

**RT-MAE 9416**

***PREVISÃO DO VETOR DE ELEMENTOS NÃO  
OBSERVADOS NUMA POPULAÇÃO FINITA***

**by**

**Silvia Nagib Elian**

**Palavras Chaves:** População Finita; Modelos de Superpopulação; Previsores Ótimos;  
Robustez.

**Classificação AMS:** 62D05  
(AMS Classification)

PREVISÃO DO VETOR DE ELEMENTOS NÃO OBSERVADOS NUMA  
POPULAÇÃO FINITA

Silvia Nagib Elian

Instituto de Matemática e Estatística

Universidade de São Paulo

C.P. 20570

01452-990 - São Paulo - SP - Brasil

Resumo

Neste trabalho, determinamos o previsor ótimo do vetor que contém os valores da variável de interesse  $Y$  para os  $N-n$  elementos populacionais não observados na amostra, sob a abordagem de modelos de superpopulação. Será obtido o previsor ótimo no modelo  $\underline{Y} = N_N(X\beta, V)$  e o previsor linear ótimo no modelo  $\underline{Y} = X\beta + \underline{\varepsilon}$ , com  $E(\underline{\varepsilon})=0$  e  $\text{Var}(\underline{\varepsilon})=V$ ,  $V$  conhecida, não diagonal. Apresentamos uma condição necessária e suficiente para que o previsor sofra uma razoável simplificação e alguns aspectos sobre robustez são abordados.

## 1. INTRODUÇÃO

Seja  $P = \{1, 2, \dots, N\}$  uma população finita de  $N$  elementos, onde ao  $i$ -ésimo elemento estão associados  $y_i, x_{i1}, x_{i2}, \dots, x_{ip}$ , sendo que  $y_i$  é o valor da variável de interesse  $Y$  e  $x_{i1}, x_{i2}, \dots, x_{ip}$  são os valores de  $p$  variáveis auxiliares, não aleatórias e completamente conhecidos para  $i = 1, 2, \dots, N$ .

Utilizando a abordagem de modelos de superpopulação, admitiremos que  $\gamma = (y_1, y_2, \dots, y_N)'$  é um vetor aleatório tal que

$$\gamma = X\beta + \varepsilon, \quad (1)$$

onde

$$X = \begin{bmatrix} 1 & x_{11} & \dots & x_{1p} \\ 1 & x_{21} & & x_{2p} \\ \vdots & & & \\ 1 & x_{N1} & \dots & x_{Np} \end{bmatrix}$$

$\beta = (\beta_0, \beta_1, \dots, \beta_p)'$  é um vetor de parâmetros desconhecidos,

e

$$E(\varepsilon) = 0, \quad \text{Var}(\varepsilon) = \text{Var}(\gamma) = V,$$

$V$  matriz conhecida, não diagonal.

Tomada uma amostra de  $n$  elementos, reordenaremos os elementos de  $\gamma$ ,  $X$  e  $V$ , de modo que

$$\gamma_s = \begin{pmatrix} y_s \\ y_r \end{pmatrix}, \quad X_s = \begin{pmatrix} X_s \\ X_r \end{pmatrix} \quad \text{e} \quad V = \begin{pmatrix} V_s & V_{sr} \\ V_{rs} & V_r \end{pmatrix},$$

com  $\gamma_s$  contendo os valores da variável  $Y$  associados aos  $n$

elementos amostrados,  $y_s$  sendo o vetor de dimensão  $N-n$  de elementos não observados,  $V_s = \text{Var}(y_s)$ ,  $V_r = \text{Var}(y_r)$  e  $V_{sr} = \text{Cov}(y_s, y_r)$ .

O problema da previsão de quantidades desconhecidas numa população finita sob a abordagem de modelos de superpopulação tem sido abordado em vários artigos.

Royall(1976) obtém o previsor linear ótimo do total populacional  $T = \sum_{i=1}^N y_i$ , sob o modelo (1). Com a suposição adicional de normalidade para  $y$ , Tam(1987) mostra que o mesmo previsor é ótimo para o total.

Também nesta linha, Bolfarine et al. (1994) derivam o previsor ótimo e linear ótimo de

$$\underline{B}_N = (X'V^{-1}X)^{-1}X'V^{-1}y,$$

o coeficiente de regressão populacional.

Ambas as quantidades,  $T$  e  $\underline{B}_N$  podem ser escritas respectivamente como

$$T = \underline{l}'_n y_s + \underline{l}'_{N-n} y_r$$

e

$$\underline{B}_N = H^{-1}BC^{-1}y_s + H^{-1}DE^{-1}y_r,$$

onde  $\underline{l}'_n$  e  $\underline{l}'_{N-n}$  são os vetores linha respectivamente de dimensão  $n$  e  $N-n$  contendo 1 em todas as posições,

$$B = X'_s - X'_r V_r^{-1} V_{rs},$$

$$C = V_s - V_{sr} V_r^{-1} V_{rs},$$

$$D = X_r' - X_s' V_s^{-1} V_{sr}, \quad E = V_r - V_{rs} V_s^{-1} V_{sr} \quad e$$

$$H = BC^{-1} X_s + DE^{-1} X_r = X' V^{-1} X$$

são matrizes não aleatórias, conhecidas.

Os previsores ótimos (ou lineares ótimos) de  $T$  e  $B_N$  são dados por

$$\hat{T} = l_n' Y_s + l_{N-n}' [V_{rs} V_s^{-1} Y_s + (X_r - V_{rs} V_s^{-1} X_s) \hat{\beta}]$$

e

$$\hat{\beta} = H^{-1} BC^{-1} Y_s + H^{-1} DE^{-1} [V_{rs} V_s^{-1} Y_s + (X_r - V_{rs} V_s^{-1} X_s) \hat{\beta}].$$

No caso da previsão de  $B_N$ , Bolfarine et al (1994) verificam adicionalmente que  $\hat{\epsilon} = \hat{\beta} = (X_s' V_s^{-1} X_s)^{-1} X_s' V_s^{-1} Y_s$ , o previsor de mínimos quadrados generalizados. Na previsão de  $T$ , Bolfarine e Rodrigues (1988) mostram que uma simplificação na expressão matemática de  $\hat{T}$  só ocorre sob condições especiais. Em ambos os casos, no entanto, notamos que o vetor de dados não observados  $y_r$  é previsto por

$$\hat{y}_r^* = V_{rs} V_s^{-1} Y_s + (X_r - V_{rs} V_s^{-1} X_s) \hat{\beta}. \quad (2)$$

Utilizando funções de verossimilhança preditivas, Rodrigues e Elian (1993) mostram que  $\hat{y}_r^*$  é o previsor de máxima verossimilhança de  $y_r$  quando o modelo de superpopulação é  $Y \sim N_N(X\beta, V)$ .

Neste artigo, estudamos outras propriedades de  $\hat{y}_r^*$  como previsor do vetor de dados não observados  $y_r$ .

Na seção 2, provamos a otimalidade do previsor e de qualquer combinação linear de seus componentes e obtemos sua matriz de covariância quando o modelo de superpopulação é  $y = N_n(X\beta, V)$ ,  $V$  não diagonal, conhecida. Abandonando a suposição de normalidade, provamos na seção 3 que o mesmo previsor é linear ótimo para  $y_r$  no modelo  $y = X\beta + \varepsilon$ , com as suposições  $E(\varepsilon) = 0$  e  $Var(\varepsilon) = V$ .

Na seção 4, estabelecemos uma condição necessária e suficiente para que  $\hat{y}_r^*$  sofra uma considerável simplificação. Finalmente, na seção 5, alguns aspectos sobre a robustez do previsor simplificado são apresentadas.

## 2. PREVISÃO ÓTIMA DE $y_r$ SOB NORMALIDADE

Na previsão de  $y_r$ , quantidade  $(N-n)$ -dimensional, utilizaremos o erro quadrático médio generalizado, definido a seguir, como medida de precisão.

Definição 2.1 Se  $\hat{y}_r$  é um previsor qualquer de  $y_r$ , o erro quadrático médio generalizado de  $\hat{y}_r$  é definido como

$$EQMG(\hat{y}_r) = \lambda' E[(\hat{y}_r - y_r)(\hat{y}_r - y_r)']\lambda,$$

para cada vetor  $(N-n)$ -dimensional  $\lambda$ ,  $\lambda \neq 0$ .

Definição 2.2 O vetor  $(N-n)$ -dimensional  $\hat{y}_r^*$  é o melhor previsor não viciado de  $y_r$ , ou é o previsor ótimo de  $y_r$ , se for não viciado, isto é,  $E(\hat{y}_r^* - y_r) = 0$  e se para todo  $\lambda \in \mathbb{R}^{N-n}$ ,

$$EQMG(\hat{y}_r^*) \leq EQMG(\hat{y}_r),$$

qualquer que seja o previsor  $\hat{y}_r$  não viciado para  $y_r$ .

Definindo o critério de otimalidade, provaremos que  $\hat{y}_r^*$  dado na expressão (2) é o previsor ótimo de  $y_r$  no modelo em que

$$y \sim N_N(X\beta, V), \text{ com } V = \text{Var}(y) = \begin{bmatrix} V_s & V_{sr} \\ V_{rs} & V_r \end{bmatrix}, \text{ conhecida.}$$

Lema 2.1 Se  $\hat{y}_r$  é um previsor de  $y_r$ , então, para todo  $\lambda \in \mathbb{R}^{N-n}$ ,

$$E(\lambda' \hat{y}_r - \lambda' y_r)^2 = E[\lambda' \hat{y}_r - E(\lambda' y_r | y_s)]^2 + E[\lambda' y_r - E(\lambda' y_r | y_s)]^2.$$

Teorema 2.1 No modelo  $y \sim N_N(X\beta, V)$ , o melhor previsor não viciado de  $y_r$  é

$$\hat{y}_r^* = V_{rs} V_s^{-1} y_s + (X_r - V_{rs} V_s^{-1} X_s) \hat{\beta},$$

$$\text{onde } \hat{\beta} = (X_s' V_s^{-1} X_s)^{-1} X_s' V_s^{-1} y_s.$$

Prova:

Se  $\hat{y}_r$  é um previsor qualquer não viciado para  $y_r$ , então

$$E(\hat{y}_r) = X_r \hat{\beta}.$$

O previsor  $\hat{Y}_r^*$  é não viciado para  $Y_r$  pois

$$E(\hat{Y}_r^*) = V_{rs} V_s^{-1} X_s \beta + (X_r - V_{rs} V_s^{-1} X_s) \beta.$$

$$\text{Como } Y \sim N_n(X\beta, V), \quad E(Y_r | Y_s) = V_{rs} V_s^{-1} Y_s + (X_r - V_{rs} V_s^{-1} X_s) \beta \quad \text{e,}$$

devido ao lema 2.1,

$$EQMG(\hat{Y}_r) = E[(\lambda' \hat{Y}_r - \lambda' Y_r)^2] =$$

$$= E([\lambda' \hat{Y}_r - \lambda' V_{rs} V_s^{-1} Y_s - \lambda' (X_r - V_{rs} V_s^{-1} X_s) \beta]^2) + E([\lambda' Y_r - E(\lambda' Y_r | Y_s)]^2).$$

Analogamente,

$$EQMG(\hat{Y}_r^*) = E[(\lambda' \hat{Y}_r^* - \lambda' Y_r)^2] =$$

$$= E([\lambda' (X_r - V_{rs} V_s^{-1} X_s) \hat{\beta} - \lambda' (X_r - V_{rs} V_s^{-1} X_s) \beta]^2) + E([\lambda' Y_r - E(\lambda' Y_r | Y_s)]^2).$$

A suposição de que  $Y \sim N_n(X\beta, V)$  implica que  $Y_s \sim N_n(X_s \beta, V_s)$ . Assim,  $\lambda' (X_r - V_{rs} V_s^{-1} X_s) \hat{\beta}$  é o estimador não viciado de variância mínima de  $\lambda' (X_r - V_{rs} V_s^{-1} X_s) \beta$  e, sendo  $\lambda' (\hat{Y}_r - V_{rs} V_s^{-1} Y_s)$  um estimador não viciado para  $\lambda' (X_r - V_{rs} V_s^{-1} X_s) \beta$ ,

segue que

$$E([\lambda' (X_r - V_{rs} V_s^{-1} X_s) \hat{\beta} - \lambda' (X_r - V_{rs} V_s^{-1} X_s) \beta]^2) \leq$$

$$E([\lambda' \hat{Y}_r - \lambda' V_{rs} V_s^{-1} Y_s - \lambda' (X_r - V_{rs} V_s^{-1} X_s) \beta]^2), \forall \lambda$$

e portanto

$$EQMG(\hat{Y}_r^*) \leq EQMG(\hat{Y}_r). \quad \square$$

Após cálculos, verificamos que

$$\text{EQMG } (\hat{Y}_r^*) = \lambda' [V_r + D'(X_s V_s^{-1} X_s)^{-1} D - V_{rs} V_s^{-1} V_{sr}] \lambda,$$

onde  $D = X_r' - X_s' V_s^{-1} V_{sr}$ .

É importante observarmos a dimensão ( $N-n$ ) do vetor a ser previsto. Na maioria dos casos, o tamanho da amostra,  $n$ , é um número pequeno comparado com  $N$ , tamanho da população. Desta forma, a dimensão do vetor  $y_r$  é, no geral, bastante grande.

Tomando  $\lambda' = \xi'$  no teorema 2.1, notamos que se  $\xi' y_r$  é uma combinação linear qualquer dos elementos de  $y_r$ , então  $\xi' \hat{Y}_r^*$  é o previsor ótimo de  $\xi' y_r$ . Em particular, a  $j$ -ésima componente de  $\hat{Y}_r^*$  será o previsor ótimo da  $j$ -ésima componente de  $y_r$ .

Por outro lado, se  $A_1$  e  $A_2$  são matrizes respectivamente  $k \times n$  e  $k \times (N-n)$ ,  $k \leq N-n$  e  $\underline{\theta} = A_1 y_s + A_2 y_r$ , segue do teorema 2.1 que  $\hat{\theta}^* = A_1 y_s + A_2 \hat{Y}_r^*$  é o previsor ótimo de  $\underline{\theta}$ . Isto pode ser verificado pois

$$E(\hat{\theta}^* - \underline{\theta}) = E[A_2(\hat{Y}_r^* - y_r)] = 0$$

e

$$\text{EQMG } (\hat{\theta}^*) = E(\lambda'^* A_2 \hat{Y}_r^* - \lambda'^* A_2 y_r)^2 = E(\lambda' \hat{Y}_r^* - \lambda' y_r)^2,$$

$$\lambda^* \in \mathbb{R}^k.$$

Em particular, os previsores ótimos de  $B_N$  e  $T$  poderiam ser alternativamente obtidos através do resultado deste teorema.

### 3. PREVISÃO LINEAR ÓTIMA DE $\hat{Y}_r$

Se, no modelo de superpopulação utilizado, a suposição de normalidade for abandonada, de modo a trabalharmos com o modelo mais geral dado em (1), o próximo teorema prova que  $\hat{Y}_r^*$  será o previsor linear ótimo de  $\hat{Y}_r$ . Agora, devido à maior generalidade do modelo, a optimilidade de  $\hat{Y}_r^*$  ficará restrita à classe dos previsores lineares não viciados de  $\hat{Y}_r$ .

Lema 3.1 No modelo (1),

$$\begin{aligned} E(\underline{h}' \underline{Y}_s - \underline{\ell}' \underline{Y})^2 &= E[(\underline{h}' - \underline{\ell}' K' V_s^{-1})(\underline{Y}_s - X_s \beta)]^2 + \underline{\ell}' V_s \underline{\ell} - \underline{\ell}' K' V_s^{-1} K \underline{\ell} \\ &+ [(\underline{h}' X_s - \underline{\ell}' X) \beta]^2, \end{aligned}$$

onde  $\underline{h}$  e  $\underline{\ell}$  são vetores respectivamente n e N-dimensionais e  $K = [V_s \quad V_{sr}]$ .

Teorema 3.1 No modelo (1), o previsor linear ótimo de  $\hat{Y}_r$  é

$$\hat{Y}_r^* = V_{rs} V_s^{-1} \underline{Y}_s + (X_r - V_{rs} V_s^{-1} X_s) \hat{\beta},$$

$$\text{onde } \hat{\beta} = (X_s' V_s^{-1} X_s)^{-1} X_s' V_s^{-1} \underline{Y}_s.$$

Prova:

Sejam  $T$  um previsor linear não viciado de  $\hat{Y}_r$ ,  $T$  matriz  $(N-n) \times n$  e  $A = [0_{(N-n) \times n} \quad I_{N-n}]$ , onde  $0_{(N-n) \times n}$  representa a matriz

nula de dimensão  $(N-n) \times n$  e  $I_{N-n}$  a matriz identidade de ordem  $N-n$ .

Nestas condições,  $\underline{\lambda}' \underline{Y}_r = \underline{\lambda}' A \underline{\beta}$ ,  $E(\underline{T} \underline{Y}_s - \underline{Y}_r) = 0$ ,

$$E(\underline{\lambda}' T \underline{Y}_s - \underline{\lambda}' \underline{Y}_r) = 0 = E(\underline{\lambda}' T \underline{Y}_s - \underline{\lambda}' A \underline{\beta}) = \underline{\lambda}' T X_s \underline{\beta} - \underline{\lambda}' A X \underline{\beta} \text{ e}$$

$$\text{EQMG } (T \underline{Y}_s) = E (\underline{\lambda}' T \underline{Y}_s - \underline{\lambda}' A \underline{\beta})^2.$$

No lema 3.1, tomando  $\underline{h}' = \underline{\lambda}' T$  e  $\underline{L}' = \underline{\lambda}' A$ , obtemos

$$\text{EQMG } (T \underline{Y}_s) = E [(\underline{\lambda}' T - \underline{\lambda}' A K' V_s^{-1})(\underline{Y}_s - X_s \underline{\beta})]^2 + \underline{\lambda}' A V A' \underline{\lambda} - \underline{\lambda}' A K' V_s^{-1} K A' \underline{\lambda}.$$

Como  $E(\underline{Y}_s) = X_s \underline{\beta}$ , o previsor linear ótimo de  $\underline{Y}_r$ ,  $T^* \underline{Y}_s$ ,

deve minimizar

$$E((\underline{\lambda}' T - \underline{\lambda}' A K' V_s^{-1}) \underline{Y}_s - E((\underline{\lambda}' T - \underline{\lambda}' A K' V_s^{-1}) \underline{Y}_s))^2$$

e, para isto,  $\underline{\lambda}' T^* \underline{Y}_s - \underline{\lambda}' A K' V_s^{-1} \underline{Y}_s$  deve ser o estimador linear ótimo de

$$E((\underline{\lambda}' T - \underline{\lambda}' A K' V_s^{-1}) \underline{Y}_s) = (\underline{\lambda}' T - \underline{\lambda}' A K' V_s^{-1}) X_s \underline{\beta} = (\underline{\lambda}' A X - \underline{\lambda}' A K' V_s^{-1} X_s) \underline{\beta}.$$

Pelo teorema de Gauss-Markov, o estimador linear ótimo de

$$(\underline{\lambda}' A X - \underline{\lambda}' A K' V_s^{-1} X_s) \underline{\beta} \text{ é } (\underline{\lambda}' A X - \underline{\lambda}' A K' V_s^{-1} X_s) \hat{\underline{\beta}} \text{ e portanto,}$$

$$\underline{\lambda}' T^* \underline{Y}_s - \underline{\lambda}' A K' V_s^{-1} \underline{Y}_s = \underline{\lambda}' A X \hat{\underline{\beta}} - \underline{\lambda}' A K' V_s^{-1} X_s \hat{\underline{\beta}}.$$

Temos que  $A K' = V_s$  e  $A X = X_r$  e assim,

$$\underline{\lambda}' \mathbf{T}^* \mathbf{Y}_s = \underline{\lambda}' \mathbf{V}_{rs} \mathbf{V}_s^{-1} \mathbf{Y}_s + \underline{\lambda}' (\mathbf{X}_r - \mathbf{V}_{rs} \mathbf{V}_s^{-1} \mathbf{X}_s) \hat{\boldsymbol{\beta}}, \quad \forall \underline{\lambda} \in \mathbb{R}^{N-n},$$

o que prova o resultado.  $\square$

#### 4. FORMA SIMPLIFICADA DE $\hat{\mathbf{Y}}_r^*$

A busca de previsões que, além de boas propriedades, possuam também uma forma simples, tem sido frequente.

Särndal and Wright (1984) ressaltam a importância de trabalharmos com previsões simples e intuitivos. Seguindo este objetivo, Bolfarine e Rodrigues (1988) verificam que o previsor ótimo do total,  $\hat{\mathbf{T}}$ , se reduz a uma forma mais simples, dada por  $\underline{\lambda}' \mathbf{X} \hat{\boldsymbol{\beta}}$ , se e somente se  $\mathbf{K} \mathbf{l}_N \in \mu(\mathbf{X}_s)$ , onde  $\mu(\mathbf{X}_s)$  representa o espaço linear gerado pelas colunas de  $\mathbf{X}_s$ .

No caso da previsão de  $\mathbf{y}_r$ , o previsor mais simples é  $\mathbf{x}_r \hat{\boldsymbol{\beta}}$ , sendo também mais intuitivo, pois  $E(\mathbf{y}_r) = \mathbf{x}_r \hat{\boldsymbol{\beta}}$ . O próximo teorema estabelece uma condição necessária e suficiente para que

$$\hat{\mathbf{Y}}_r^* = \mathbf{x}_r \hat{\boldsymbol{\beta}}.$$

Teorema 4.1 O previsor ótimo de  $\mathbf{y}_r$ ,  $\hat{\mathbf{Y}}_r^*$ , coincide com  $\mathbf{x}_r \hat{\boldsymbol{\beta}}$  se e somente se

$$\mathbf{V}_{sr} \underline{\lambda} \in \mu(\mathbf{X}_s), \tag{3}$$

para todo vetor  $(N-n)$ -dimensional  $\underline{\lambda}$ .

Prova:

$$\hat{y}_r^* = X_r \hat{\beta} \Leftrightarrow \underline{\ell}' \hat{y}_r^* = \underline{\ell}' X_r \hat{\beta} \quad \forall \underline{\ell} \in \mathbb{R}^{N-n} \Leftrightarrow$$

$$\underline{\ell}' V_{rs}^{-1} y_s + \underline{\ell}' (X_r - V_{rs}^{-1} X_s) \hat{\beta} = \underline{\ell}' X_r \hat{\beta}, \quad \forall \underline{\ell} \in \mathbb{R}^{N-n} \Leftrightarrow$$

$$\underline{\ell}' V_{rs}^{-1} (y_s - X_s \hat{\beta}) = 0, \quad \forall \underline{\ell} \in \mathbb{R}^{N-n}.$$

Como  $(y_s - X_s \hat{\beta}) \in \mu^\perp(X_s)$ , onde  $\mu^\perp(X_s)$  representa o espaço vetorial ortogonal a  $\mu(X_s)$ , a última igualdade vale se e somente se  $V_{rs} \underline{\ell} \in \mu(X_s)$ ,  $\forall \underline{\ell} \in \mathbb{R}^{N-n}$ , o que encerra a demonstração.  $\square$

A condição (3) parece mais restrita que  $K \mathbf{1}_{N-n} \in \mu(X_s)$ , no entanto, a primeira não implica na segunda, conforme mostra o corolário 4.1. Devemos nos lembrar da maior dimensão da quantidade a ser prevista,  $y_r$ . Mesmo assim, o exemplo 4.1 apresenta uma situação usual em que a condição está satisfeita.

#### Exemplo 4.1

Consideremos o modelo de superpopulação

$$y = X\beta + \varepsilon, \quad E(\varepsilon) = 0, \quad \text{Var}(\varepsilon) = V$$

com

$$X = \mathbf{1}_N, \quad V = (1-\rho)I_N + \rho \mathbf{1}_N \mathbf{1}_N' = (1-\rho)I_N + \rho J_N,$$

onde  $J_N$  é a matriz NxN contendo 1 em todas as posições.

Neste caso,

$$V_s = (1-\rho)I_N + \rho J_n,$$

o que implica que

$$V_s^{-1} = \frac{1}{1-\rho} \left[ I_n - \frac{\rho}{1+(n-1)\rho} J_n \right],$$

$$\hat{\beta} = \bar{y}_s = \frac{\sum_{i=1}^n y_i}{n},$$

$$V_{rs} = \rho J_{N-n,n} e$$

$$x_r - V_{rs} V_s^{-1} x_s = \frac{1-\rho}{1+(n-1)\rho} \underline{l}'_{N-n}.$$

Além disso,

$$V_{rs} V_s^{-1} y_s = \frac{\rho}{1+(n-1)\rho} \underline{l}_{N-n} n \bar{y}_s,$$

e assim,

$$\hat{y}_r^* = \underline{l}_{N-n} \bar{y}_s.$$

Como  $x_r = \underline{l}_{N-n}$ , segue que  $\hat{y}_r^* = x_r \hat{\beta}$  e, pelo teorema 4.1,

$$V_{sr} \underline{\ell} \in \mu(x_s), \forall \underline{\ell} \in \mathbb{R}^{N-n}.$$

De fato, se  $\underline{\ell}' = (\ell_1, \ell_2 \dots \ell_{N-n})$ ,

$$V_{sr} \underline{\ell} = \rho \begin{bmatrix} 1 & 1 & \dots & 1 \\ 1 & 1 & & 1 \\ \vdots & & & \\ 1 & 1 & & 1 \end{bmatrix} \underline{\ell} = \underline{l}_n \rho \sum_{i=1}^{N-n} \ell_i = x_s \delta, \text{ para } \delta = \rho \sum_{i=1}^{N-n} \ell_i,$$

o que mostra que  $V_{sr} \underline{\ell} \in \mu(x_s)$ ,  $\forall \underline{\ell} \in \mathbb{R}^{N-n}$ .

Corolário 4.1 Se  $\hat{y}_r^* = x_r \hat{\beta}$  e  $V_s \underline{l}_n \in \mu(x_s)$ , então  $\hat{T} = \underline{l}'_n x \hat{\beta}$ .

Prova:

Se  $\hat{y}_r^* = X_r \hat{\beta}$ , pelo teorema 4.1,  $V_{sr} \underline{\ell} \in \mu(X_s)$ ,  $\forall \underline{\ell} \in \mathbb{R}^{N-n}$  e assim,  $V_s \underline{1}_{N-n} \in \mu(X_s)$ . Temos também, por hipótese, que  $V_s \underline{1}_n \in \mu(X_s)$ , e com isto,

$$V_{sr} \underline{1}_{N-n} = X_s \underline{\delta}_1, \quad \underline{\delta}_1 \in \mathbb{R}^{P+1}$$

e

$$V_s \underline{1}_n = X_s \underline{\delta}_2, \quad \underline{\delta}_2 \in \mathbb{R}^{P+1},$$

que implica em

$$[V_s \quad V_{sr}] \begin{bmatrix} \underline{1}_n \\ \underline{1}_{N-n} \end{bmatrix} = X_s (\underline{\delta}_1 + \underline{\delta}_2).$$

Desta forma,  $K \underline{1}_N \in \mu(X_s)$ , o que garante que  $\hat{T} = \underline{1}_N' X \hat{\beta}$ .  $\square$

## 5. ROBUSTEZ DOS PREVISORES ÓTIMOS COM RELAÇÃO A ALTERAÇÕES NA MATRIZ DE COVARIÂNCIA DO MODELO

Uma análise comum quando trabalhamos com previsores ótimos em um determinado modelo é a pesquisa de condições sob as quais estes previsores mantém sua otimalidade em modelos alternativos.

Neste sentido, o resultado do teorema 4.1 permite um estudo sobre a robustez do previsor quanto a alguns tipo de falhas na especificação da matriz de covariância.

Vamos considerar os modelos

$$\xi_1 : y = X\beta + \varepsilon_1, \quad E(\varepsilon_1) = 0, \quad \text{Var}(\varepsilon_1) = \text{Var}(y) = \begin{bmatrix} V_s & 0 \\ 0 & V_{r1} \end{bmatrix}$$

e

$$\xi_2 : y = X\beta + \varepsilon_2, \quad E(\varepsilon_2) = 0, \quad \text{Var}(\varepsilon_2) = \text{Var}(y) = \begin{bmatrix} V_s & V_{sr} \\ V_{rs} & V_{r2} \end{bmatrix}, \quad V_{sr} \neq 0,$$

e os previsores lineares ótimos de  $T$  e  $\hat{Y}_{r1}$ , respectivamente sob os modelos  $\xi_1$  e  $\xi_2$ :  $\hat{T}_1$ ,  $\hat{Y}_{r1}^*$ ,  $\hat{T}_2$ ,  $\hat{Y}_{r2}^*$ .

Os próximos corolários estabelecem alguns aspectos relativos à robustez dos previsores.

Corolário 5.1  $\hat{Y}_{r1}^* = \hat{Y}_{r2}^*$  se e somente se a condição (3) está satisfeita.

Prova:

$$\hat{Y}_{r1}^* - X_r \hat{\beta} = \hat{Y}_{r2}^* - V_{rs} V_s^{-1} Y_s + (X_r - V_{rs} V_s^{-1} X_s) \hat{\beta}, \quad \text{onde } \hat{\beta} = (X_s' V_s^{-1} X_s)^{-1} X_s' V_s^{-1} Y_s.$$

Segue diretamente do teorema 4.1 que  $\hat{Y}_{r1}^* = \hat{Y}_{r2}^*$  se e somente se (3) está satisfeita.  $\square$

Corolário 5.2 Se a condição (3) está satisfeita então  $\hat{T}_1 = \hat{T}_2$ .

Prova:

$$\hat{T}_1 = \underline{1}'_n Y_s + \underline{1}'_{N-n} X_r \hat{\beta} = \underline{1}'_n Y_s + \underline{1}'_{N-n} \hat{Y}_{r1}^* \quad \text{e}$$

$$\hat{T}_2 = \underline{1}'_n Y_s + \underline{1}'_{N-n} [V_{rs} V_s^{-1} Y_s + (X_r - V_{rs} V_s^{-1} X_s) \hat{\beta}] = \underline{1}'_n Y_s + \underline{1}'_{N-n} \hat{Y}_{r2}^*.$$

A condição (3) implica que  $\hat{Y}_{r2}^* = \hat{Y}_{r1}^*$ , e portanto,  $\hat{T}_1 = \hat{T}_2$ .  $\square$

Com relação ao corolário 5.2, verifica-se alternativamente que se  $V_{sr} \hat{\beta} \in \mu(X_s)$ ,  $\forall \hat{\beta} \in \mathbb{R}^{M-n}$ , vale a condição (6.1.11), necessária e suficiente para que  $\hat{T}_1 = \hat{T}_2$ , dada em Bolfarine and Zacks (1993).

Observamos ainda que, neste caso, o cálculo dos previsores, além de não depender do conhecimento de  $V_r$ , será também independente de  $V_{sr}$ .

Se, juntamente com (3), for também válida a condição

$$V_s X_s = X_s F, \quad (4)$$

para alguma matriz  $F$ ,  $(p+1) \times (p+1)$ , não singular, é possível a previsão ótima de  $y_r$  e  $T$  sem a especificação de  $V_r$ .

Isto acontece porque (4) é uma condição necessária e suficiente para que  $(X_s' V_s^{-1} X_s)^{-1} X_s' V_s^{-1} Y_s = (X_s' X_s)^{-1} X_s' Y_s$ , (Graybill (1976), pág. 209), ou seja, para que o estimador de mínimos quadrados generalizados coincida com o estimador de mínimos quadrados usual.

Finalizando, observamos que a validade da condição (3) não altera a forma matemática do previsor ótimo de  $B_N$ , pois este é  $\hat{\beta} = (X_s' V_s^{-1} X_s)^{-1} X_s' V_s^{-1} Y_s$ , qualquer que seja a matriz  $V_{sr}$ .

## REFERÊNCIAS

- Bolfarine, H., Zacks, S., Elian, S.N. and Rodrigues, J.(1994). Optimal Prediction of the Finite Population Regression Coefficient in Finite Populations. *Sankhya, Series B*, (aceito para publicação).
- Bolfarine, H. and Rodrigues, J. (1988). On the simple projection predictor in finite populations. *Australian Journal of Statistics*, 30(3): 338-341.
- Bolfarine, H. and Zacks, S.(1993). *Prediction Theory for Finite Populations*. Springer-Verlag, New York. 207 p.
- Graybill, F.A. (1976). *Theory and Application of the Linear Model*. Duxbury Press. 704 p.
- Rodrigues, J. and Elian, S.N. (1993). Maximum Likelihood Prediction in Finite Populations. Technical Report, University of São Paulo, Department of Statistics.
- Royall, R.M. (1976). The Linear Least-Squares Prediction Approach to Two-stage sampling. *Journal of the American Statistical Association*, 71(355): 657-664.
- Sarndal, C.E. and Wright, R.L. (1984). Cosmetic Form of estimators in survey sampling. *Scandinavian Journal of Statistics*, 11(3): 146-156.
- Tam, S.M. (1987). Optimality of Royall's predictor under a Gaussian Superpopulation Model. *Biometrika*, 74(3):659-660.

ULTIMOS RELATORIOS TECNICOS PUBLICADOS

- 9401 - PAULA, G. A., SEN P.K., Tests of ordered Hypotheses in Linkage in Heredity, 12p.
- 9402 - PAULA, G. A., SEN P. K. One-Sided Tests in Generalized Linear Models with Parallel Regression Lines, 18p.
- 9403 - PAULA, G. A., .Influence Diagnostics in Proper Dispersion Models, 22 p.
- 9404 - SALINAS-TORRES, V.H. & PEREIRA, C.A.B. and TIWARI, R.C. - Convergence of Dirichlet Measures Arising in Context of Bayesian Analysis of Competing Risk Models, 17p.
- 9405 - CRIBARI-NETO, F. & FERRARI, S.L.P. - Second Order Asymptotics for Score Tests in Generalized Linear Models, 25p.
- 9406 - ZUAZOLA, P.L.I., PEREIRA, C.A.B. & WECHSLER, S. - Predictivistic Statistical Inference in Finite Populations, 10p.
- 9407 - BOLFARINE, H. & ROJAS, M.G. - Maximum Likelihood Estimation of Simultaneous Pairwise Linear Structural Relationships, 19p.
- 9408 - FERRARI, P.A. & KIPNIS, C. - Second Class Particles in the Rarefaction Fan, 9p.
- 9409 - ANDRÉ, C.D.S., NARULA, S.C. & PERES, C.A. - Asymptotic Properties of MSAE Estimates in Multistage Model. Preliminary Results, 19p.
- 9410 - ARELLANO-VALLE, R.B. & BOLFARINE, H. - On Some Characterizations of the t-Distribution, 12p.
- 9411 - NEVES, E.J., A Discrete Variational Problem Related to Ising Droplets at Low Temperatures, 16p.
- 9412 - FERRARI, S.L.P. & CORDEIRO, G.M. - Corrected Score Tests for Exponential Family Nonlinear Models, 14p.
- 9413 - ANDRADE, D.F. & SINGER, J.M. - Profile Analysis for Randomized Complete Block Experiments, 8p.
- 9414 - BOLFARINE, H. & ROJAS, M.G. - On Structural Comparative Calibration, 13p.
- 9415 - AUBIN, E.C.Q. & CORDEIRO, G.M. Bias in Linear Regression Models with Unknown Covariance Matrix, 16p.

The complete list of Relatórios do Departamento de Estatística, IME-USP, will be sent upon request.

- Departamento de Estatística  
IME-USP  
Caixa Postal 20.570  
01452-990 - São Paulo, Brasil