack{k,k' \\ k \neq k'}} e_k e_{k'} = - \frac{1}{N(N-1)} \sum_k e_k^2 + \left( \sum_k e_k \right) \left( \sum_{k'} e_{k'} \right) = \\
 &= - \frac{1}{N(N-1)} \sum_k e_k^2 = - \frac{\sigma^2}{N-1} = \sigma^2 \rho \quad \text{onde } \rho = - \frac{1}{N-1}
 \end{aligned}$$

(4.31)

Em notação matricial com

$$y^t = (y_{11} : \dots : y_{1r} : \dots : y_{t1} : \dots : y_{tr})$$

e

$$e = (e_{11} : \dots : e_{1r} : \dots : e_{t1} : \dots : e_{tr})$$

o modelo derivado para o planejamento completamente casualizado é portanto um modelo linear dado por

$$y = X\beta + e$$

com

$$\beta^t = (u: t_1: \dots: t_t)$$

$$X = \left( \begin{array}{c} [1] \\ \psi \end{array} \right) \quad \text{uma matriz } M \times t+1 \text{ de posto } t$$

sendo  $[1]$  um vetor  $N \times 1$  cujas coordenadas são todas iguais a um

e

$$\psi = \begin{vmatrix} x(1) & \emptyset & \dots & \emptyset \\ \emptyset & x(2) & \dots & \emptyset \\ \emptyset & \emptyset & \dots & x(t) \end{vmatrix}$$

onde cada  $x_{(i)}$ ,  $i=1, \dots, t$ , representa um vetor  $r \times 1$  cujas coordenadas são todas iguais a um

e  $\emptyset$  representa um vetor  $r \times s$  nulo.

e,

(por, (4.29))

$$E(e) = \emptyset$$

(por (4.30) e (4.31))

$$E(e e^t) = \sigma^2 V$$

Sendo  $V = \begin{vmatrix} 1 & \rho & \dots & \rho \\ \rho & 1 & & \rho \\ \vdots & \vdots & & \vdots \\ \rho & \rho & & 1 \end{vmatrix}$  uma matriz  $N \times N$  de posto  $N-1$

Observando que as matrizes  $X$  e  $V$  do modelo linear derivado do Planejamento Casualizado são semelhantes ao caso deduzido em (4.16) com, a restrição de que  $V$  é singular então, temos que

$$V = \begin{vmatrix} 1 & \rho & \dots & \rho \\ \rho & 1 & \dots & \rho \\ \vdots & \vdots & & \vdots \\ \rho & \rho & \dots & 1 \end{vmatrix} = (1 - \rho) I_N + \rho \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \begin{pmatrix} 1 & \dots & 1 \end{pmatrix} =$$

$$= X T_1 X^t + (I - P_X) T_2 (I - P_X) + K^2 I$$

onde  $T_2$  é uma matriz nula  $N \times N$

$$K^2 = (1 - \rho) = \frac{N}{N-1} \in R$$

$$T_1 = \rho \begin{vmatrix} 1 & \emptyset \\ \emptyset & \emptyset \end{vmatrix} \text{ é uma matriz } (t+1) \times (t+1)$$

Assim, para obtermos o BLUE de uma função paramétrica linearmente estimável no modelo linear derivado de Planejamento Completamente Casualizado é suficiente trabalharmos com o modelo linear cujas hipóteses são as do Modelo Linear de Gauss-Markoff ou seja,

$$E(e) = \emptyset$$

$$E(e e^t) = \sigma^2 I$$



## B I B L I O G R A F I A

- AITKEN; A.C. 1935. On least squares and linear combination of observations. *Proceedings of the Royal Society of Edinburgh, Section A*, 55:42-47.
- FISHER, R.A. 1966. *The design of experiments*. Edinburg, Oliver & Boyd. 248p.
- GAUSS, C.F. 1855. *Methode des Moindres Carres*. (Trans. J. Bertrand)
- GOLDMAN, A.J. & ZELEN, M. 1964. Weak generalized inverses and minimum variance linear unbiased estimation. *Journal of Research of the National Bureau of Standards, Section B*, 68B:151-172.
- HALMOS, P.R. 1978. *Espaços vetoriais de dimensão finita*. Rio de Janeiro, Campus. 199p.
- HOFFMAN, K. & KUNZE, R. 1979. *Algebra linear*. 2.ed. Rio de Janeiro, Livros Técnicos e Científicos. 514p.
- KEMPTHORNE, O. 1952. *The design and analysis of experiments* New York, John Wiley. 631p.
- KEMPTHORNE, O. 1976. *Best linear unbiased estimation with arbitrary variance matrix*. (Unpublished mimeographed notes)

- KEMPTHORNE, O. et alii. 1961. *Analysis of variance procedures*. Ohio, Patterson Air Force Base. (Aeronautical Research Laboratory. Technical Report, 149)
- KRUSKAL, W. 1975. The geometry of generalized inverses. *Journal of the Royal Statistical Society, Series B*, 37(2): 272-283.
- MARKOFF, A.A. 1912. *Warscheinlichkeitsrechnung*. 2.ed. Leipzig, s.c.p. (Trans. H. Liebmann)
- MONTEIRO, L.H.J. 1969. *Algebra linear*. 5.ed. São Paulo, Nobel. v.1
- RAO, C.R. 1965. *Linear statistical inference and its applications*. New York, John Wiley. 522p. (Wiley Series in Probability and Mathematical Statistics)
- RAO, C.R. 1967. Least squares theory using an estimated dispersion matrix and its application to measurement of signals. In: BERKELEY SYMPOSIUM ON MATHEMATICAL STATISTICS AND PROBABILITY, 5., Berkeley, 1965. *Proceedings*. Berkeley, University of California Press, 1967. v.1,p.355-372.
- RAO, C.R. 1971. Unified theory of linear estimation. *Sankhyā, Series A*, 33(4):371-394.
- RAO, C.R. 1972. Some recent results in linear estimation. *Sankhyā, Series B*, 34(4):369-378.
- RAO, C.R. 1973a. Representations of best linear unbiased estimators in the Gaus-Markoff model with a singular dispersion matrix. *Journal of Multivariate Analysis*, 3(1):276-292.

- RAO, C.R. 1973b. Unified theory of least squares. *Communications in Statistics*, 1(1):1-8.
- RAO, C.R. 1975. On a unified theory of estimation in linear models a review of recent results. In: GANI, J., ed. *Perspectives in probability and statistics*. London, Academic Press. p.89-104.
- RAO, C.R. 1978. A note on the unified theory of least squares. *Communications in Statistics-Theory and Methods*, A7(5):409-411.
- RAO, C.R. & MITRA, S. 1971. *Generalized inverse of matrices and its applications*. New York, John Wiley. 240p. (Wiley Series in Probability and Mathematical Statistics)
- SCHEFFE, H. 1959. *The analysis of variance*. 477p.
- ZYSKIND, G. 1967. On canonical forms, non-negative covariance matrices and best and simple least squares linear estimators in linear models. *Annals of Mathematical Statistics*, 38(4):1092-1109.
- ZYSKIND, G. et alii. 1964. *Research on analysis of variance and related topics*. Ohio, Patterson Air Force Base. (Aerospace Research Laboratories. Technical Report, 64-193)
- ZYSKIND, G. & MARTIN, F.B. 1969. On best linear estimation and a general Gauss-Markov theorem in linear models with arbitrary nonnegative covariance structure. *SIAM Journal on Applied Mathematics*, 17(6):1190-1202.