

DISCRIMINAÇÃO DE DUAS POPULAÇÕES MULTIVARIADAS
COM BASE EM DESIGUALDADE DE MATRIZES DE DISPERSÕES

Este exemplar corresponde a redação
final da tese devidamente corrigida
e defendida pela Sra.

DORIS ALBINA GÓMEZ TIGERÁN
e aprovada pela Comissão Julgadora.

Campinas 12 de Outubro de 1988.

prof. Dr.


Orientador

Dissertação apresentada ao Instituto
de Matemática, Estatística e Ciência
da Computação, UNICAMP, como requisi-
to parcial para obtenção do Título
de Mestre em ESTATÍSTICA.

G586d

9981/BC

DISCRIMINAÇÃO DE DUAS POPULAÇÕES MULTIVARIADAS
COM BASE EM DESIGUALDADE DE MATRIZES DE DISPERSÕES

ALUNA : DORIS ALBINA GÓMEZ TICERÁN

ORIENTADOR : PROF. DR. JOSÉ ANTÔNIO CORDEIRO

INSTITUTO DE MATEMÁTICA, ESTATÍSTICA E CIÊNCIA DA COMPUTAÇÃO
(IMECC)
UNIVERSIDADE ESTADUAL DE CAMPINAS - (UNICAMP)

CAMPINAS - SÃO PAULO

BRASIL

U N I C A M P
BIBLIOTECA CENTRAL

A mi hijo YAKOV

con todo el amor,
que la distancia
le privó.

AGRADECIMENTOS

Ao prof. Dr. José Antônio Cordeiro, pela orientação e incentivo recebido durante a realização do presente trabalho.

Ao prof. Dr. Armando Infante, pelas valiosas sugestões que tanto nos auxiliaram.

Aos professores, colegas e amigos da U.N.M. de San Marcos de Lima Perú, que me alentaram na iniciação dos meus estudos de mestrado.

Aos meus amigos e colegas do Mestrado, José Luis Llanos, e José Ramos, pelos valiosos auxílios na parte de computação.

Ao meu amigo Mario Tarumoto pelo precioso apoio na datilografia e na correção do português.

Ao meu esposo Mario pela compreensão e a força recebida, que apesar da distância nunca me faltou, e sem as quais seria impossível a culminação dos meus estudos.

Aos meus pais Luis e Guillermina pela paciência e carinho que me dedicaram.

A Eugenia, Myriam, Emma, Rosangela, pela amizade e solidariedade nos meus momentos de saudade. E a todos os meus amigos e colegas que direta ou indiretamente me apoiaram.

Ao CNPq e UNICAMP que financiaram o meu programa de pós-graduação.

INDICE

INTRODUÇÃO	1
CAPITULO 1	
O PROBLEMA GERAL DA DISCRIMINAÇÃO	
1.1.-Introdução.....	4
1.2.-Regras de Boa Classificação.....	5
1.3.-Procedimentos de Classificação com Distribuições de probabilidade conhecidas.....	8
1.4.-Método de Fisher para Duas Populações	
1.4.1.-Parâmetros conhecidos.....	13
1.4.2.-Parâmetros desconhecidos.....	14
1.5.-Classificação em duas Populações Normais Multivaria das Homoscedásticas.....	15
1.6.-Critério de Classificação baseado na Estrutura de Covariâncias das Populações Concorrentes.	
1.6.1.-Obtenção das Combinações Lineares.....	18
1.6.2.-Uma Proposta de Discriminação.....	28
CAPITULO 2	
PROBLEMA DE DISCRIMINAÇÃO NO CASO NORMAL HETEROSCEDASTICICO	
2.1.-Introdução.....	33
2.2.-Construção da Regra de Discriminação Quadrática.....	34

2.3.	-Construção de um Novo Método de Discriminação.	
2.3.1.	-Parâmetros Conhecidos.....	37
2.3.2.	-Parâmetros Desconhecidos.....	41
2.3.3.	-Avaliação do Procedimento de Discriminação Proposto.....	43
2.3.4.	-Estimação da Probabilidade Total de Má Classificação.	
2.3.4.1.	-Primeiro Estimador (Método de Re- substituição).....	51
2.3.4.2.	-Segundo estimador (Método H).....	52
2.3.4.3.	-Terceiro estimador (Método U modi- ficado).....	53

CAPÍTULO 3

O DESEMPENHO DO NOVO METODO : SIMULAÇÃO E EXEMPLO

3.1.	-Introdução.....	55
3.2.	-Simulações	
3.2.1.	-Geração das Duas Populações Normais de dimensão p	56
3.2.2.	-Geração das Duas Populações Normais bi-variadas.....	62
3.2.3.	-Construção da Função de Discriminação Amostral.....	63
3.2.4.	-Avaliação da Função de Discriminação Amos- tral e apresentação dos Resultados Experi- mentais.....	67
3.3.	-Exemplo de Aplicação	
3.3.1.	-Introdução.....	90
3.3.2.	-Descrição dos Dados.....	90
3.3.3.	-Resultados Obtidos.....	100

CAPITULO 4

CONCLUSÕES DAS SIMULAÇÕES E DO EXEMPLO.....	115
---	-----

APENDICE

PROGRAMA N ^o 1.-Escrito em Linguagem Fortran: Contém os resultados das simulações e a função discriminante para duas populações normais de dimensão dois.....	127
PROGRAMA N ^o 2.-Escrito em Linguagem Fortran: Contém os resultados das simulações e a função discriminante para duas populações normais de dimensão três.....	137
PROGRAMA N ^o 3.-É o Proc Discrim do SAS para as amostras geradas com o programa N ^o 1.....	147
PROGRAMA N ^o 4.-É o Proc Discrim do SAS para as amostras geradas com o programa N ^o 2.....	148
PROGRAMA N ^o 5.-Escrito em Linguagem Fortran: Contém os cálculos necessários para obter a função discriminante do exemplo de aplicação.....	149
PROGRAMA N ^o 6.-É o Proc Discrim do SAS para os dados do exemplo de aplicação.....	158
QUADRO A1.-Obtenção dos autovalores e razão de erro aparente para diferentes parâmetros de entrada do programa 1.....	159

QUADRO A2. -Contém resultados de interesse do programa 6.160

QUADRO A3. -Contém resultados de interesse do programa 5.161

QUADRO A4. -Contém resultados de interesse do programa 5.162

QUADRO A5. -Contém resultados de interesse do programa 6.170

REFERENCIA BIBLIOGRÁFICA. 171

INTRODUÇÃO

Um dos tópicos mais importantes da Estatística Multivariada, é apresentado com o título de Análise Discriminante ou Discriminação e Classificação, cujo interesse principal é alocar um indivíduo(objeto) ou um grupo deles em uma das categorias, grupos ou populações concorrentes. Também, os critérios de discriminação adotados, frequentemente, são utilizados para a redução de dimensão do problema estatístico.

A classificação consiste na identificação da categoria ou grupo ao qual pertence o novo indivíduo, levando em consideração as suas características observadas. Quando tais características são medições numéricas a designação aos grupos é chamada discriminação e a combinação das medições recebe o nome de função discriminante. Mais especificamente, na discriminação tenta-se descrever de maneira gráfica (em duas ou três dimensões) ou algebricamente mediante funções chamadas discriminantes, os aspectos diferenciais dos indivíduos ou objetos de várias populações. Quando a(s) função(ões) de discriminação são lineares o que se tem são combinações das variáveis originais que, escolhidas convenientemente, podem providenciar informação importante. Também, tais combinações simplificam a estrutura da matriz de covariâncias facilitando a interpretação dos dados.

Em muitos casos assume-se a existência de um número finito de populações a uma das quais pertence o indivíduo, sendo que cada população é caracterizada pela distribuição de probabilidade de suas medidas e uma observação é um valor amostral de uma dessas populações. Portanto, o indivíduo a ser classificado é considerado como uma observação aleatória de uma das populações.

Cabe notar que em algumas situações, as distribuições de probabilidade das populações são consideradas conhecidas de início, em outras situações a forma da distribuição de probabilidade das populações é conhecida mas os parâmetros são desconhecidos, então, tomam-se amostras dessas populações para estimar as quantidades desconhecidas.

Os métodos mais utilizados em problemas práticos de discriminação e classificação são o de Fisher (Fisher, 1936), o de razão de verossimilhanças e o de Bayes (Anderson, 1958), que produzem funções de discriminação lineares (caso homoscedástico) ou quadráticas (caso heteroscedástico) nas medições do indivíduo a ser classificado.

No contexto do problema de discriminação e classificação e tomando a idéia de Flury (Flury, 1983), o objetivo do presente trabalho é propor um novo método de discriminação baseado na comparação das matrizes de covariâncias para duas populações multivariadas de dimensão p , que conduz a uma função discriminante a partir da qual pode-se estabelecer uma regra de classificação.

O método proposto sempre fornece duas combinações lineares das componentes do indivíduo a classificar, que podem ser utilizadas em representações gráficas e redução de dimensão do problema, toda vez que as matrizes de covariâncias entre as duas populações forem diferentes.

A conclusão do presente trabalho é que, comparado com o método de classificação por quociente de verossimilhanças, no caso de populações com distribuições de probabilidade normais de dimensão $p=3$ o método proposto apresenta vantagens e desvantagens, e, em $p=2$ eles parecem ser equivalentes. As populações foram simuladas pelo método Monte Carlo.

Sugere-se que o método proposto seja usado como complementar, que poderia ajudar numa melhor classificação e num melhor entendimento do problema.

O trabalho está dividido em 4 capítulos. O capítulo 1 contém os resultados de uma pesquisa bibliográfica sobre regras de classificação e as funções de discriminação em populações homoscedásticas. Além disso, apresentamos o novo critério de classificação baseado nas estruturas de covariâncias das populações concorrentes. O problema de discriminação e a nova proposta para populações normais heteroscedásticas são apresentados no capítulo 2. No capítulo 3, usando amostras de populações normais de dimensão $p=2$ e $p=3$ geradas por processo de simulação Monte Carlo e com um exemplo de aplicação, avalia-se o desempenho do método de discriminação proposto. As conclusões obtidas do estudo de simulação e do exemplo são apresentadas no capítulo 4.

CAPITULO 1

O PROBLEMA GERAL DA DISCRIMINAÇÃO

1.1 INTRODUÇÃO

Sejam Π_1 , Π_2 as duas populações ou classes de objetos e $\underline{X}^{(g)} = (X_1^{(g)}, \dots, X_p^{(g)})$, $g=1,2$ um vetor aleatório com valores em \mathbb{R}^p contendo medições dos indivíduos de cada uma das populações. Os valores observados de $\underline{X}^{(g)}$ diferem de uma classe à outra e através de suas medidas construiremos uma regra para classificar um novo indivíduo \underline{x} de \mathbb{R}^p em uma das duas populações.

Na construção de uma função de discriminação, a suposição de igualdade das matrizes de covariâncias das populações concorrentes (homoscedasticidade) é uma suposição muito forte e às vezes não satisfeita nas aplicações práticas.

Sob a suposição de homoscedasticidade obtém-se uma função linear, no entanto, quando a suposição de homogeneidade de matrizes de covariâncias não pode ser feita (heteroscedasticidade), a função discriminante contém termo quadrático.

1.2 Regras de Boa Classificação

Em princípio, independentemente da condição de homoscedasticidade ou heteroscedasticidade das matrizes de covariâncias das duas populações, nos problemas de classificação estamos sujeitos aos possíveis erros de classificação, isto é, alocar um indivíduo a certa população quando na realidade pertence a uma outra população. Portanto, na construção do procedimento de classificação procuramos aquele que minimiza o custo esperado de má classificação.

Podemos pensar de uma observação como um ponto no espaço de dimensão p . Dividimos tal espaço em duas regiões disjuntas R_1 e R_2 ($R_1 \cup R_2 = \mathbb{R}^p$). Se a observação \underline{x} pertence a R_1 é classificada como procedente de Π_1 e se pertence a R_2 , como procedente de Π_2 , ou seja:

$$\begin{array}{l} \text{Alocar } \underline{x} \text{ em } \Pi_g \text{ se } \underline{x} \in R_g \quad g=1,2 \quad (1) \\ \text{com } R_1 \cup R_2 = \mathbb{R}^p \quad \text{e} \quad R_1 \cap R_2 = \emptyset \end{array}$$

As populações Π_1 e Π_2 estão caracterizadas pelas funções de densidade $f_1(\underline{x})$ e $f_2(\underline{x})$, respectivamente.

Em todo processo de classificação temos associado o custo, dado que, quando alocamos um objeto em Π_1 sendo que ele pertence a Π_2 ou alocamos em Π_2 dado que procede de Π_1 , estamos cometendo um erro que tem um determinado custo. Tais custos podem ser medidos em qualquer unidade porque o que importa é o quociente entre eles.

Claramente, um bom procedimento de classificação é aquele que minimiza o custo de má classificação.

Nós iniciaremos agora o procedimento do problema de discriminação e classificação envolvendo duas categorias ou populações, para o qual necessitamos da notação:

$$g=1,2 \quad i=1,2 \quad j=1,2 \quad i \neq j \quad (2)$$

$f_g(\underline{x})$	Funções de densidade de probabilidade correspondente à população Π_g .
R_g	Regiões de classificação correspondente à população Π_g .
R	Denota uma regra de classificação particular.
$C(i/j)$	Custo de classificar erradamente a observação \underline{x} da população Π_j em Π_i .
$P(i/j, R)$	Probabilidade condicional de classificar uma observação de Π_j em Π_i , segundo a regra R .
$q_g = P(\underline{X} \in \Pi_g)$	Probabilidade a priori de obter uma observação da população Π_g .
$r(j, R)$	Risco ou perda esperada quando uma observação da população Π_j é classificada em Π_i .

$$P(x \text{ ser classificado corretamente}) = P(g/g, R) = \int_{R_g} f_g(x) dx.$$

$$P(x \text{ ser classificado incorretamente}) = P(i/j, R) = \int_{R_i} f_j(x) dx.$$

$$\text{onde, } dx = dx_1 dx_2 \dots dx_p = \prod_{i=1}^p dx_i$$

$$P(2/1, R) = 1 - P(1/1, R) \quad P(1/2, R) = 1 - P(2/2, R) \quad (3)$$

$$r(1, R) = C(2/1)P(2/1, R) \quad r(2, R) = C(1/2)P(1/2, R)$$

DEFINIÇÃO 1.1 O custo esperado de má classificação (CEM) da regra R é definido como a soma dos produtos da probabilidade de uma observação pertencer a uma determinada população pela perda esperada da mesma. Ou seja:

$$\begin{aligned} \text{CEM} &= q_1 r(1, R) + q_2 r(2, R) \\ &= q_1 C(2/1)P(2/1, R) + q_2 C(1/2)P(1/2, R) \end{aligned} \quad (4)$$

O procedimento que minimiza (4) é chamado Procedimento de Bayes para q_1 e q_2 dados. Todo procedimento de Bayes é admissível, isto é, na classe de procedimentos R não existe outro melhor que ele.

DEFINIÇÃO 1.2 A Probabilidade total de má classificação (PTM) da regra R é definida como:

$$\begin{aligned}
 \text{PTM} &= P(x \text{ ser classificado incorretamente em } \Pi_1 \text{ ou } \Pi_2) \\
 &= q_1 P(2/1, R) + q_2 P(1/2, R) \\
 &= q_1 \int_{R_2} f_1(x) dx + q_2 \int_{R_1} f_2(x) dx
 \end{aligned}
 \tag{5}$$

1.3 PROCEDIMENTOS DE CLASSIFICAÇÃO EM UMA DE DUAS POPULAÇÕES COM DISTRIBUIÇÕES DE PROBABILIDADES CONHECIDAS

Quando as distribuições de probabilidade são conhecidas devemos usar tal informação na construção das regras de classificação.

Vamos voltar ao problema de escolher as regiões R_1 e R_2 tais que o CEM (4) seja mínima.

Dada a regra R, de (4) temos:

$$\begin{aligned} \text{CEM} &= C(2/1)P(2/1, R)q_1 + C(1/2)P(1/2, R)q_2 \\ &= q_1 C(2/1) \int_{R_2} f_1(\tilde{x})d\tilde{x} + q_2 C(1/2) \int_{R_1} f_2(\tilde{x})d\tilde{x} \end{aligned}$$

$$\begin{aligned} \text{CEM} &= q_1 C(2/1) \left\{ 1 - \int_{R_1} f_1(\tilde{x})d\tilde{x} \right\} + q_2 C(1/2) \int_{R_1} f_2(\tilde{x})d\tilde{x} \\ &= q_1 C(2/1) + q_2 C(1/2) \int_{R_1} f_2(\tilde{x})d\tilde{x} - q_1 C(2/1) \int_{R_1} f_1(\tilde{x})d\tilde{x} \end{aligned}$$

$$\text{CEM} = q_1 C(2/1) + \int_{R_1} \left[q_2 C(1/2) f_2(\tilde{x}) - q_1 C(2/1) f_1(\tilde{x}) \right] d\tilde{x} \quad (6)$$

A expressão (6) é minimizada quando a região R_1 é escolhida de tal maneira que:

$\tilde{x} \in R_1$, se e só se

$$q_2 C(1/2) f_2(\tilde{x}) - q_1 C(2/1) f_1(\tilde{x}) \leq 0$$

ou equivalentemente:

$$\frac{f_1(\tilde{x})}{f_2(\tilde{x})} \geq \frac{q_2 C(1/2)}{q_1 C(2/1)} \quad (7)$$

Assim, a regra que minimiza o custo esperado de má classificação é dada pelo seguinte teorema:

TEOREMA 1.1 - Se q_1 e q_2 são as probabilidades a priori de se retirar uma observação da população Π_1 com densidade $f_1(\underline{x})$ e da população Π_2 com densidade $f_2(\underline{x})$, e se o custo de classificar uma observação de Π_1 como de Π_2 é $C(2/1)$ e uma observação de Π_2 como de Π_1 é $C(1/2)$, então as regiões de classificação R_1 e R_2 definidas por:

$$R_1 : \frac{f_1(\underline{x})}{f_2(\underline{x})} \geq \frac{q_2 C(1/2)}{q_1 C(2/1)}$$

$$R_2 : \frac{f_1(\underline{x})}{f_2(\underline{x})} < \frac{q_2 C(1/2)}{q_1 C(2/1)}$$

minimizam o custo esperado de má classificação.

Outro procedimento que conduz ao resultado (7), é aquele que aloca \underline{x} no grupo com maior probabilidade a posteriori, onde consideram-se custos $C(i/j)$ unitários.

Sejam :

$P(\Pi_1/\underline{X})$: Probabilidade a posteriori da observação \underline{X} pertencer à população Π_1 .

$P(\Pi_2/\underline{X})$: Probabilidade a posteriori da observação \underline{X} pertencer à população Π_2 .

E pela Regra de Bayes, temos:

$$\begin{aligned}
 P(\Pi_g | \tilde{X}) &= \frac{P(\tilde{X} \in \Pi_g) P(\tilde{X} / \tilde{X} \in \Pi_g)}{\sum_{g=1}^2 P(\tilde{X} \in \Pi_g) P(\tilde{X} / \tilde{X} \in \Pi_g)} & g=1,2 \\
 &= \frac{q_g f_g(\tilde{x})}{q_1 f_1(\tilde{x}) + q_2 f_2(\tilde{x})} & (8)
 \end{aligned}$$

Para um valor observado \tilde{x} minimizaremos a probabilidade total de má classificação alocando-o na população que apresenta maior probabilidade a posteriori. Ou seja:

 Alocar \tilde{x} em Π_1 quando:

$$\begin{aligned}
 \frac{q_1 f_1(\tilde{x})}{q_1 f_1(\tilde{x}) + q_2 f_2(\tilde{x})} &\geq \frac{q_2 f_2(\tilde{x})}{q_1 f_1(\tilde{x}) + q_2 f_2(\tilde{x})} \\
 q_1 f_1(\tilde{x}) &\geq q_2 f_2(\tilde{x}) \\
 \text{caso contrário, alocar em } \Pi_2 & & (9)
 \end{aligned}$$

Apresenta-se também a regra que está baseada na máxima verossimilhança, segundo a apresentação feita por *MARDIA, KENT E BIBBY (1979)*, mediante a definição 1.4. Previamente definiremos o conceito de função de verossimilhança.

DEFINIÇÃO 1.3 Seja X_1, \dots, X_n uma amostra aleatória de tamanho n da população Π cuja função de densidade de probabilidade é $f(x; \theta) = f(x)$ onde θ é o vetor de parâmetros. A função de verossimilhança para toda a amostra definida por:

$$L(\theta, X_1, \dots, X_n) = \prod_{i=1}^n f(x_i, \theta) \quad \text{é uma função do parâmetro } \theta.$$

DEFINIÇÃO 1.4 Sejam Π_1 e Π_2 duas populações p variadas com funções de densidade $f_1(\underline{x})$ e $f_2(\underline{x})$, a regra de discriminação baseada na máxima verossimilhança aloca \underline{x} para uma das populações Π_1 ou Π_2 para a qual \underline{x} tem maior função de verossimilhança, ou seja:

Alocar \underline{x} em Π_1 quando

$$L_1(\underline{x}) \geq L_2(\underline{x})$$

ou seja, quando

$$\frac{f_1(\underline{x})}{f_2(\underline{x})} \geq 1 \quad (10)$$

caso contrário, alocar em Π_2

Observamos que a regra (10) é equivalente à regra que minimiza o CEM com custos e probabilidades a priori iguais.

Em algumas situações as categorias ou populações estão especificadas de antemão, no sentido de que as distribuições de probabilidade são completamente conhecidas. Em outros casos, só a forma das distribuições de probabilidade são conhecidas e têm-se que estimar os parâmetros populacionais, para o que usamos resultados amostrais de tais populações.

Antes de fazer a apresentação da nova proposta de classificação, é conveniente fazer uma recordação da regra de discriminação linear proposta por Fisher (1936), e apresentaremos também a regra de discriminação para populações normais homoscedásticas.

1.4 MÉTODO DE FISHER PARA DUAS POPULAÇÕES.

1.4.1 PARAMETROS CONHECIDOS

Considere Π_1 e Π_2 duas populações em \mathbb{R}^p e $X^{(g)} = (X_1^{(g)}, X_2^{(g)}, \dots, X_p^{(g)})$ um vetor aleatório de Π_g e $f_g(x)$ funções de densidade de probabilidade associados a Π_g , $g = 1, 2$.

A técnica de Fisher (1936) consiste em determinar a combinação linear das coordenadas de x que maximiza o quadrado da distância entre as médias das combinações dos dois grupos relativa à sua variância.

Sejam:

$$\tilde{M}_g = E(X/\Pi_g) = E(X^{(g)}) = \begin{bmatrix} m_1^{(g)} \\ \dots \\ m_p^{(g)} \end{bmatrix} : \text{Valor esperado da variável aleatória } X, \text{ quando } X \in \Pi_g.$$

(11)

$$V_g = E(X - \tilde{M}_g)(X - \tilde{M}_g)'$$

matriz de covariâncias da população Π_g , $g=1, 2$.

com $V_1 = V_2 = V$ positiva definida.

A regra de classificação de Fisher (Lachenbruch, 1975; Johnson e Wichern, 1982) é:

Alocar x na população Π_1 quando:

$$x'V^{-1}(M_1 - M_2) - \frac{1}{2}(M_1 + M_2)'V^{-1}(M_1 - M_2) \geq 0$$

caso contrário alocar em Π_2 (12)

1.4.2 PARAMETROS DESCONHECIDOS

Sejam:

$X_{\sim 1}^{(g)}, X_{\sim 2}^{(g)}, \dots, X_{\sim n_g}^{(g)}$ amostra aleatória de Π_g

$$X_{\sim i}^{(g)} = (X_{\sim i 1}^{(g)}, \dots, X_{\sim i p}^{(g)}) \quad g=1,2 \quad i=1, \dots, n_g \quad (13)$$

$\bar{X}_{\sim g}^{(g)} = \frac{1}{n_g} \sum_{i=1}^{n_g} X_{\sim i}^{(g)}$ vetor de médias para a amostra do grupo g . É estimador não viesado de \underline{M}_g .

$$S_g = \frac{1}{n_g - 1} \left\{ \sum_{i=1}^{n_g} X_{\sim i}^{(g)} X_{\sim i}^{(g)'} - n_g \bar{X}_{\sim g}^{(g)} \bar{X}_{\sim g}^{(g)'} \right\}$$

estimador não viesado de V_g .

$$S = \frac{(n_1 - 1) S_1 + (n_2 - 1) S_2}{n_1 + n_2 - 2}$$

Matriz de covariâncias amostral combinada. Estimador da matriz V .

Substituindo $\underline{M}_1, \underline{M}_2, V$ por $\bar{X}_{\sim 1}^{(1)}, \bar{X}_{\sim 2}^{(2)}$ e S em (12), obtemos a seguinte regra de classificação amostral:

Alocar \underline{x} em Π_1 quando :

$$\underline{x}' S^{-1} (\bar{X}_{\sim 1}^{(1)} - \bar{X}_{\sim 2}^{(2)}) - \frac{1}{2} (\bar{X}_{\sim 1}^{(1)} + \bar{X}_{\sim 2}^{(2)})' S^{-1} (\bar{X}_{\sim 1}^{(1)} - \bar{X}_{\sim 2}^{(2)}) \geq 0$$

caso contrário, alocar em Π_2 (14)

1.5 CLASSIFICAÇÃO EM DUAS POPULAÇÕES MULTIVARIADAS
HOMOSCEDÁSTICAS

Vamos aplicar as regras apresentadas em (1.2) no caso de se terem duas populações normais multivariadas homoscedásticas, onde \tilde{M}_g ($g=1,2$) é o vetor de médias da g -ésima população e V , positiva definida, é a matriz de covariâncias comum às duas populações.

Segundo a regra de alocação que minimiza o custo esperado de má classificação, TEOREMA 1.1, a região de classificação em Π_1 , ou seja em R_1 , é o conjunto dos \tilde{x} para o qual:

$$\frac{f_1(\tilde{x})}{f_2(\tilde{x})} = \frac{\left[\frac{1}{2\pi}\right]^{\frac{p}{2}} |V|^{-\frac{1}{2}} \exp\left\{-\frac{1}{2}(\tilde{x} - \tilde{M}_1)'V^{-1}(\tilde{x} - \tilde{M}_1)\right\}}{\left[\frac{1}{2\pi}\right]^{\frac{p}{2}} |V|^{-\frac{1}{2}} \exp\left\{-\frac{1}{2}(\tilde{x} - \tilde{M}_2)'V^{-1}(\tilde{x} - \tilde{M}_2)\right\}} \geq \frac{q_2 C(1/2)}{q_1 C(2/1)} \quad (15)$$

Tomando logaritmo e fazendo simplificações chega-se a:

$$\tilde{x}'V^{-1}(\tilde{M}_1 - \tilde{M}_2) - \frac{1}{2}(\tilde{M}_1 + \tilde{M}_2)'V^{-1}(\tilde{M}_1 - \tilde{M}_2) \geq \ln \left\{ \frac{q_2 C(1/2)}{q_1 C(2/1)} \right\} \quad (16)$$

Onde o primeiro termo do lado esquerdo da desigualdade (16) recebe o nome de *Função Linear Discriminante*.

Quando os parâmetros são desconhecidos, o que geralmente acontece nas aplicações práticas, utilizamos (13) para estimar as quantidades M_1 , M_2 e V e apresentamos a seguinte regra de classificação amostral.

Alocar x em Π_1 quando:

$$x' S^{-1} (\bar{X}_{\sim}^{(1)} - \bar{X}_{\sim}^{(2)}) - \frac{1}{2} (\bar{X}_{\sim}^{(1)} + \bar{X}_{\sim}^{(2)})' S^{-1} (\bar{X}_{\sim}^{(1)} - \bar{X}_{\sim}^{(2)}) \geq \ln \left[\frac{q_2 C(1/2)}{q_1 C(2/1)} \right]$$

caso contrário, classificar em Π_2 (17)

A expressão :

$$W = x' S^{-1} (\bar{X}_{\sim}^{(1)} - \bar{X}_{\sim}^{(2)}) - \frac{1}{2} (\bar{X}_{\sim}^{(1)} + \bar{X}_{\sim}^{(2)})' S^{-1} (\bar{X}_{\sim}^{(1)} - \bar{X}_{\sim}^{(2)})$$

recebe o nome de FUNÇÃO DE CLASSIFICAÇÃO AMOSTRAL DE ANDERSON.

Anderson (1958) apresenta o seguinte teorema:

TEOREMA 1.2 - Seja:

$$W = \bar{X}_{\sim}^{\prime} S^{-1} (\bar{X}_{\sim}^{(1)} - \bar{X}_{\sim}^{(2)}) - \frac{1}{2} (\bar{X}_{\sim}^{(1)} + \bar{X}_{\sim}^{(2)})^{\prime} S^{-1} (\bar{X}_{\sim}^{(1)} - \bar{X}_{\sim}^{(2)})$$

com a notação em (13):

$\bar{X}_{\sim}^{(g)}$: média da amostra de $\Pi_g \sim NCM_g(V)$.

S_g : matriz de covariâncias amostral de Π_g .

Então a distribuição de:

$$W = \bar{X}_{\sim}^{\prime} S^{-1} (\bar{X}_{\sim}^{(1)} - \bar{X}_{\sim}^{(2)}) - \frac{1}{2} (\bar{X}_{\sim}^{(1)} + \bar{X}_{\sim}^{(2)})^{\prime} S^{-1} (\bar{X}_{\sim}^{(1)} - \bar{X}_{\sim}^{(2)})$$

quando $n_1 \rightarrow \infty$ e $n_2 \rightarrow \infty$ é:

$$N\left[\frac{1}{2} \alpha^2, \alpha^2\right] \text{ se } \bar{X}_{\sim} \in \Pi_1$$

$$N\left[-\frac{1}{2} \alpha^2, \alpha^2\right] \text{ se } \bar{X}_{\sim} \in \Pi_2$$

$$\text{onde } \alpha^2 = (M_{\sim 1} - M_{\sim 2})^{\prime} V^{-1} (M_{\sim 1} - M_{\sim 2}),$$

sendo α chamada distân-

cia de Mahalanobis.

Considerando $a^2 = (\bar{X}_{\sim}^{(1)} - \bar{X}_{\sim}^{(2)})^{\prime} V^{-1} (\bar{X}_{\sim}^{(1)} - \bar{X}_{\sim}^{(2)})$, Anderson (1973), dá a distribuição das expressões:

$$(W - a^2/2)/a$$

$$(W + a^2/2)/a$$

Onde conclui que são $NC(0,1)$.

1.6 CRITÉRIO DE CLASSIFICAÇÃO BASEADO NA ESTRUTURA DE COVARIÂNCIAS DAS POPULAÇÕES CONCORRENTES

A função de discriminação mais conhecida apresentada na secção (1.4) está baseada no pressuposto de estruturas de covariâncias iguais. No presente item, apresenta-se uma proposta baseada na estrutura de covariâncias diferentes das populações concorrentes.

O entendimento das diferenças das matrizes de covariâncias pode ser conseguido analisando-se as combinações lineares das variáveis $X^{(g)}$, $g=1,2$ com quociente extremo de variâncias, isto é, analisando aquelas combinações lineares definidas com os autovetores associados aos autovalores máximo e mínimo da matriz $V_1^{-1}V_2$ (Flury, 1983). Ver-se-á que a comparação das matrizes de covariâncias analisando certas combinações lineares, proporciona muito mais informações que a simples decisão de igualdade ou não das matrizes V_1 e V_2 , (Flury, 1985).

1.6.1 OBTENÇÃO DAS COMBINAÇÕES LINEARES VIA COMPARAÇÃO DAS MATRIZES DE COVARIÂNCIAS

O teste da União e Interseção introduzido por Roy (1957) é usado para a obtenção das componentes principais generalizadas (Flury, 1983). Tais componentes são de muita utilidade para a nova proposta de discriminação, razão pela qual será descrito a seguir.

O teste de Roy está baseado na seguinte consideração:

Sejam $\underline{X}^{(1)}$ e $\underline{X}^{(2)}$ vetores aleatórios independentemente distribuídos com vetores de médias \underline{M}_1 e \underline{M}_2 e matrizes de covariâncias V_1 e V_2 respectivamente, onde as matrizes são positivas definidas.

Dado que o interesse é construir uma regra de discriminação baseada nas estruturas de covariâncias V_1 e V_2 , é melhor verificar se a suposição $V_1 = V_2$ é adequada. Isto pode ser feito testando a hipótese:

$$H_0: V_1 = V_2$$

$$H_1: V_1 \neq V_2$$

(18)

A solução de (18) pode-se simplificar analisando o comportamento das variâncias das combinações lineares das variáveis aleatórias originais. Portanto, se definirmos:

$$Y^{(1)} = \underline{a}' \underline{X}^{(1)}$$

$$Y^{(2)} = \underline{a}' \underline{X}^{(2)}$$

$$\forall \underline{a} \in \mathbb{R}^p$$

(19)

$$\text{então, } Y^{(g)} \sim (\underline{a}' \underline{M}_g, \underline{a}' V_g \underline{a}) \quad g = 1, 2$$

Para as variâncias das combinações lineares de (19) pode-se construir a seguinte hipótese:

$$H_{0a}: \underline{a}' V_1 \underline{a} = \underline{a}' V_2 \underline{a}$$

$$\forall \underline{a} \in \mathbb{R}^p$$

(20)

Pelo Princípio da União e Intersecção de Roy(1957) a hipótese H_0 de (18) pode ser escrita como a intersecção do conjunto das hipóteses univariadas de (20), ou seja:

$$H_0: V_1 = V_2 \iff \underline{a}'V_1\underline{a} = \underline{a}'V_2\underline{a}, \forall \underline{a} \in \mathbb{R}^p \quad (21)$$

As matrizes V_1 e V_2 são iguais quando

$$\left[\frac{\underline{a}'V_2\underline{a}}{\underline{a}'V_1\underline{a}} \right] = 1$$

ou

$$\max_{\underline{a} \in \mathbb{R}^p} \left[\frac{\underline{a}'V_2\underline{a}}{\underline{a}'V_1\underline{a}} \right] = \min_{\underline{a} \in \mathbb{R}^p} \left[\frac{\underline{a}'V_2\underline{a}}{\underline{a}'V_1\underline{a}} \right] = 1 \quad (22)$$

ou seja, temos que estudar os extremos da função $H(\underline{a})$:

$$H(\underline{a}) = \frac{\underline{a}'V_2\underline{a}}{\underline{a}'V_1\underline{a}} \quad \underline{a} \in \mathbb{R}^p \quad (23)$$

Dado que a função $H(\underline{a})=H(c\underline{a})$ para todo $c \in \mathbb{R}$ ($c \neq 0$), sem perda de generalidade podemos impor $\underline{a}'V_1\underline{a}=1$ e maximizar a função:

$$H_1(\underline{a}) = \underline{a}'V_2\underline{a} - \lambda (\underline{a}'V_1\underline{a} - 1)$$

onde λ é multiplicador de Lagrange.

Mas, a solução do problema conduz à obtenção dos autovalores e autovetores da matriz $V_1^{-1}V_2$.

Então sem perda de generalidade, os autovalores da matriz $V_1^{-1}V_2$ podem ser representados por $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$, e os autovetores associados por $\beta_1, \beta_2, \dots, \beta_p$.

Se λ é autovalor de $V_1^{-1}V_2$ associado ao autovetor " \underline{a} ", com $\underline{a}'V_1\underline{a}=1$, tem-se:

$$\begin{aligned} \underline{a}'V_2\underline{a} - \lambda\underline{a}'V_1\underline{a} &= 0 \\ \underline{a}'V_2\underline{a} &= \lambda \end{aligned} \quad (24)$$

A equação (24) mostra que, se o vetor " \underline{a} " satisfaz a $(V_2 - \lambda V_1)\underline{a} = 0$, então a razão de variâncias das combinações lineares $\underline{a}'X^{(1)}$ e $\underline{a}'X^{(2)}$ é " λ ", logo vale:

$$\begin{aligned} (V_2 - \lambda V_1)\beta_1 &= 0 \\ \beta_1'V_2\beta_1 - \lambda\beta_1'V_1\beta_1 &= 0 \\ \beta_1'V_2\beta_1 &= \lambda_1 \quad \beta_1'V_1\beta_1 = 1 \end{aligned} \quad (25)$$

com :

$$Y_1^{(1)} = \beta_1'X^{(1)} \quad Y_1^{(2)} = \beta_1'X^{(2)}$$

sendo $(Y_1^{(1)}, Y_1^{(2)})$ as combinações lineares com maior quociente de variâncias.

O passo seguinte é procurar as combinações lineares que têm o maior quociente de variâncias entre todas as combinações lineares $\underline{a}'X^{(1)}$ e $\underline{a}'X^{(2)}$ que estão não correlacionadas com $Y_1^{(1)}$ e $Y_1^{(2)}$ respectivamente. Ou seja, deve-se maximizar $H(\underline{a})$ tal que:

$$H(\underline{a}) = \frac{\underline{a}' V_2 \underline{a}}{\underline{a}' V_1 \underline{a}} \quad \text{razão das variâncias}$$

$V \underline{a} \in \mathbb{R}^P$

com as restrições:

$$(i) \quad \underline{a}' V_1 \underline{a} = 1 \tag{26}$$

$$(ii) \quad \text{Cov}(\underline{a}' X_1^{(1)}, Y_1^{(1)}) = \underline{a}' V_1 \beta_1 = 0$$

$$(iii) \quad \text{Cov}(\underline{a}' X_1^{(2)}, Y_1^{(2)}) = \underline{a}' V_2 \beta_1 = 0$$

Usando multiplicadores de Lagrange e a condição $\underline{a}' (V_2 - \lambda V_1) \beta_1 = 0$, só se tem que maximizar:

$$H_2(\underline{a}) = \underline{a}' V_2 \underline{a} - \lambda (\underline{a}' V_1 \underline{a} - 1) - 2v_1 (\underline{a}' V_1 \beta_1 - 0) \tag{27}$$

onde o vetor de derivadas parciais é :

$$\frac{\partial H_2(\underline{a})}{\partial \underline{a}} = 2 V_2 \underline{a} - 2 \lambda V_1 \underline{a} - 2v_1 V_1 \beta_1 \tag{28}$$

e o vetor " \underline{a} " que maximiza (27) deve satisfazer à equação (28) igual a zero. Depois de alguns cálculos chega-se a :

$$(V_2 - \lambda V_1) \underline{a} = 0 \tag{29}$$

A equação (29) mostra que os novos valores " λ " e " $\underline{\beta}$ " procurados satisfazem à mesma equação $(V_2 - \lambda V_1) = 0$, que a solução anterior λ_1 e $\underline{\beta}_1$. Dado que λ_1 e seu correspondente autovetor não satisfazem (ii) e (iii) de (26), os candidatos óbvios são λ_2 e $\underline{\beta}_2$ que satisfazem :

$$\begin{aligned} (V_2 - \lambda_2 V_1) \underline{\beta}_2 &= 0 \\ \underline{\beta}_2' V_1 \underline{\beta}_2 &= 1 \quad \underline{\beta}_2' V_2 \underline{\beta}_2 = \lambda_2 \\ \underline{\beta}_2' V_1 \underline{\beta}_1 &= 0 \quad \underline{\beta}_2' V_2 \underline{\beta}_1 = 0 \end{aligned} \tag{30}$$

e se tem

$$Y_2^{(1)} = \underline{\beta}_2' X^{(1)} \quad Y_2^{(2)} = \underline{\beta}_2' X^{(2)}$$

Que são o segundo par de combinações lineares com maior quociente de variâncias entre todas as combinações não correlacionadas com $Y_1^{(1)}$ e $Y_1^{(2)}$.

O processo de obtenção das combinações lineares continua e pode-se assumir que os primeiros q pares de combinações lineares ($1 \leq q < p$) podem ser definidas como:

$$Y_i^{(1)} = \underline{\beta}_i' X^{(1)} \quad Y_i^{(2)} = \underline{\beta}_i' X^{(2)}$$

onde $\underline{\beta}_i$ é o i -ésimo autovetor da matriz $V_1^{-1} V_2$ associado ao autovalor λ_i , satisfazendo a:

$$(V_2 - \lambda_i V_1) \underline{\beta}_i = 0 \tag{31}$$

$$\langle 1 \rangle \left\{ \begin{aligned} \text{Var}(Y_i^{(1)}) &= \underline{\beta}_i' V_1 \underline{\beta}_i = 1 \\ \text{Var}(Y_i^{(2)}) &= \underline{\beta}_i' V_2 \underline{\beta}_i = \lambda_i \end{aligned} \right.$$

$$\langle 2 \rangle \left\{ \begin{aligned} \text{Cov}(Y_i^{(1)}, Y_j^{(1)}) &= \underline{\beta}_i' V_1 \underline{\beta}_j = 0 \\ \text{Cov}(Y_i^{(2)}, Y_j^{(2)}) &= \underline{\beta}_i' V_2 \underline{\beta}_j = 0 \end{aligned} \right. \quad 1 \leq i < j \leq q$$

Agora desejam-se as $(q+1)$ -ésimas combinações lineares com quociente máximo de variâncias entre todas as combinações lineares $\tilde{a}'\tilde{X}_1^{(1)}$ e $\tilde{a}'\tilde{X}_1^{(2)}$ que estão não correlacionadas com $Y_i^{(1)}$ e $Y_i^{(2)}$, $1 \leq i \leq q$, sujeito a $\tilde{a}'V_1\tilde{a}=1$, ou seja, maximizar:

$$H(\tilde{a}) = \frac{\tilde{a}'V_2\tilde{a}}{\tilde{a}'V_1\tilde{a}} \quad \text{razão das variâncias}$$

$$\forall \tilde{a} \in \mathbb{R}^p$$

com as restrições:

$$i) \quad \tilde{a}'V_1\tilde{a} = 1 \quad (32)$$

$$ii) \quad \text{Cov}(\tilde{a}'\tilde{X}_1^{(1)}, Y_i^{(1)}) = \tilde{a}'V_1\beta_i = 0 \quad 1 \leq i \leq q$$

$$iii) \quad \text{Cov}(\tilde{a}'\tilde{X}_1^{(2)}, Y_i^{(2)}) = \tilde{a}'V_2\beta_i = 0$$

Pela condição $(V_2 - \lambda V_1)\beta_i = 0$ de (31), (iii) de (32) pode ser omitida e só se vai maximizar a função :

$$H_{q+1}(\tilde{a}) = \tilde{a}'V_2\tilde{a} - \lambda(\tilde{a}'V_1\tilde{a} - 1) - 2 \sum_{i=1}^q v_i \tilde{a}'V_1\beta_i \quad (33)$$

com λ e v_i ($1 \leq i \leq q$) multiplicadores de Lagrange.

O vetor de derivadas parciais igual a zero é :

$$\frac{\partial H_{q+1}(\tilde{a})}{\partial \tilde{a}} = 2V_2\tilde{a} - 2\lambda V_1\tilde{a} - 2 \sum_{i=1}^q v_i V_1\beta_i = 0 \quad (34)$$

Pré-multiplicando (34) por β_j' ($1 \leq j \leq q$, $i \neq j$) e pelas condições (ii) e (iii) de (32), os dois primeiros termos desaparecem, e por « 2 » de (31) a última soma também desaparece.

Dado que $\beta_1' V_1 \beta_1 = 1$ (por « 1 » de (31)) conclui-se que $v_j = 0$. De tal maneira que a equação (34) conduz à :

$$(V_2 - \lambda V_1) \underline{a} = 0 \quad (35)$$

a qual mostra que "λ" e "a" procurados satisfazem à mesma equação (29) que as soluções prévias λ_i e β_i ($1 \leq i \leq q$). Dado que os "q" maiores autovalores e seus autovetores associados não satisfazem às condições (ii) e (iii) de (32) pela suposição « 1 » de (31), os seguintes candidatos são λ_{q+1} e β_{q+1} , com os quais definimos as (q+1)-ésimas combinações lineares:

$$Y_{q+1}^{(1)} = \beta_{q+1}' X^{(1)} \quad Y_{q+1}^{(2)} = \beta_{q+1}' X^{(2)}$$

satisfazendo a :

$$\llcorner 1 \llcorner \left\{ \begin{array}{l} \text{Var}(Y_{q+1}^{(1)}) = \beta_{q+1}' V_1 \beta_{q+1} = 1 \\ \text{Var}(Y_{q+1}^{(2)}) = \beta_{q+1}' V_2 \beta_{q+1} = \lambda_{q+1} \end{array} \right. \quad (36)$$

$$\llcorner 2 \llcorner \left\{ \begin{array}{l} \text{Cov}(Y_{q+1}^{(1)}, Y_i^{(1)}) = \beta_{q+1}' V_1 \beta_i = 0 \\ \text{Cov}(Y_{q+1}^{(2)}, Y_i^{(2)}) = \beta_{q+1}' V_2 \beta_i = 0 \end{array} \right. \quad 1 \leq i \leq q$$

Dado que V_1 e V_2 são matrizes simétricas definidas positivas, pode-se continuar com o procedimento e no último passo λ_p e β_p serão usados para definir as últimas combinações lineares $Y_p^{(1)} = \beta_p' X_p^{(1)}$ e $Y_p^{(2)} = \beta_p' X_p^{(2)}$ satisfazendo às mesmas condições de (31) com $1 \leq i \leq p$.

Os resultados anteriores, são resumidos no teorema apresentado a seguir (Flury, 1983).

TEOREMA 1.3. - Dados os vetores aleatórios $X_g^{(1)}$ e $X_g^{(2)}$ independentes, com parâmetros de locação e dispersão M_g e V_g $g=1,2$ respectivamente, sendo que V_1 e V_2 são positivas definidas, definem-se as combinações lineares:

$$Y_i^{(1)} = \beta_i' X_i^{(1)} \quad 1 \leq i \leq p$$

$$Y_i^{(2)} = \beta_i' X_i^{(2)}$$

usando os autovetores $B = (\beta_1, \dots, \beta_p)$ da matriz $V_1^{-1}V_2$.
Então:

$$1) \quad \text{Var}(Y_i^{(1)}) = I_p$$

$$\text{Var}(Y_i^{(2)}) = \Lambda \quad \text{com}$$

$$I_p = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad \Lambda = \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_p \end{bmatrix}$$

λ_i i-ésimo autovalor de $V_1^{-1}V_2$, isto é, as combinações lineares, $Y_i^{(1)} = (Y_1^{(1)}, \dots, Y_p^{(1)})$, $Y_i^{(2)} = (Y_1^{(2)}, \dots, Y_p^{(2)})$ estão não correlacionadas em ambos os grupos.

ii) $(Y_i^{(1)}, Y_i^{(2)})$ é o i -ésimo par de combinações lineares com maior quociente de variâncias de todas as combinações lineares não correlacionadas com as anteriores.

As combinações lineares $(Y_i^{(1)}, Y_i^{(2)})$ $1 \leq i \leq p$ denominam-se Componentes Principais Generalizadas. (Flury, 1983).

Dado que a nossa atenção está no caso V_1 ser diferente de V_2 , então, a solução de (22) conduz à escolha das combinações lineares $(Y_1^{(1)}, Y_1^{(2)})$ e $(Y_p^{(1)}, Y_p^{(2)})$ com quocientes de variâncias λ_1 e λ_p , respectivamente. Usaremos tais combinações lineares para propor um novo critério de discriminação.

No caso $V_1 = V_2$, as combinações lineares não são de utilidade para a construção da regra de discriminação, porque em tal situação todos os autovalores da matriz $V_1^{-1}V_2$ valem um. A mesma observação é válida no caso de proporcionalidade entre V_1 e V_2 .

Nas aplicações práticas a igualdade entre V_1 e V_2 é facilmente avaliada com o maior e menor autovalores da matriz $S_1^{-1}S_2$.

1.6.2 UMA PROPOSTA DE DISCRIMINAÇÃO

Mesmo que os resultados apresentados em (1.6.1) não sejam essencialmente novos, eles são pouco conhecidos em aplicações práticas.

As combinações lineares $\underline{y}^{(1)}$ e $\underline{y}^{(2)}$ não são correlacionadas em ambos os grupos, e para compreender as diferenças entre V_1 e V_2 , é mais fácil analisar as variâncias de tais combinações.

Segundo a demonstração do TEOREMA 1.3, toda informação a respeito das diferenças em variabilidade entre os vetores $\underline{X}^{(1)}$ e $\underline{X}^{(2)}$ está expressa nos autovalores, " λ_j " afastados do valor um, daí o interesse especial nas combinações lineares:

$$Y_i^{(1)} = \beta_i' \underline{X}^{(1)} \quad Y_i^{(2)} = \beta_i' \underline{X}^{(2)} \quad i=1,p \quad (37)$$

e não nas $Y_k^{(g)}$ $g=1,2$, $k \neq i$, que não contribuem para estabelecer as diferenças entre V_1 e V_2 , isto é, descartam-se todas as combinações lineares que têm quociente de variâncias perto de um.

Em muitas aplicações práticas tem-se observado que os autovalores extremos diferem marcadamente de "um", sendo que os outros estão próximos de "um", (Flury, 1985). De um modo geral, se alguns autovalores afastam-se de "um", os que mais o fazem são os extremos. Portanto, concentram-se as atenções somente nas combinações lineares com QUOCIENTES DE VARIANCIAS EXTREMOS, sendo as combinações:

POPULAÇÃO	QUOCIENTE DE VARIANCIAS	
	Máximo	Mínimo
Um	$Y_1^{(1)} = \beta_1' X_1^{(1)}$	$Y_p^{(1)} = \beta_p' X_1^{(1)}$
Dois	$Y_1^{(2)} = \beta_1' X_2^{(2)}$	$Y_p^{(2)} = \beta_p' X_2^{(2)}$

(38)

respectivamente.

Segundo as suposições iniciais para $X_1^{(1)}$ e $X_2^{(2)}$, os parâmetros populacionais das combinações de (38) são :

população Um:

$$E(Y_1^{(1)}) = \beta_1' E(X_1^{(1)}) = \beta_1' M_1$$

$$E(Y_p^{(1)}) = \beta_p' E(X_1^{(1)}) = \beta_p' M_1$$

$$\text{Var}(Y_1^{(1)}) = \beta_1' V_1 \beta_1 = 1$$

$$\text{Var}(Y_p^{(1)}) = \beta_p' V_1 \beta_p = 1$$

$$\text{Cov}(Y_1^{(1)}, Y_p^{(1)}) = \beta_1' V_1 \beta_p = 0$$

(39)

população Dois:

$$E(Y_1^{(2)}) = \beta_1' E(X_2^{(2)}) = \beta_1' M_2$$

$$E(Y_p^{(2)}) = \beta_p' E(X_2^{(2)}) = \beta_p' M_2$$

$$\text{Var}(Y_1^{(2)}) = \beta_1' V_2 \beta_1 = \lambda_1$$

$$\text{Var}(Y_p^{(2)}) = \beta_p' V_2 \beta_p = \lambda_p$$

$$\text{Cov}(Y_1^{(2)}, Y_p^{(2)}) = \beta_1' V_2 \beta_p = 0$$

Para simplificar o desenvolvimento posterior considere-se a notação:

$$y = \begin{bmatrix} Y_1 \\ Y_p \end{bmatrix} = \begin{bmatrix} Y_{\max} \\ Y_{\min} \end{bmatrix} \in \mathbb{R}^2$$

$$y^{(g)} = \begin{bmatrix} Y_1^{(g)} \\ Y_p^{(g)} \end{bmatrix} = \begin{bmatrix} Y_{\max}^{(g)} \\ Y_{\min}^{(g)} \end{bmatrix} \in \mathbb{R}^2$$

$$\mu^{(1)} = \begin{bmatrix} \beta_1' M_1 \\ \beta_p' M_1 \end{bmatrix} = \begin{bmatrix} \mu_1^{(1)} \\ \mu_2^{(1)} \end{bmatrix} \in \mathbb{R}^2$$

(40)

$$\mu^{(2)} = \begin{bmatrix} \beta_1' M_2 \\ \beta_p' M_2 \end{bmatrix} = \begin{bmatrix} \mu_1^{(2)} \\ \mu_2^{(2)} \end{bmatrix} \in \mathbb{R}^2$$

$$\Sigma_1 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

$$\Sigma_2 = \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{bmatrix}$$

e tem-se a situação:

duas populações bivariadas Π_1 e Π_2 com parâmetros de locação $\mu^{(1)}$ e $\mu^{(2)}$, parâmetros de dispersão Σ_1 e Σ_2 e com funções de densidade de probabilidade $f_1(y)$ e $f_2(y)$.

Deseja-se usar tal informação para classificar o indivíduo $x \in \mathbb{R}^p$. As outras suposições com respeito aos custos de má classificação e as probabilidades a priori são as mesmas que as dadas para (1.2) do capítulo 1.

As regiões de classificação que minimizam o custo esperado de má classificação, são dadas pelo

TEOREMA 1.4. - Se q_1 e q_2 são as probabilidades a priori das populações Π_1 e Π_2 com funções de densidade $f_1(y)$ e $f_2(y)$, e se o custo de classificar uma observação de Π_1 como de Π_2 é $C(2/1)$ e uma observação de Π_2 como de Π_1 é $C(1/2)$, então as regiões de classificação R_1 e R_2 definidas por:

$$R_1 : \frac{f_1(y)}{f_2(y)} \geq \frac{q_2 C(1/2)}{q_1 C(2/1)}$$

$$R_2 : \frac{f_1(y)}{f_2(y)} < \frac{q_2 C(1/2)}{q_1 C(2/1)}$$

minimizam o custo esperado de má classificação.

De onde obtemos a seguinte regra:

\tilde{x} é alocado em Π_1 se :

$$\frac{f_1(\tilde{y})}{f_2(\tilde{y})} \geq \frac{q_2 C(1/2)}{q_1 C(2/1)} \quad (41)$$

caso contrário é alocado em Π_2

onde $\tilde{y} \in \mathbb{R}^2$ é o vetor transformado segundo:

$$\tilde{y} = \begin{bmatrix} \beta_1' X \\ \beta_p' X \end{bmatrix} \in \mathbb{R}^2$$

β_1 e β_p são os autovetores associados aos autovalores máximo e mínimo λ_1 e λ_p da matriz $V_1^{-1}V_2$.

CAPÍTULO 2

PROBLEMA DE DISCRIMINAÇÃO NO CASO NORMAL HETEROSCEDÁSTICO

2.1 INTRODUÇÃO

Quando o conjunto de variâncias e covariâncias de uma população normal multivariada não é o mesmo que o conjunto de variâncias e covariâncias da outra população normal multivariada, pode-se aplicar a teoria apresentada para matrizes de covariâncias iguais, só que $\ln(f_1(\underline{x})/f_2(\underline{x}))$ é uma função quadrática.

Neste capítulo serão apresentados, o procedimento usado até agora e a nova proposta de discriminação, considerando as populações Π_1 e Π_2 normais multivariadas com diferentes estruturas de covariâncias, isto é, $N(\underline{M}_1, V_1)$ e $N(\underline{M}_2, V_2)$, onde \underline{M}_g é o vetor de médias da população g , e V_g positiva definida, a correspondente matriz de covariâncias, $g=1,2$.

A densidade de Π_g é:

$$f_g(\underline{x}) = f_g(\underline{x}, \underline{M}_g, V_g) = \frac{1}{(2\pi)^{p/2} |V_g|^{1/2}} \exp \left\{ -\frac{1}{2} (\underline{x} - \underline{M}_g)' V_g^{-1} (\underline{x} - \underline{M}_g) \right\}$$

$g = 1, 2$ (1)

E foi visto no capítulo 1 que as regiões R_1 e R_2 que minimizam o custo esperado de má classificação são encontradas de acordo com o quociente de densidades.

2.2 CONSTRUÇÃO DA REGRA DE CLASSIFICAÇÃO QUADRÁTICA

Neste caso as regiões R_1 e R_2 que minimizam o custo esperado de má classificação consideram a razão:

$$\frac{f_1(\tilde{x})}{f_2(\tilde{x})} = \frac{(2\pi)^{p/2} |V_2|^{-1/2} \exp\left\{-\frac{1}{2}(\tilde{x} - \tilde{M}_1)' V_1^{-1}(\tilde{x} - \tilde{M}_1)\right\}}{(2\pi)^{p/2} |V_1|^{-1/2} \exp\left\{-\frac{1}{2}(\tilde{x} - \tilde{M}_2)' V_2^{-1}(\tilde{x} - \tilde{M}_2)\right\}} \quad (2)$$

$$= \frac{|V_2|^{1/2}}{|V_1|^{1/2}} \exp\left\{-\frac{1}{2}(\tilde{x} - \tilde{M}_1)' V_1^{-1}(\tilde{x} - \tilde{M}_1) + \frac{1}{2}(\tilde{x} - \tilde{M}_2)' V_2^{-1}(\tilde{x} - \tilde{M}_2)\right\}$$

pelo teorema 1 de (1.1) a região R_1 está definida por:

$$R_1: \frac{|V_2|^{1/2}}{|V_1|^{1/2}} \exp\left\{-\frac{1}{2}(\tilde{x} - \tilde{M}_1)' V_1^{-1}(\tilde{x} - \tilde{M}_1) + \frac{1}{2}(\tilde{x} - \tilde{M}_2)' V_2^{-1}(\tilde{x} - \tilde{M}_2)\right\} \geq \left[\frac{q_2 C(1/2)}{q_1 C(2/1)} \right]$$

Aplicando o logaritmo tem-se:

$$\ln \left[\frac{|V_2|^{1/2}}{|V_1|^{1/2}} \right] - \frac{1}{2}(\tilde{x} - \tilde{M}_1)' V_1^{-1}(\tilde{x} - \tilde{M}_1) + \frac{1}{2}(\tilde{x} - \tilde{M}_2)' V_2^{-1}(\tilde{x} - \tilde{M}_2) \geq \ln \left[\frac{q_2 C(1/2)}{q_1 C(2/1)} \right] \quad (3)$$

ou, equivalentemente:

$$-\frac{1}{2} \tilde{x}'(V_1^{-1} - V_2^{-1})\tilde{x} + \tilde{x}'(V_1^{-1}M_1 - V_2^{-1}M_2) + C \geq \ln \left\{ \frac{q_2 C(1/2)}{q_1 C(2/1)} \right\} \quad (4)$$

$$\text{onde } C = \ln \left[\frac{|V_2|^{1/2}}{|V_1|^{1/2}} \right] - \frac{1}{2} (M_1' V_1^{-1} M_1 - M_2' V_2^{-1} M_2)$$

e com o resultado obtido, formula-se o seguinte teorema:

TEOREMA 2.1 - Se Π_g , $g = 1, 2$ tem a densidade (1), as regiões que minimizam o custo esperado de má classificação são dadas pelos valores de \tilde{x} que satisfazem às seguintes desigualdades:

$$R_1: -\frac{1}{2} \tilde{x}'(V_1^{-1} - V_2^{-1})\tilde{x} + \tilde{x}'(V_1^{-1}M_1 - V_2^{-1}M_2) + C \geq \ln \left\{ \frac{q_2 C(1/2)}{q_1 C(2/1)} \right\}$$

$$R_2: -\frac{1}{2} \tilde{x}'(V_1^{-1} - V_2^{-1})\tilde{x} + \tilde{x}'(V_1^{-1}M_1 - V_2^{-1}M_2) + C < \ln \left\{ \frac{q_2 C(1/2)}{q_1 C(2/1)} \right\}$$

De onde surge diretamente a regra de classificação para as duas populações normais multivariadas com diferente estrutura de covariâncias, que é a seguinte :

Alocar \tilde{x} na população Π_1 se :

$$-\frac{1}{2} \tilde{x}'(V_1^{-1} - V_2^{-1})\tilde{x} + \tilde{x}'(V_1^{-1}M_1 - V_2^{-1}M_2) + C \geq \ln \left[\frac{q_2 C(1/2)}{q_1 C(2/1)} \right]$$

caso contrário alocar \tilde{x} em Π_2 (5)

Para obter o resultado anterior foi suposto que as duas distribuições normais têm parâmetros conhecidos. Mas, em muitas aplicações desta teoria, os parâmetros não são conhecidos e têm que ser estimados com base nos resultados amostrais das populações Π_1 e Π_2 . Substituindo assim, as quantidades amostrais $\bar{X}_1^{(1)}$, $\bar{X}_1^{(2)}$, S_1 , S_2 em M_1 , M_2 , V_1 , V_2 respectivamente, conforme as expressões (13) do capítulo 1, temos então, a regra de classificação quadrática amostral para populações com distribuição normal e diferentes matrizes de variâncias e covariâncias, que é a seguinte:

Alocar a observação \tilde{x} em Π_1 se:

$$\hat{R}_1: -\frac{1}{2} \tilde{x}'(S_1^{-1} - S_2^{-1})\tilde{x} + \tilde{x}'(S_1^{-1}\bar{X}_1^{(1)} - S_2^{-1}\bar{X}_1^{(2)}) + C \geq \ln \left[\frac{q_2 C(1/2)}{q_1 C(2/1)} \right]$$

caso contrário alocá-lo em Π_2 com

$$\hat{C} = \ln \left[\frac{|S_2|^{1/2}}{|S_1|^{1/2}} \right] - \frac{1}{2} (\bar{X}_1^{(1)}, S_1^{-1}\bar{X}_1^{(1)} - \bar{X}_1^{(2)}, S_2^{-1}\bar{X}_1^{(2)}) \quad (6)$$

Que será chamada de Regra de Classificação Quadrática Amostral de Anderson.

2.3 CONSTRUÇÃO DE UM NOVO MÉTODO DE DISCRIMINAÇÃO

2.3.1 PARAMETROS CONHECIDOS

Considerando os mesmos supostos iniciais de haver duas populações normais multivariadas Π_1 e Π_2 com estrutura de covariâncias diferentes e usando os resultados apresentados nos itens (1.6.1) e (1.6.2) do capítulo anterior, isto é, tem-se:

O vetor $\underline{x}^{(g)} = (X_1^{(g)}, X_2^{(g)}, \dots, X_p^{(g)})$ $g = 1, 2$

sob Π_1 tem distribuição $N_p(\underline{M}_1, V_1)$ e

sob Π_2 tem distribuição $N_p(\underline{M}_2, V_2)$

E quer-se estabelecer um critério para classificar um indivíduo com medições $\underline{x} \in \mathbb{R}^p$ como pertencente a Π_1 ou Π_2 . Então, são propostos os seguintes passos:

1^o) Transformar as variáveis $\underline{x}^{(g)}$ normais multivariadas em univariadas através das combinações lineares:

$$Y^{(g)} = \underline{a}' \underline{x}^{(g)}, \quad g = 1, 2$$

E tomar aquelas com quocientes extremos de variâncias, que são:

$$\tilde{Y}^{(1)} = \begin{bmatrix} Y_{\max}^{(1)} \\ Y_{\min}^{(1)} \end{bmatrix} = \begin{bmatrix} \beta_1 X^{(1)} \\ \beta_p X^{(1)} \end{bmatrix} \in \mathbb{R}^2$$

$$\tilde{Y}^{(2)} = \begin{bmatrix} Y_{\max}^{(2)} \\ Y_{\min}^{(2)} \end{bmatrix} = \begin{bmatrix} \beta_1 X^{(2)} \\ \beta_p X^{(2)} \end{bmatrix} \in \mathbb{R}^2$$

com distribuições $N_2(\mu^{(1)}, \Sigma_1)$ e $N_2(\mu^{(2)}, \Sigma_2)$ respectivamente, onde:

$$\mu^{(1)} = \begin{bmatrix} \mu_1^{(1)} \\ \mu_2^{(1)} \end{bmatrix} \quad \mu^{(2)} = \begin{bmatrix} \mu_1^{(2)} \\ \mu_2^{(2)} \end{bmatrix}$$

(7)

$$\Sigma_1 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} = I_2 \quad \Sigma_2 = \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{bmatrix}$$

λ_1 e λ_p : máximo e mínimo autovalores da matriz $V_1^{-1}V_2$ e
 β_1 e β_p : autovetores associados a λ_1 e λ_p conforme o teorema 1.3.

2^o) Dado que $\tilde{Y} = \begin{pmatrix} \beta_1' \\ \beta_p \end{pmatrix} X$ tem distribuição $N_2(\mu^{(1)}, \Sigma_1 = I_2)$

sob Π_1 e distribuição $N_2(\mu^{(2)}, \Sigma_2)$ sob Π_2 , o vetor $x \in \mathbb{R}^p$ será bem alocado em Π_1 e Π_2 , sempre que \tilde{Y} o for em uma das duas populações transformadas.

Mas, a densidade transformada f_g é:

$$f_g(x, \mu^{(g)}, \Sigma_g) = \frac{1}{(2\pi)^{p/2} |\Sigma_g|^{1/2}} \exp \left\{ -\frac{1}{2} (x - \mu^{(g)})' \Sigma_g^{-1} (x - \mu^{(g)}) \right\} \quad (8)$$

E as regiões R_1 e R_2 que minimizam o custo esperado de má classificação consideram a razão:

$$\frac{f_1(x, \mu^{(1)}, \Sigma_1)}{f_2(x, \mu^{(2)}, \Sigma_2)} = \frac{(2\pi)^{p/2} |\Sigma_2|^{1/2} \exp \left\{ -\frac{1}{2} (x - \mu^{(1)})' \Sigma_1^{-1} (x - \mu^{(1)}) \right\}}{(2\pi)^{p/2} |\Sigma_1|^{1/2} \exp \left\{ -\frac{1}{2} (x - \mu^{(2)})' \Sigma_2^{-1} (x - \mu^{(2)}) \right\}}$$

E pelo teorema 1.4 tem-se:

$$R_1: \frac{|\Sigma_2|^{1/2}}{|\Sigma_1|^{1/2}} \exp \left\{ -\frac{1}{2} (x - \mu^{(1)})' \Sigma_1^{-1} (x - \mu^{(1)}) + \frac{1}{2} (x - \mu^{(2)})' \Sigma_2^{-1} (x - \mu^{(2)}) \right\} \geq \frac{q_2 C(1/2)}{q_1 C(2/1)}$$

Aplicando logaritmo:

$$\begin{aligned}
 R_1: & -\frac{1}{2} \chi' (I_2 - \Sigma_2^{-1}) \chi + \chi' (I_2 \mu_1^{(1)} - \Sigma_2^{-1} \mu^{(2)}) \\
 & - \frac{1}{2} (\mu^{(1)}, \mu^{(1)} - \mu^{(2)}, \Sigma_2^{-1} \mu^{(2)}) + \frac{1}{2} \ln \frac{|\Sigma_2|}{|\Sigma_1|} \geq \ln \left\{ \frac{q_2 C(1/2)}{q_1 C(2/1)} \right\}
 \end{aligned}
 \tag{9}$$

$$\begin{aligned}
 R_2: & -\frac{1}{2} \chi' (I_2 - \Sigma_2^{-1}) \chi + \chi' (I_2 \mu^{(1)} - \Sigma_2^{-1} \mu^{(2)}) \\
 & - \frac{1}{2} (\mu^{(1)}, \mu^{(1)} - \mu^{(2)}, \Sigma_2^{-1} \mu^{(2)}) + \frac{1}{2} \ln \frac{|\Sigma_2|}{|\Sigma_1|} < \ln \left\{ \frac{q_2 C(1/2)}{q_1 C(2/1)} \right\}
 \end{aligned}$$

Resultado que pode ser expresso na forma do seguinte teorema:

TEOREMA 2.2 - Se Π_g , $g = 1, 2$ tem densidades (7), as regiões R_1 e R_2 que minimizam o custo esperado são dadas pelos valores χ que satisfazem às seguintes desigualdades:

$$R_1: -\frac{1}{2} \chi' (I_2 - \Sigma_2^{-1}) \chi + \chi' (I_2 \mu^{(1)} - \Sigma_2^{-1} \mu^{(2)}) + d \geq \ln \left\{ \frac{q_2 C(1/2)}{q_1 C(2/1)} \right\}$$

$$R_2: -\frac{1}{2} \chi' (I_2 - \Sigma_2^{-1}) \chi + \chi' (I_2 \mu^{(1)} - \Sigma_2^{-1} \mu^{(2)}) + d < \ln \left\{ \frac{q_2 C(1/2)}{q_1 C(2/1)} \right\}$$

onde: $d = \frac{1}{2} \ln |\Sigma_2| - \frac{1}{2} (\mu^{(1)}, \mu^{(1)} - \mu^{(2)}, \Sigma_2^{-1} \mu^{(2)})$

de onde surge a proposta de classificação para duas populações normais com diferente estrutura de covariâncias, que é a seguinte:

Alocar \underline{x} na população Π_1 quando:

$$-\frac{1}{2} \underline{X}'(\mathbf{I}_2 - \Sigma_2^{-2})\underline{X} + \underline{X}'(\mathbf{I}_2 \underline{\mu}^{(1)} - \Sigma_2^{-1} \underline{\mu}^{(2)}) + d \geq \ln \left(\frac{q_2 C(1/2)}{q_1 C(2/1)} \right)$$

caso contrário alocar em Π_2

(10)

$$\text{com } \underline{X} = \begin{bmatrix} \beta_1' \\ \beta_2' \end{bmatrix} \underline{x}$$

2.3.2 PARAMETROS DESCONHECIDOS

Para apresentar os resultados em (2.3.1) foi admitido que as duas distribuições tem parâmetros conhecidos, mas, em muitas aplicações práticas os parâmetros têm que ser estimados com base nos resultados amostrais das populações Π_1 e Π_2 .

Sejam:

$$\begin{aligned} X_{\sim 1}^{(1)}, X_{\sim 2}^{(1)}, \dots, X_{\sim n_1}^{(1)} & \text{ com distribuição } N(\underline{M}_1, V_1) \text{ e} \\ X_{\sim 1}^{(2)}, X_{\sim 2}^{(2)}, \dots, X_{\sim n_2}^{(2)} & \text{ com distribuição } N(\underline{M}_2, V_2) \end{aligned}$$

a partir das quais obtêm-se as amostras:

$\tilde{y}_1^{(1)}, \tilde{y}_2^{(1)}, \dots, \tilde{y}_{n_1}^{(1)}$ com distribuição $N(\mu^{(1)}, \Sigma_1)$ e

$\tilde{y}_1^{(2)}, \tilde{y}_2^{(2)}, \dots, \tilde{y}_{n_2}^{(2)}$ com distribuição $N(\mu^{(2)}, \Sigma_2)$

onde:

$$\tilde{y}_i^{(g)} = \begin{pmatrix} b_1' X_i^{(g)} \\ b_p' X_i^{(g)} \end{pmatrix} \in \mathbb{R}^2 \quad \begin{matrix} i=1, \dots, n_g \\ g=1,2 \end{matrix} \quad (11)$$

b_1 e b_p são autovetores associados aos autovalores

r_1 e r_p da matriz $S_1^{-1} S_2$. S_1 e S_2 foram obtidas conforme (13) do capítulo 1.

Fazendo

$$\hat{\tilde{y}}^{(1)} = \tilde{y}^{(1)} = \begin{pmatrix} b_1' \bar{X}^{(1)} \\ b_p' \bar{Y}^{(1)} \end{pmatrix} \in \mathbb{R}^2 \quad (12)$$

$$\hat{\tilde{y}}^{(2)} = \tilde{y}^{(2)} = \begin{pmatrix} b_1' \bar{X}^{(2)} \\ b_p' \bar{Y}^{(2)} \end{pmatrix} \in \mathbb{R}^2$$

$$\hat{\Sigma}_1 = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} = I_2$$

$$\hat{\Sigma}_2 = \begin{pmatrix} r_1 & 0 \\ 0 & r_p \end{pmatrix}$$

$$\hat{d} = \frac{1}{2} \ln \left(\frac{r_1 r_p}{r_1 r_p} \right) - \frac{1}{2} \left[\bar{Y}^{(1)'} \bar{Y}^{(1)} - \bar{Y}^{(2)'} \hat{\Sigma}_2^{-1} \bar{Y}^{(2)} \right]$$

Tem-se agora, a seguinte proposta de classificação amostral para populações normais multivariadas com diferente estrutura de covariâncias:

Alocar uma observação \underline{x} na população Π_1 quando:

$$\hat{R}_1: -\frac{1}{2} \underline{x}'(\mathbf{I}_2 - \hat{\Sigma}_2^{-1})\underline{x} + \underline{x}'(\mathbf{I}_2 \bar{\underline{Y}}^{(1)} - \hat{\Sigma}_2^{-1} \bar{\underline{Y}}^{(2)}) + \hat{d} \geq \ln \left\{ \frac{q_2 C(1/2)}{q_1 C(2/1)} \right\}$$

e em Π_2 quando:

$$\hat{R}_2: -\frac{1}{2} \underline{x}'(\mathbf{I}_2 - \hat{\Sigma}_2^{-1})\underline{x} + \underline{x}'(\mathbf{I}_2 \bar{\underline{Y}}^{(1)} - \hat{\Sigma}_2^{-1} \bar{\underline{Y}}^{(2)}) + \hat{d} < \ln \left\{ \frac{q_2 C(1/2)}{q_1 C(2/1)} \right\}$$

(13)

2.3.3 AVALIAÇÃO DO PROCEDIMENTO DE DISCRIMINAÇÃO

Dado que é importante conhecer o desempenho da função de discriminação proposta em (2.3.1), apresentamos a seguir as tentativas feitas que conduzem à obtenção da sua distribuição com a finalidade de avaliar a probabilidade total de má classificação. Têm-se os seguintes resultados (Rao e Mitra, 1971):

LEMA 9.1.2 - Seja $Y \sim N_p(\underline{\mu}, \mathbf{I})$. Então a estatística

$$\underline{Y}'\mathbf{A}\underline{Y} + \underline{b}'\underline{Y} + E$$

tem distribuição $\chi^2(k, \delta)$ se e só se:

$$i) A^2 = A$$

$$ii) \underline{b} \in \mathcal{E}(A), E = \underline{b}' \underline{b}$$

$$\text{com } k = R(A) \text{ e } \delta = (\underline{b} + \underline{\mu})' A (\underline{b} + \underline{\mu})$$

TEOREMA 9.2.1 - Seja $\underline{Y} \sim N_p(\underline{\mu}, \Sigma)$, onde Σ pode ser singular. Então a estatística

$$\underline{Y}' A \underline{Y} + 2 \underline{b}' \underline{Y} + E$$

tem distribuição $\chi^2(k, \delta)$ se e só se:

$$i) \Sigma A \Sigma A \Sigma = \Sigma A \Sigma \text{ ou equivalentemente}$$

$$(\Sigma A)^2 = (\Sigma A)$$

$$ii) \mathcal{E}[\Sigma(A\underline{\mu} + \underline{b})] \in \mathcal{E}(\Sigma A \Sigma)$$

$$iii) (A\underline{\mu} + \underline{b})' \Sigma (A\underline{\mu} + \underline{b}) = \underline{\mu}' A \underline{\mu} + 2 \underline{b}' \underline{\mu} + E$$

em tal caso:

$$k = \text{tr}(A \Sigma)$$

$$\delta = (\underline{b} + A\underline{\mu})' \Sigma A \Sigma (\underline{b} + A\underline{\mu})$$

onde $\mathcal{E}(D)$, é o espaço gerado pelas colunas da matriz D.

Agora considerando as duas populações normais transformadas com parâmetros $\underline{\mu}^{(1)}$, $\underline{\mu}^{(2)}$, Σ_1 e Σ_2 conhecidos, deseja-se encontrar a distribuição da variável aleatória:

$$U = \underline{Y}' (\mathbf{I}_2 - \Sigma_2^{-1}) \underline{Y} - 2 \underline{Y}' (\mathbf{I}_2 \underline{\mu}^{(1)} - \Sigma_2^{-1} \underline{\mu}^{(2)}) + \underline{\mu}^{(1)'} \underline{\mu}^{(1)} - \underline{\mu}^{(2)'} \Sigma_2^{-1} \underline{\mu}^{(2)} - \ln (\lambda_1 \lambda_2) \quad (14)$$

$$A = \Sigma_1^{-1} - \Sigma_2^{-1} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} - \begin{bmatrix} 1/\lambda_1 & 0 \\ 0 & 1/\lambda_p \end{bmatrix}$$

$$= \begin{bmatrix} \frac{\lambda_1 - 1}{\lambda_1} & 0 \\ 0 & \frac{\lambda_p - 1}{\lambda_p} \end{bmatrix}$$

$$B = -\Sigma_1^{-1} \mu^{(1)} + \Sigma_2^{-1} \mu^{(2)} =$$

$$= \begin{bmatrix} -1 & 0 \\ 0 & -1 \end{bmatrix} \begin{bmatrix} \mu_1^{(1)} \\ \mu_2^{(1)} \end{bmatrix} + \begin{bmatrix} 1/\lambda_1 & 0 \\ 0 & 1/\lambda_p \end{bmatrix} \begin{bmatrix} \mu_1^{(2)} \\ \mu_2^{(2)} \end{bmatrix}$$

$$= \begin{bmatrix} -\mu_1^{(1)} \\ -\mu_2^{(1)} \end{bmatrix} + \begin{bmatrix} \mu_1^{(2)}/\lambda_1 \\ \mu_2^{(2)}/\lambda_p \end{bmatrix} = \begin{bmatrix} \mu_1^{(2)}/\lambda_1 & -\mu_1^{(1)} \\ \mu_2^{(2)}/\lambda_p & -\mu_2^{(1)} \end{bmatrix}$$

$$E = \mu^{(1)'} \Sigma_1^{-1} \mu^{(1)} - \mu^{(2)'} \Sigma_2^{-1} \mu^{(2)} - \ln(\lambda_1 \lambda_p)$$

aplicando os resultados acima, não se verificam as suposições do teorema 9.2.1, pois:

sob $\Pi_1: \underline{y} \sim N(\mu^{(1)}, I)$:

$$A^2 = \begin{bmatrix} \left[\frac{\lambda_1 - 1}{\lambda_1} \right]^2 & 0 \\ 0 & \left[\frac{\lambda_p - 1}{\lambda_p} \right]^2 \end{bmatrix} \neq A$$

$$B \cdot B \neq E$$

e não se pode concluir que U tem distribuição χ^2 .

sob $\Pi_2: \tilde{Y} \sim NC(\mu^{(2)}, \Sigma_2)$:

$$\begin{aligned} \Sigma_2^A \Sigma_2^A \Sigma_2 &= \begin{pmatrix} \lambda_1^{-1} & 0 \\ 0 & \lambda_p^{-1} \end{pmatrix} \begin{pmatrix} \lambda_1^{-1} & 0 \\ 0 & \lambda_p^{-1} \end{pmatrix} \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{pmatrix} \\ &= \begin{pmatrix} (\lambda_1^{-1})^2 & 0 \\ 0 & (\lambda_p^{-1})^2 \end{pmatrix} \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{pmatrix} = \begin{pmatrix} \lambda_1^{-1} & 0 \\ 0 & \lambda_p^{-1} \end{pmatrix} \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{pmatrix} \\ \Sigma_2^A \Sigma_2 &= \begin{pmatrix} \lambda_1^{-1} & 0 \\ 0 & \lambda_p^{-1} \end{pmatrix} \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{pmatrix} = \begin{pmatrix} \lambda_1(\lambda_1^{-1}) & 0 \\ 0 & \lambda_p(\lambda_p^{-1}) \end{pmatrix} \end{aligned}$$

Com $\Sigma_2^A \Sigma_2^A \Sigma_2 \neq \Sigma_2^A \Sigma_2$.

também não se pode concluir que U tem distribuição χ^2 .

Continuando com o estudo para tentar obter a distribuição de U faz-se a seguinte decomposição:

$$U = U_1 + U_2 - \ln(\lambda_1 \lambda_p) \quad \text{onde:}$$

$$U_1 = \tilde{Y}' \Sigma_1^{-1} \tilde{Y} + 2 \tilde{Y}' (C - \Sigma_1^{-1} H^{(1)}) + H^{(1)'} \Sigma_1^{-1} H^{(1)} \quad (15)$$

$$U_2 = \tilde{Y}' (C - \Sigma_2^{-1}) \tilde{Y} + 2 \tilde{Y}' (C \Sigma_2^{-1} H^{(2)}) - H^{(2)'} \Sigma_2^{-1} H^{(2)}$$

Para se obterem os valores médios e as variâncias e covariâncias tem-se:

sob Π_1 : Se $Y \sim N(\mu^{(1)}, \Sigma_1)$, então com:

$$i) A = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \implies A^2 = A$$

$$ii) B = -\left[\Sigma_1^{-1} \mu^{(1)} \right] = \begin{pmatrix} -\mu_1^{(1)} \\ -\mu_2^{(1)} \end{pmatrix} \implies B \in \mathcal{S}(A)$$

$$E = \mu^{(1)'} \Sigma_1^{-1} \mu^{(1)} = (\mu_1^{(1)}, \mu_2^{(1)}) \begin{pmatrix} \mu_1^{(1)} \\ \mu_2^{(1)} \end{pmatrix} = B'B$$

tem-se que, sob Π_1 :

$$U_1 = Y' \Sigma_1^{-1} Y + 2 Y' (-\Sigma_1^{-1} \mu^{(1)}) + \mu^{(1)'} \Sigma_1^{-1} \mu^{(1)} \sim \chi^2(2, 0)$$

e, agora, se:

$$i) A = \Sigma_2^{-1} = \begin{pmatrix} 1/\lambda_1 & 0 \\ 0 & 1/\lambda_p \end{pmatrix} \implies$$

$$A^2 = \begin{pmatrix} 1/\lambda_1^2 & 0 \\ 0 & 1/\lambda_p^2 \end{pmatrix} \neq A$$

$$ii) B = \Sigma_2^{-1} \mu^{(2)} = \begin{pmatrix} \mu_1^{(2)}/\lambda_1 \\ \mu_2^{(2)}/\lambda_p \end{pmatrix} \in \mathcal{S}(A)$$

$$B'B = \begin{pmatrix} \frac{\mu_1^{(2)}}{\lambda_1} \end{pmatrix}^2 + \begin{pmatrix} \frac{\mu_2^{(2)}}{\lambda_p} \end{pmatrix}^2$$

$$E = -\mu^{(2)'} \Sigma_2^{-1} \mu^{(2)} = -\frac{(\mu_1^{(2)})^2}{\lambda_1} - \frac{(\mu_2^{(2)})^2}{\lambda_p} \neq B'B$$

e por (i) e (ii) não se pode concluir que, sob Π_1 , U_2 tenha distribuição χ^2 .

Mas, sob Π_2 : $Y \sim N(\mu^{(2)}, \Sigma_2)$, fazendo:

$$i) A = \Sigma_1^{-1} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad B = -\Sigma_1^{-1} \mu^{(1)}$$

$$E = \mu^{(1)}, \mu^{(1)}$$

$$\Sigma_2 A \Sigma_2 A \Sigma_2 = \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{bmatrix} \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{bmatrix} \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{bmatrix} = \begin{bmatrix} \lambda_1^3 & 0 \\ 0 & \lambda_p^3 \end{bmatrix}$$

$$\Sigma_2 A \Sigma_2 = \begin{bmatrix} \lambda_1^2 & 0 \\ 0 & \lambda_p^2 \end{bmatrix}$$

$$\Rightarrow \Sigma_2 A \Sigma_2 A \Sigma_2 \neq \Sigma_2 A \Sigma_2$$

e, com esse resultado, sob Π_2 , ainda não se pode dizer que U_1 tem distribuição χ^2 .

Agora, se:

$$i) A = - \begin{bmatrix} 1/\lambda_1 & 0 \\ 0 & 1/\lambda_p \end{bmatrix}$$

$$B = \Sigma_2^{-1} \mu^{(2)} = \begin{bmatrix} \mu_1^{(2)}/\lambda_1 \\ \mu_2^{(2)}/\lambda_p \end{bmatrix}$$

$$E = -\mu^{(2)}, \Sigma_2^{-1} \mu^{(2)}$$

$$\Sigma_z^A \Sigma_z^A \Sigma_z = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{bmatrix} = \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{bmatrix}$$

$$\Sigma_z^A \Sigma_z = - \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{bmatrix}$$

$$ii) A_{\tilde{\mu}}^{(z)} + \tilde{b} = - \begin{bmatrix} 1/\lambda_1 & 0 \\ 0 & 1/\lambda_p \end{bmatrix} \begin{bmatrix} \mu_1^{(z)} \\ \mu_2^{(z)} \end{bmatrix} + \begin{bmatrix} \mu_1^{(z)}/\lambda_1 \\ \mu_2^{(z)}/\lambda_p \end{bmatrix} = \tilde{0}$$

$$\Sigma_z (A_{\tilde{\mu}}^{(z)} + \tilde{b}) = 2 \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_p \end{bmatrix} \begin{bmatrix} \mu_1^{(z)}/\lambda_1 \\ \mu_2^{(z)}/\lambda_p \end{bmatrix} = \tilde{0}$$

vemos que $\mathcal{R}(\Sigma_z (A_{\tilde{\mu}}^{(z)} + \tilde{b})) \in \mathcal{R}(\Sigma_z^A \Sigma_z)$

$$iii) \delta = (A_{\tilde{\mu}}^{(z)} + \tilde{b})' \Sigma_z (A_{\tilde{\mu}}^{(z)} + \tilde{b}) = 4 \left[\frac{\mu_1^{(z)}}{\lambda_1} \right]^2 = 0$$

por (i) e (ii) tem-se que sob Π_2 :

$$U_z = \tilde{Y}' \Sigma_z^{-1} \tilde{Y} + 2 \tilde{Y}' (-\Sigma_z^{-1} \tilde{\mu}^{(z)}) + \tilde{\mu}^{(z)'} \Sigma_z^{-1} \tilde{\mu}^{(z)} \sim \chi^2(2, 0)$$

Resumindo:

$$\text{sob } \Pi_1 : U_1 = \tilde{Y}'_1 \Sigma_1^{-1} \tilde{Y}_1 + 2 \tilde{Y}'_1 (-\Sigma_1^{-1} \mu^{(1)}) + \mu^{(1)'} \Sigma_1^{-1} \mu^{(1)}$$

tem distribuição $\chi^2(2,0)$

$$\text{sob } \Pi_2 : U_2 = \tilde{Y}'_2 \Sigma_2^{-1} \tilde{Y}_2 + 2 \tilde{Y}'_2 (-\Sigma_2^{-1} \mu^{(2)}) + \mu^{(2)'} \Sigma_2^{-1} \mu^{(2)}$$

tem distribuição $\chi^2(2,0)$

(16)

mas, não se conseguem obter as distribuições de

$$\begin{aligned} & \tilde{Y}'_1 \Sigma_1^{-1} \tilde{Y}_1 + 2 \tilde{Y}'_1 (-\Sigma_1^{-1} \mu^{(1)}) + \mu^{(1)'} \Sigma_1^{-1} \mu^{(1)} \\ & \tilde{Y}'_2 \Sigma_2^{-1} \tilde{Y}_2 + 2 \tilde{Y}'_2 (-\Sigma_2^{-1} \mu^{(2)}) + \mu^{(2)'} \Sigma_2^{-1} \mu^{(2)} \end{aligned} \quad e$$

sob Π_1 e Π_2 , respectivamente.

Pelo exposto, é muito difícil avaliar a probabilidade total de má classificação (PTM) da regra proposta.

2.3.4 ESTIMAÇÃO DA PROBABILIDADE TOTAL DE MÁ CLASSIFICAÇÃO

Mas no entanto, para dar prosseguimento ao estudo de avaliação, serão usados os valores amostrais $\bar{X}_1^{(1)}$, $\bar{X}_2^{(2)}$, S_1 , S_2 , $S_1^{-1} S_2$, $\bar{Y}_1^{(1)}$, $\bar{Y}_2^{(2)}$, na avaliação do desempenho da função classificadora amostral, calculando a Razão de Erro Real, (Johnson e Wichern, 1982).

A Razão de Erro Real (RER), é definida como:

$$RER = q_1 \int_{\hat{R}_2} f_1(y) dy + q_2 \int_{\hat{R}_1} f_2(y) dy \quad (17)$$

onde $dy = dy_1 dy_2$,

\hat{R}_1 e \hat{R}_2 são as regiões de classificação amostral construídas através das amostras de tamanho n_1 e n_2 das populações, usando $\bar{y}^{(1)}$, $\bar{y}^{(2)}$, $\hat{\Sigma}_1$, $\hat{\Sigma}_2$ para estimar os parâmetros na expressão(9).

Abaixo se fará uma apresentação resumida dos estimadores da Razão de Erro Aparente .

2.3.4.1 Primeiro Estimador (Método de Re-substituição)

Existe um tipo de avaliação da função de classificação que não depende da forma das populações de origem, mas pode ser calculado para qualquer procedimento de classificação, e é chamado Razão de Erro Aparente (REA).

A REA é definida como a fração de observações das amostras que são mal classificadas pela função de classificação amostral. Este estimador é fácil de calcular, mas tende a subestimar a RER, a menos que n_1 e n_2 , tamanhos amostrais sejam grandes.

Tomam-se n_1 observações de Π_1 e n_2 observações de Π_2 , constrói-se a função de classificação amostral e avalia-se cada observação das amostras na função. Obtém-se então, a seguinte tabela:

POPULAÇÃO VERDADEIRA	DECISÃO ESTATÍSTICA		
	Π_1	Π_2	TOTAL
Π_1	n_{1c}	$n_{1m} = n_1 - n_{1c}$	n_1
Π_2	$n_{2m} = n_2 - n_{2c}$	n_{2c}	n_2

(18)

onde:

- n_{1c} : n^o de itens de Π_1 classificados corretamente em Π_1 .
- n_{1m} : n^o de itens de Π_1 classificados incorretamente em Π_2 .
- n_{2c} : n^o de itens de Π_2 classificados corretamente em Π_2 .
- n_{2m} : n^o de itens de Π_2 classificados incorretamente em Π_1 .

A Razão de Erro Aparente é definida por:

$$REA = \frac{n_{1m} + n_{2m}}{n_1 + n_2} \quad (19)$$

2.3.4.2 Segundo Estimador (Método H)

Um outro estimador da Razão de Erro Real (RER) é obtido dividindo-se as amostras em dois subconjuntos. As duas sub-amostras do primeiro subconjunto são usadas para construir a função de discriminação amostral, enquanto que as sub-amostras do segundo subconjunto são usadas para avaliar a função.

Neste caso, o estimador da Razão de Erro Real é determinado pela proporção de membros do segundo subconjunto mal classificados, (subconjunto que serve para a avaliação). Este procedimento apresenta dois defeitos principais :

-requer amostras grandes.

-não são usadas todas as observações das amostras para construir a função, e nessa situação perdem-se informações importantes.

$$\begin{aligned} \text{Resumindo, se } n_1 &= n_{11} + n_{12} \\ n_2 &= n_{21} + n_{22} \end{aligned}$$

$n_{11} + n_{21}$ são usados para construir a função de discriminação, e $n_{12} + n_{22}$ são usados para avaliar a função construída.

2.3.4.3 Terceiro Estimador (Método \mathcal{U} modificado)

Este procedimento foi proposto por *Lachenbruch e Mickey*, (1968) e consiste em tomar amostras de tamanhos n_1 e n_2 , de Π_1 e Π_2 respectivamente:

i) Começa-se com as observações de Π_1 , omitindo uma observação desse grupo e construindo a função discriminante amostral com as $n_1 - 1$ e n_2 observações.

ii) Classifica-se a observação que é retirada da amostra de Π_1 segundo a função construída no item (i).

iii) Repetem-se os passos (i) e (ii) até que todas as observações de Π_1 sejam classificadas.

iv) Repeteu-se o mesmo procedimento com as observações de Π_2 .

Seja n_{1m} o n_{2m} o de observações mal classificadas de Π_1 e n_{2m} o de Π_2 . Então, as estimativas de $P(1/2)$ e $P(2/1)$ são dadas por:

$$\hat{P}(2/1) = \frac{n_{1m}}{n_1} \quad \hat{P}(1/2) = \frac{n_{2m}}{n_2}$$

e o estimador da Razão de Erro Real (RER) é:

$$E(\hat{RER}) = \frac{n_{1m} + n_{2m}}{n_1 + n_2} \quad (20)$$

O desempenho da Função de Discriminação proposta neste capítulo será avaliada com a Razão de Erro Aparente calculada pelo Método de Re-substituição, por ser o mais conhecido, fácil de trabalhar e supondo que para amostras grandes proporciona uma boa estimativa da probabilidade total de má classificação.

CAPITULO 3

O DESEMPENHO DO NOVO METODO: SIMULAÇÃO E EXEMPLO

3.1. Introdução

No presente capítulo apresenta-se um estudo simulado com respeito ao critério de discriminação proposto no item (2.3) do capítulo anterior e uma aplicação prática com dados de *Flury e Riedwyl(1983)*, com a finalidade de mostrar a viabilidade do método.

Na primeira parte será apresentado um estudo baseado em simulações de Monte Carlo onde, com as amostras geradas construiu-se a regra de classificação amostral (13) do capítulo 2.

Tais amostras, além de se classificarem com este método, também são classificadas com (6) do capítulo anterior cuja fórmula consta no pacote estatístico Statistical Analysis System (SAS). O gerador de números aleatórios é o que está implementado no computador VAX 785/11VMS da *Universidade Estadual de Campinas (unicamp)*.

Para um melhor entendimento do trabalho ,na seção (3.2) far-se-á uma apresentação da geração das amostras das populações.

Na parte final do capítulo serão apresentados os resultados obtidos da aplicação.

3.2 SIMULAÇÕES

3.2.1 GERAÇÃO DAS DUAS POPULAÇÕES NORMAIS DE DIMENSÃO P

Existem vários geradores de números pseudo-aleatórios. Por facilidade e dada a sua ampla divulgação usamos o gerador RANDU implementado no VAX 785/11, o qual gera números pseudo-aleatórios de módulo $2^{31}-1$ que é do tipo:

$$g_{n+1} = k g_n \pmod{m}$$

sugerido por Lehmer. Tal algoritmo aparece no artigo de Payne, Rabung e Bogyo (1969).

O resultado de uma chamada a RANDU é um número uniforme no intervalo (0,1).

Nos programas n^o 1 e n^o 2 do apêndice (em linguagem FORTRAN), depois da geração das variáveis uniformes, pseudo aleatórias, usou-se o método proposto por Box-Muller(1958), que é uma transformação direta de variáveis uniformes independentes no intervalo (0,1), para variáveis normais independentes com média zero e variância um. Este procedimento inicial de geração de amostras de populações normais padrões é igual em ambos os grupos para qualquer número de variáveis até se chegar às variáveis correlacionadas, usando as transformações que serão apresentadas a seguir e que são muito conhecidas na literatura estatística.

1) A geração de vetores aleatórios normais padronizados de dimensão p (2 ou 3) é feita sob a seguinte suposição :

$z_{i1}^{(g)} \sim N(\phi, I_p)$ $g=1,2$ $i=1, \dots, n_g$ onde cada

$$z_i^{(g)} = (z_{i1}^{(g)}, \dots, z_{ip}^{(g)}) \quad (1)$$

criando-se assim as matrizes de dados amostrais de ordem $n_g \times p$, que será denotada por:

$$Z^{(g)} = (z_{11}^{(g)}, z_{21}^{(g)}, \dots, z_{n_g 1}^{(g)}) \quad g=1,2$$

2) A geração de variáveis independentes em cada população, com vetor de médias diferentes de zero e matriz de covariâncias diferente da identidade é feita através da transformação:

$$w_i^{(g)} = D^{(g)} z_i^{(g)} + A^{(g)} \quad g=1,2$$

onde:

$$w_i^{(g)} \sim N_p(A^{(g)}, D^{(g)} D^{(g)}) \quad (2)$$

com

$$A^{(g)} = \begin{bmatrix} a_1^{(g)} \\ \dots \\ a_p^{(g)} \end{bmatrix} \quad D^{(g)} = \begin{bmatrix} v_1^{(g)} & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & \dots & \dots & v_p^{(g)} \end{bmatrix}_{p \times p} \quad (3)$$

3) Depois é introduzida a estrutura de correlações entre as variáveis segundo a transformação :

$$\tilde{x}_i^{(g)} = R^{(g)} \tilde{w}_i^{(g)} \quad g=1,2 \quad , i=1, \dots, n_g \quad (4)$$

onde $R^{(g)}$ é um operador que produz uma rotação no plano e no espaço tridimensional segundo p, seja 2 ou 3.

Cabe lembrar que $\tilde{x}_i^{(g)} \sim N_p(M_g, V_g)$ com

$$M_g = R^{(g)} A^{(g)} \quad e \quad V_g = R^{(g)} D^{(g)} D^{(g)}, R^{(g)} \quad (5)$$

Criam-se as matrizes de dados $X^{(g)} = (x_{i1}^{(g)}, \dots, x_{in_g}^{(g)})$

$g=1,2$ com $\tilde{x}_i^{(g)} = (x_{i1}^{(g)}, \dots, x_{ip}^{(g)})$.

Nas presentes simulações foi usada, para o caso $p=2$ a matriz de rotação:

$$R^{(g)} = \begin{bmatrix} \text{cosa} & -\text{sena} \\ \text{sena} & \text{cosa} \end{bmatrix}^{(g)}$$

e para $p=3$ a matriz:

(6)

$$R^{(g)} = \begin{bmatrix} \text{cosa} & -\text{sena} & 0 \\ \text{sena} & \text{cosa} & 0 \\ 0 & 0 & 1 \end{bmatrix}^{(g)}$$

dando origem a:

$$V_g = \begin{cases} \begin{bmatrix} v_1^2 \cos^2 \alpha + v_2^2 \sin^2 \alpha & (v_1^2 - v_2^2) \sin \alpha \cos \alpha \\ (v_1^2 - v_2^2) \sin \alpha \cos \alpha & v_1^2 \sin^2 \alpha + v_2^2 \cos^2 \alpha \end{bmatrix}^{(g)} & \text{se } p=2 \\ \begin{bmatrix} v_1^2 \cos^2 \alpha + v_2^2 \sin^2 \alpha & (v_1^2 - v_2^2) \sin \alpha \cos \alpha & 0 \\ (v_1^2 - v_2^2) \sin \alpha \cos \alpha & v_1^2 \sin^2 \alpha + v_2^2 \cos^2 \alpha & 0 \\ 0 & 0 & 1 \end{bmatrix}^{(g)} & \text{se } p=3 \end{cases}$$

A transformação usada é a mesma ou diferente nos grupos, dando origem a amostras com a mesma ou diferente estrutura de covariâncias.

Nas simulações com $p=3$ só foram criadas estruturas de correlações entre as duas primeiras componentes de $x_i^{(g)} = (x_{i1}, x_{i2}, x_{i3})$. Não obstante com a mesma idéia poderiam ter sido criadas correlações entre as outras ou entre todas elas. O importante é gerar duas amostras provenientes de distribuições normais com estrutura de covariâncias diferentes.

4) Para a execução inicial dos programas $n^{\circ}1$ e $n^{\circ}2$ os parâmetros de entrada são os seguintes:

n_1, \dots, n_g , tamanho do g -ésimo grupo. Nestas simulações $n_1 = n_2 = 100$.

$v_1^{(g)}, \dots, v_p^{(g)}$, são os elementos da matriz $D^{(g)}$.

$a_1^{(g)}, \dots, a_p^{(g)}$, são os elementos do vetor de médias $\hat{A}^{(g)}$, que nas simulações foram fixados como nulos.

$\alpha^{(g)}$, são os ângulos que produzem as rotações nos grupos um e dois criando assim correlações entre as variáveis.

5) Depois de cada simulação de Monte Carlo e usando a teoria desenvolvida temos a seguintes matrizes de dados:

$$X^{(g)} = \begin{bmatrix} x_{11}^{(g)} & x_{12}^{(g)} & \dots & x_{1p}^{(g)} \\ \dots & \dots & \dots & \dots \\ x_{n_g 1}^{(g)} & x_{n_g 2}^{(g)} & \dots & x_{n_g p}^{(g)} \end{bmatrix} \quad \begin{array}{l} g = 1, 2 \\ p = 2 \text{ ou } 3 \end{array}$$

contendo as observações amostrais com as p medições.

Com os dados contidos em $X^{(g)}$ obtemos os vetores de médias e as matrizes de covariâncias amostrais segundo as fórmulas (13) do capítulo 1, chegando a obter $\bar{X}_1^{(1)}$, $\bar{X}_2^{(2)}$, S_1 e S_2 .

6) Neste ponto introduzimos nos programas $n-1$ e $n-2$ a subrotina FOZAEF da biblioteca NAG (Numerical Algorithms Groups).

Para clareza faz-se uma descrição resumida da subrotina FOZAEF que calcula todos os autovalores e autovetores de $A\hat{b} = \lambda B\hat{b}$, ou seja da matriz $B^{-1}A$ usando a redução de Householder e o algoritmo QL (Wilkinson, J. H. e Reinsch, C., 1971).

Dado que a matriz $B^{-1}A$ é não simétrica, o problema reduz-se primeiro à obtenção de autovalores e autovetores de uma matriz simétrica, usando o método de Cholesky para decompor B em matrizes triangulares, $B=LL'$ onde L é triangular inferior.

como $A \underline{b} = \lambda B \underline{b}$ (7)

$$L^{-1}AL^{-1}L'\underline{b} = \lambda L^{-1}B \underline{b} \quad \text{implica}$$

$$(L^{-1}AL^{-1})(L'\underline{b}) = \lambda L'\underline{b}$$

então, os autovalores de (7) são os de

$$P \underline{c} = \lambda \underline{c} \quad \text{onde} \quad \underline{c} = L'\underline{b} \quad P=L^{-1}AL^{-1}, \quad (8)$$

O método de *Householder* é usado para tridiagonalizar a matriz P simétrica e obter os seus autovalores com o algoritmo *QL*.

Um autovetor associado à matriz simétrica P está relacionado com o autovetor \underline{b} da matriz original $B^{-1}A$ mediante

$$\underline{c} = L'\underline{b} \quad (9)$$

Dado que o autovetor \underline{c} é obtido com o algoritmo *QL* e normalizado segundo $\underline{c}'\underline{c} = 1$, então, os autovalores do problema original são obtidos resolvendo o sistema (9), onde \underline{b} é normalizado segundo $\underline{b}'B \underline{b} = 1$. Ou seja, o uso da subrotina *FOZAEF* permite calcular os autovalores e autovetores da matriz $S_1^{-1}S_2$ com $A = S_2$ e $B=S_1$, onde S_1^{-1} é a inversa da matriz de covariâncias da amostra do grupo um.

A notação usada será r_1, \dots, r_p para os autovalores da matriz $S_1^{-1}S_2$, e $\underline{b}_1, \dots, \underline{b}_p$ para os autovetores associados.

3.2.2 GERAÇÃO DE DUAS POPULAÇÕES NORMAIS DE DIMENSÃO DOIS

Com os autovetores \underline{b}_1 e \underline{b}_p associados aos autovalores r_1 e r_p constroem-se as combinações lineares de interesse, não correlacionadas em ambos os grupos, definidas por (11) do capítulo anterior :

$$\begin{aligned}
 \underline{x}_i^{(g)} &= (\underline{b}_1, \underline{b}_p)' \underline{x}_i^{(g)} & i=1, \dots, n_g, \quad g=1,2 \\
 &= (y_{i1}^{(g)}, y_{i2}^{(g)}) & \underline{b}_1, \underline{b}_2 \in \mathbb{R}^p
 \end{aligned}
 \tag{10}$$

criando assim as matrizes de dados de ordem $n_g \times 2$:

$$Y^{(g)} = (x_1^{(g)}, \dots, x_{n_g}^{(g)})$$

$$Y^{(g)} = \begin{bmatrix} y_{11}^{(g)} & y_{12}^{(g)} \\ y_{21}^{(g)} & y_{22}^{(g)} \\ \dots & \dots \\ y_{n_g 1}^{(g)} & y_{n_g 2}^{(g)} \end{bmatrix}$$

$$Y^{(g)} = \begin{bmatrix} x_{11}^{(g)} & x_{12}^{(g)} & \dots & x_{1p}^{(g)} \\ x_{21}^{(g)} & x_{22}^{(g)} & \dots & x_{2p}^{(g)} \\ \dots & \dots & \dots & \dots \\ x_{n_g 1}^{(g)} & x_{n_g 2}^{(g)} & \dots & x_{n_g p}^{(g)} \end{bmatrix} \begin{bmatrix} b_{11} & b_{p1} \\ b_{12} & b_{p2} \\ \dots & \dots \\ b_{1p} & b_{pp} \end{bmatrix}$$

é evidente que :

$$y_i^{(1)} \sim N_2(\mu^{(1)}, I) \quad i=1, \dots, n_g \quad (11)$$

$$y_i^{(2)} \sim N_2(\mu^{(2)}, \Sigma_2)$$

3.2.3 CONSTRUÇÃO DA FUNÇÃO DISCRIMINANTE AMOSTRAL

Com os dados contidos nas matrizes $Y^{(g)}$ constrói-se a função discriminante amostral.

Obtêm-se as estatísticas:

$$\bar{Y}^{(1)} = \begin{bmatrix} \bar{Y}_1^{(1)} \\ \bar{Y}_2^{(1)} \end{bmatrix} = \frac{1}{n_1} \begin{bmatrix} y_{11}^{(1)} & y_{12}^{(1)} \\ \dots & \dots \\ y_{n_1 1}^{(1)} & y_{n_1 2}^{(1)} \end{bmatrix}, \begin{bmatrix} 1 \\ 1 \\ 1 \\ \dots \\ 1 \end{bmatrix}$$

$$\bar{Y}^{(z)} = \begin{bmatrix} \bar{Y}_1^{(z)} \\ \bar{Y}_2^{(z)} \\ \vdots \end{bmatrix} = \frac{1}{n_z} \begin{bmatrix} y_{11}^{(z)} & y_{12}^{(z)} \\ y_{21}^{(z)} & y_{22}^{(z)} \\ \dots & \dots \\ y_{n_z 1}^{(z)} & y_{n_z 2}^{(z)} \end{bmatrix} \cdot \begin{bmatrix} 1 \\ 1 \\ 1 \\ \dots \\ 1 \end{bmatrix}$$

$$\hat{\Sigma}_1 = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} = I_2$$

$$\hat{\Sigma}_2 = \begin{bmatrix} r_1 & 0 \\ 0 & r_p \end{bmatrix}$$

necessárias para calcular a função discriminante amostral.

Foram calculados previamente:

a). - Termo independente:

$$X_{INDT} = \bar{Y}_1^{(1)}, \bar{Y}_1^{(1)} - \bar{Y}_2^{(2)}, \hat{\Sigma}_2^{-1} \bar{Y}_2^{(2)} - \ln(r_1 r_p)$$

b). - vetor dos coeficientes do termo linear :

$$-2(\bar{Y}_2^{(1)} - \hat{\Sigma}_2^{-1} \bar{Y}_2^{(2)})$$

c). - Matriz do termo quadrático:

$$I_2 - \hat{\Sigma}_2^{-1}$$

d). -E logo a Função Discriminante Amostral:

$$D(\tilde{y}) = \tilde{y}'(I_2 - \hat{\Sigma}_2^{-1})\tilde{y} - 2\tilde{y}'(I_2 \bar{Y}^{(1)} - \hat{\Sigma}_2^{-1} \bar{Y}^{(2)}) + XINDT \quad (12)$$

e). -Assumindo custos de má classificação e probabilidades a priori iguais.

Então, o indivíduo que tem as medições $\tilde{y}_i^{(g)}$ é classificado como:

$$\begin{aligned} &\text{do grupo um, se } D(\tilde{y}_i^{(g)}) \leq 0 \text{ ou} \\ &\text{do grupo dois, se } D(\tilde{y}_i^{(g)}) > 0 \end{aligned} \quad (13)$$

Ou seja, para as n_1 e n_2 observações de cada simulação, $(\tilde{y}_i^{(g)})$, substituímos os valores de cada observação transformada

$$(\tilde{y}_i^{(g)}):$$

$$z_i^{(g)} = \begin{bmatrix} \tilde{p}_1 z_i^{(g)} \\ \tilde{p}_2 z_i^{(g)} \end{bmatrix} \in \mathbb{R}^2$$

na função (12), obtendo-se assim a tabela (18) do capítulo 2.

Com tais valores calculou-se a proporção de itens classificados incorretamente, ou seja, a Razão de Erro Aparente (CREA) com o Método de Re-substituição.

3.2.4 AVALIAÇÃO DA FUNÇÃO DE DISCRIMINAÇÃO AMOSTRAL E APRESENTAÇÃO DOS RESULTADOS EXPERIMENTAIS

Para fazer um melhor julgamento da Função de Discriminação Amostral (12) do item anterior, ajusta-se aos conjuntos de dados normais p-variados contidos nas matrizes $X^{(1)}$ e $X^{(2)}$, a metodologia implementada no STATISTICAL ANALYSIS SYSTEM (SAS), residente no computador VAX/UNICAMP. Portanto, antes de fazer a avaliação, é conveniente apresentar um resumo de tal metodologia. (Programas n^o 3 e n^o 4 do apêndice).

Com os dados contidos em $X^{(1)}$ e $X^{(2)}$ forma-se só um arquivo que contém as variáveis medidas e uma variável classificadora identificando os grupos.

O "PROC DISCRIM" do SAS ajusta uma função discriminante para classificar cada observação em um dos grupos, assumindo distribuição normal com igual ou diferente estrutura de covariâncias nos grupos.

Opcionalmente pedimos um teste de homogeneidade para as matrizes de covariâncias, e se a hipótese de igualdade é rejeitada, a classificação é feita com a função de Discriminação Quadrática Amostral de Anderson; ou seja, com a regra (6) do capítulo 2, em caso contrário com a Função de Discriminação Linear proposta por Fisher-regra (14) do capítulo 1.

Com o método proposto, seja aceitando ou rejeitando o teste de homogeneidade de variâncias, trabalhou-se com (12), só que, é de se esperar que no caso de homoscedasticidade e dado que consideramos médias iguais, vai ser quase impossível a discriminação.

Em cada simulação de Monte Carlo, foram geradas duas matrizes de dados amostrais normais de dimensão dois e três respectivamente, sobre o que devem ser feitas as seguintes considerações:

Dado que, o que interessa é a diferença entre os ângulos e não o quadrante em que estão localizadas as amostras, e tendo confirmado isso através de simulações (ver quadro A1 do apêndice), então para facilitar o trabalho, foi fixado o ângulo de rotação do primeiro grupo em 0° , e só foram feitas rotações no segundo grupo, com ângulos de rotação de 0° a 90° .

Tais condições iniciais para a criação dos grupos estão apresentadas nas colunas "PARAMETROS DE ENTRADA" dos quadros 3.1A até 3.7A para $p = 2$ e em 3.1B até 3.7B quando $p = 3$. Por exemplo, para $p = 2$, na execução 02A temos o seguinte: na população Π_1 , $v_1 = v_2 = 1$, $\alpha = 0^{\circ}$, e na população Π_2 , $v_1 = v_2 = 1$, $\alpha = 45^{\circ}$, ou seja, que as duas amostras foram retiradas de populações com distribuições circulares. Então, simularam-se amostras de populações esféricas, esféricas versus elípticas, elípticas versus elípticas com vários ângulos entre os respectivos eixos principais.

Com a finalidade de avaliar mais especificamente a validade do critério de discriminação proposto, supostamente baseado na diferenças das matrizes de covariâncias, as amostras criadas procedem de populações com vetores de médias iguais a zero. Então, nas simulações supõe-se que as distribuições estão centradas no vetor $\underline{0}_{p \times 1}$ e qualquer diferença entre elas está contida nas matrizes de covariâncias.

Para maior aproximação de situações práticas reais, em alguns casos, foram feitas simulações com variâncias iguais e em outros com variâncias diferentes.

Dado que seria impossível esboçarem-se todas as combinações de matrizes de covariâncias, trabalhou-se com algumas delas, de tal maneira que caracterizem situações de interesse.

Por exemplo, nas execuções 01A-02A, mantêm-se as duas populações com distribuições circulares, entretanto, nas execuções 07A, 08A, 09A, perturbaram-se as variâncias sob independência em ambas populações, e nas execuções 03A, 10A, 11A, 14A, impõe-se estrutura de correlações no segundo grupo e mantêm-se independência no primeiro.

Com os dados das amostras geradas sob as condições dadas, foram feitos os cálculos expostos nas secções 3.2 e 3.3 do presente capítulo, obtendo-se os resultados apresentados nas colunas "TESTE DE HOMOGENEIDADE", "PROPOSTA DE DISCRIMINAÇÃO", "CORRELAÇÃO AMOSTRAL", e "SAS" dos quadros 3.1A até 3.4B em $p = 2$ e $p = 3$.

Cabe ressaltar que em cada execução o teste de homogeneidade para as matrizes de covariâncias, conduz à rejeição ou aceitação de igualdade das matrizes o qual fica na coluna "TESTE DE HOMOGENEIDADE" dos quadros 3.1A até 3.4B.

Para clareza da interpretação das tabelas 3.1A até 3.4b.1, faz-se, como exemplo, uma pequena descrição das tabelas 3.1A e 3.1A.1.

Na tabela 3.1A apresentam-se quatro execuções onde em todas elas a primeira população é esférica; em tanto que, na segunda população, as duas primeiras execuções são esféricas, e tem-se introduzido estrutura de correlações na terceira execução, e na quarta execução, as variáveis são independentes.

Segundo o teste para as matrizes de covariâncias, do Proc Discrim, nas duas primeiras execuções é aceita a hipótese de homogeneidade e nas terceira e quarta execuções tal hipótese é rejeitada.

Para as mesmas execuções, na parte inferior da tabela apresenta-se o número de elementos mal classificados em cada grupo (n_{1m}, n_{2m}), segundo a proposta e o SAS; com tais valores calculam-se as estimativas das probabilidades de má classificação (REA). Também mostram-se os autovalores máximo e mínimo da matriz $S_1^{-1}S_2$.

Entretanto, a tabela 3.1A.1 refere-se exclusivamente à execução 01A, onde a parte superior contém o número da observação mal classificada segundo ambos os métodos e a parte inferior contém as observações mal classificadas por um dos métodos. Ou seja, que das 92 observações mal classificadas pela proposta e 82 observações mal classificadas com o SAS, (parte A+B ou parte A+C), 70 observações foram erradamente classificadas pelos dois métodos, (parte A).

As conclusões dos resultados experimentais serão apresentadas no último capítulo.

TABELA N^o 3.1A

ESTIMATIVAS DAS PROBABILIDADES DE NA CLASSIFICAÇÃO (REA) OBTIDAS COM O NOVO METODO DE CLASSIFICAÇÃO PROPOSTO E COMPARADAS COM AS OBTIDAS PELO SAS

EXE	PARAMETROS DE ENTRADA						CORRELAÇÃO AMOSTRAL		TESTE DE HOMOGENEIDADE
	Pop um			Pop dois			$\hat{\rho}^{(1)}$	$\hat{\rho}^{(2)}$	$V_1 = V_2$
	v_1	v_2	α	v_1	v_2	α			
01A	1	1	0	1	1	0	0.071	0.089	Aceitar
02A	1	1	0	1	1	45	0.071	0.019	Aceitar
03A	4	4	0	2	4	45	0.071	-0.589	Rejeitar
04A	4	4	0	2	4	90	0.071	-0.089	Rejeitar

EXE	PROPOSTA DE DISCRIMINAÇÃO					SAS			
	REA	n_{1m}	n_{2m}	Autovalores		r_1/r_p	REA (%)	n_{1m}	n_{2m}
				r_1	r_p				
01A	46	35	57	1.33	1.09	1.26	41	42	40
02A	43.5	31	56	1.27	1.14	1.11	42.5	42	43
03A	31.0	42	20	1.27	0.285	4.56	31.0	42	20
04A	32.5	46	19	1.29	0.279	4.64	32.5	46	19

Fonte : Simulações com o Programa n^o 1.

(Ver págs. 80, 81).

TABELA Nº 3.2A

ESTIMATIVAS DAS PROBABILIDADES DE MA CLASSIFICAÇÃO (REA) OBTIDAS COM O NOVO METODO DE CLASSIFICAÇÃO PROPOSTO E COMPARADAS COM AS OBTIDAS PELO SAS

EXE	PARAMETROS DE ENTRADA						CORRELAÇÃO AMOSTRAL		TESTE DE HOMOGENEIDADE
	Pop um			Pop dois			$\hat{\rho}^{(1)}$	$\hat{\rho}^{(2)}$	$V_1 = V_2$
	v_1	v_2	α	v_1	v_2	α			
05A	1	1	0	2	0.5	0	0.071	0.089	Rejeitar
06A	1	1	0	2	0.5	60	0.071	0.851	Rejeitar
07A	3	0.5	0	3	0.5	0	0.071	0.089	Aceitar
08A	3	0.5	0	3	0.5	90	0.071	-0.089	Rejeitar

EXE	PROPOSTA DE DISCRIMINAÇÃO						SAS		
	REA	n_{1m}	n_{2m}	Autovalores		r_1/r_p	REA (%)	n_{1m}	n_{2m}
				r_1	r_p				
05A	24	21	27	5.325	0.272	19.54	24	21	27
06A	28.5	25	32	4.461	0.325	13.72	28.5	25	32
07A	46.0	35	57	1.328	1.092	1.22	41.5	42	40
08A	9.5	8	11	41.230	0.035	1171.32	9.5	8	11

Fonte : Simulações com o Programa n-1.

(Ver págs. 82, 83)

TABELA Nº 3.3A

ESTIMATIVAS DAS PROBABILIDADES DE MA CLASSIFICAÇÃO (REA) OBTIDAS COM O NOVO METODO DE CLASSIFICAÇÃO PROPOSTO E COMPARADAS COM AS OBTIDAS PELO SAS

EXE	PARAMETROS DE ENTRADA						CORRELAÇÃO AMOSTRAL		TESTE DE HOMOGENEIDADE
	Pop um			Pop dois			$\hat{\rho}^{(1)}$	$\hat{\rho}^{(2)}$	$V_1 = V_2$
	v_1	v_2	α	v_1	v_2	α			
09A	3	0.5	0	0.5	3	0	0.071	0.089	Rejeitar
10A	3	0.5	0	0.5	3	45	0.071	-0.944	Rejeitar
11A	8	0.05	0	8	0.05	60	0.071	-0.93	Rejeitar
12A	8	0.05	0	8	0.05	90	0.071	-0.089	Rejeitar

EXE	PROPOSTA DE DISCRIMINAÇÃO						SAS		
	REA	n_{1m}	n_{2m}	Autovalores		r_1/r_p	REA (%)	n_{1m}	n_{2m}
				r_1	r_p				
09A	8	8	8	39.645	0.037	1083.21	8	8	8
10A	13.5	11	16	22.066	0.066	335.35	13.5	11	16
11A	0.0	0	0	21983.5	0.0001	314.0×10^6	0.0	0	0
12A	0.0	0	0	29308.4	0.0001	586.2×10^6	0.0	0	0

Fonte : Simulações com o Programa n-1.

TABELA Nº 3.4A

ESTIMATIVAS DAS PROBABILIDADES DE MÁ CLASSIFICAÇÃO (REA) OBTIDAS COM O NOVO METODO DE CLASSIFICAÇÃO PROPOSTO E COMPARADAS COM AS OBTIDAS PELO SAS

EXE	PARAMETROS DE ENTRADA						CORRELAÇÃO AMOSTRAL		TESTE DE HOMOGENEIDADE
	Pop 1m			Pop 2m			$\hat{\rho}^{(1)}$	$\hat{\rho}^{(2)}$	$V_1 = V_2$
	v_1	v_2	α	v_1	v_2	α			
13A	2	0.5	0	8	0.05	0	0.071	0.089	Rejeitar
14A	2	0.5	0	8	0.05	45	0.071	0.999	Rejeitar
15A	2	0.5	0	8	0.05	60	0.071	0.999	Rejeitar
16A	2	0.5	0	8	0.05	90	0.071	-0.089	Rejeitar

EXE	PROPOSTA DE DISCRIMINAÇÃO						SAS		
	REA	n_{1m}	n_{2m}	Autovalores		r_1/r_p	REA (%)	n_{1m}	n_{2m}
				r_1	r_p				
13A	6	9	3	21.34	0.0109	1958.2	6	9	3
14A	4	7	1	151.76	0.0015	101.2×10^3	4	7	1
15A	2	3	1	220.42	0.0011	200.4×10^3	2	3	1
16A	0.5	1	0	293.09	0.0008	366.4×10^3	0.5	1	0

Fonte : Simulações com o Programa nº 1.

(Ver pág. 84).

TABELA N.º 3.1B

ESTIMATIVAS DAS PROBABILIDADES DE MÁ CLASSIFICAÇÃO (REA) OBTIDAS COM O NOVO METODO DE CLASSIFICAÇÃO PROPOSTO E COMPARADAS COM AS OBTIDAS PELO SAS

	PARAMETROS DE ENTRADA								CORRELAÇÃO AMOSTRAL		TESTE DE HOMOGENEIDADE
	pop. um				pop. dois				$\hat{\rho}^{(1)}$	$\hat{\rho}^{(2)}$	
	v_1	v_2	v_3	α	v_1	v_2	v_3	α			
01B	1	1	1	0	1	1	1	0	0.043	0.062	Aceitar
02B	1	1	1	0	1	1	1	45	0.043	-0.013	Aceitar
03B	8	4	2	0	8	4	2	60	0.043	-0.518	Rejeitar
04B	8	4	2	0	8	4	2	90	0.043	-0.062	Rejeitar

EXE	PROPOSTA DE DISCRIMINAÇÃO						SAS		
	REA	n_{1m}	n_{2m}	Autovalores		r_1/r_p	REA (%)	n_{1m}	n_{2m}
				r_1	r_p				
01B	42	35	49	1.361	0.7258	1.88	45	45	45
02B	40	52	28	1.326	0.7050	1.88	41.5	42	41
03B	30	34	26	3.121	0.2560	12.19	30.5	34	27
04B	28.5	31	26	3.603	0.2199	16.39	25.5	26	25

Fonte : Simulações com o Programa n.º 2.

(Ver pág. 85).

TABELA Nº 3.2B

ESTIMATIVAS DAS PROBABILIDADES DE MÁ CLASSIFICAÇÃO (REA) OBTIDAS COM O NOVO METODO DE CLASSIFICAÇÃO PROPOSTO E COMPARADAS COM AS OBTIDAS PELO SAS

	PARAMETROS DE ENTRADA								CORRELAÇÃO AMOSTRAL		TESTE DE HOMOGENEI
	pop. um				pop. dois				$\hat{\rho}^{(1)}$	$\hat{\rho}^{(2)}$	
	v_1	v_2	v_3	α	v_1	v_2	v_3	α			
05B	1	1	1	0	2	1.5	0.5	45	0.043	0.268	Rejeitar
06B	1	1	1	0	2	1.5	0.5	60	0.043	0.205	Rejeitar
07B	6	4	2	0	4	4	4	0	0.043	0.062	Rejeitar
08B	6	4	2	0	4	4	4	90	0.043	-0.062	Rejeitar

EXE	PROPOSTA DE DISCRIMINAÇÃO						SAS		
	REA	n_{1m}	n_{2m}	Autovalores		r_1/r_p	REA (%)	n_{1m}	n_{2m}
				r_1	r_p				
05B	31.5	33	30	3.422	0.2800	12.22	26.5	23	30
06B	30.0	32	28	3.464	0.2806	12.34	26.5	23	30
07B	28.5	19	38	4.794	0.3648	13.14	29.5	21	38
08B	29.0	20	38	4.769	0.3875	12.31	28.0	26	30

Fonte : Simulações com o Programa nº 2.

(Ver pág. 86, 87).

TABELA Nº 3.3B

ESTIMATIVAS DAS PROBABILIDADES DE NA CLASSIFICAÇÃO (REAJ) OBTIDAS COM O NOVO METODO DE CLASSIFICAÇÃO PROPOSTO E COMPARADAS COM AS OBTIDAS PELO SAS

	PARAMETROS DE ENTRADA								CORRELAÇÃO AMOSTRAL		TESTE DE HOMOGENEIA
	pop. um				pop. dois				$\hat{\rho}^{(1)}$	$\hat{\rho}^{(2)}$	
	v_1	v_2	v_3	α	v_1	v_2	v_3	α			
09B	2	0.5	1.5	0	8	0.05	1.5	0	0.043	0.0622	Rejeitar
10B	2	0.5	1.5	0	8	0.05	1.5	45	0.043	0.999	Rejeitar
11B	8	0.05	2.0	0	8	0.05	2.0	60	0.043	0.999	Rejeitar
12B	8	0.05	2.0	0	8	0.05	2.0	90	0.043	-0.062	Rejeitar

EXE	PROPOSTA DE DISCRIMINAÇÃO						SAS		
	REA	n_{1m}	n_{2m}	Autovalores		r_1/r_p	REA (%)	n_{1m}	n_{2m}
				r_1	r_p				
09B	7.5	12	3	14.106	0.0090	1567.3	6	10	2
10B	2.5	4	1	117.765	0.0011	107059.4	2	4	0
11B	0	0	0	16936.6	0.0001	338.7×10^6	0	0	0
12B	0.5	0	1	225.876	0.0006	752.6×10^6	0.5	0	1

Fonte : Simulações com o Programa nº 2. (ver págs. 88)

TABELA N^o 3.4B

ESTIMATIVAS DAS PROBABILIDADES DE MA CLASSIFICAÇÃO (REA) OBTIDAS COM O NOVO METODO DE CLASSIFICAÇÃO PROPOSTO E COMPARADAS COM AS OBTIDAS PELO SAS

	PARAMETROS DE ENTRADA								CORRELAÇÃO AMOSTRAL		TESTE DE HOMOGENEI
	pop. um				pop. dois				$\hat{\rho}^{(1)}$	$\hat{\rho}^{(2)}$	
	v_1	v_2	v_3	α	v_1	v_2	v_3	α			
13B	3	0.5	0.05	0	3	0.5	0.05	0	0.043	0.0622	Aceitar
14B	3	0.5	0.05	0	3	0.5	0.05	9	0.043	0.06887	Rejeitar
15B	3	0.5	0.05	0	3	0.5	0.05	29	0.043	0.9272	Rejeitar
16B	3	0.5	0.05	0	3	0.5	0.05	39	0.043	0.9427	Rejeitar
17B	3	0.5	0.05	0	3	0.5	0.05	45	0.043	0.9448	Rejeitar
18B	3	0.5	0.05	0	3	0.5	0.05	90	0.043	-0.0622	Rejeitar

EXE	PROPOSTA DE DISCRIMINAÇÃO						SAS		
	REA	n_{1m}	n_{2m}	Autovalores		r_1/r_p	REA	n_{1m}	n_{2m}
				r_1	r_p				
13B	42	35	49	1.361	0.7258	1.87	45	45	45
14B	34	44	24	2.311	0.3505	6.59	38	44	32
15B	17.5	23	12	8.919	0.0879	101.48	18.5	23	14
16B	13	16	10	13.794	0.0567	243.28	13.5	16	11
17B	12.5	15	10	16.925	0.0462	366.34	12	15	09
18B	07	06	08	31.819	0.0245	1298.76	8.5	09	08

Fonte : Simulações com o Programa n^o 2.

(ver pág. 89).

segundo a PROPOSTA e o SAS (A)

obs de Π_1 classificada em Π_2				obs de Π_2 classificada em Π_1			
02	37	82	97	102	125	156	183
04	38	84		104	126	159	184
13	39	85		106	129	161	185
14	48	87		107	130	163	188
16	50	89		111	135	165	190
17	55	90		112	143	166	191
21	59	92		114	145	167	192
30	67	93		115	149	169	197
34	76	96		117	152	172	200
36	78	97		121	155	180	

PROPOSTA (B)

SAS (C)

de Π_1 em Π_2	de Π_2 em Π_1	de Π_1 em Π_2	de Π_2 em Π_1
41	101 160	5 99	131
44	105 162	8	
75	116 164	12	
95	119 174	25	
	127 175	35	
	138 176	45	
	140 179	46	
	144 195	56	
	147	62	
	148	79	

$$\text{TOTAL DE MAL CLASSIFICADAS} \begin{cases} \text{PROPOSTA} = A + B \\ \text{SAS} = A + C \end{cases}$$

=====

segundo a PROPOSTA e o SAS (A)

obs de Π_1 classificada em Π_2						obs de Π_2 classificada em Π_1
02	20	43	65	82		103
03	22	46	71	87		104
06	23	47	73	90		115
08	28	48	74	93		118
10	31	50	76	97		120
11	33	52	77	100		124
12	35	54	78			131
14	36	56	79			134
16	37	61	80			137
17	38	63	81			139

=====

PROPOSTA (B)		SAS (C)	
de Π_1 em Π_2	de Π_2 em Π_1	de Π_1 em Π_2	de Π_2 em Π_1

TOTAL DE MAL CLASSIFICADAS

$$\left\{ \begin{array}{l} \text{PROPOSTA} = A + B \\ \text{SAS} = A + C \end{array} \right.$$

segundo a PROPOSTA e o SAS (A)

obs de Π_1 classificada em Π_2			obs de Π_2 classificada em Π_1		
02	55	100	101	133	174
14	58		111	142	181
17	63		113	144	182
27	74		116	148	183
28	76		117	152	190
37	77		119	155	194
38	78		121	158	200
47	80		126	162	
48	87		127	169	
50	98		128	170	

PROPOSTA (B)

SAS (C)

de Π_1 em Π_2	de Π_2 em Π_1	de Π_1 em Π_2	de Π_2 em Π_1
-----------------------	-----------------------	-----------------------	-----------------------

TOTAL DE MAL CLASSIFICADAS

$$\left\{ \begin{array}{l} \text{PROPOSTA} = A + B \\ \text{SAS} = A + C \end{array} \right.$$

segundo a PROPOSTA e o SAS (A)

obs de Π_1 classificada em Π_2				obs de Π_2 classificada em Π_1			
02	37	82	98	102	125	159	184
04	38	84		104	126	161	185
13	39	85		106	129	163	188
14	48	87		107	130	165	190
16	50	89		111	135	166	191
17	55	90		112	143	167	192
21	59	92		114	145	169	197
30	67	93		115	149	172	200
34	76	96		117	152	180	
36	78	97		121	158	183	

PROPOSTA (B)

SAS (C)

de Π_1 em Π_2	de Π_2 em Π_1	de Π_1 em Π_2	de Π_2 em Π_1
41	101 155	05 99	131
44	105 160	08	153
75	116 162	12	
95	119 164	25	
	127 174	35	
	138 175	45	
	140 176	46	
	144 179	56	
	147 195	62	
	148	79	

TOTAL DE MAL CLASSIFICADAS

$$\left\{ \begin{array}{l} \text{PROPOSTA} = A + B \\ \text{SAS} = A + C \end{array} \right.$$

segundo a PROPOSTA e o SAS (A)

obs de Π_1 classificada em Π_2	obs de Π_2 classificada em Π_1
04	158
13	
24	
49	
51	
66	
99	

PROPOSTA (B)

SAS (C)

de Π_1 em Π_2	de Π_2 em Π_1	de Π_1 em Π_2	de Π_2 em Π_1
-----------------------	-----------------------	-----------------------	-----------------------

TOTAL DE MAL CLASSIFICADAS	{	PROPOSTA = A + B
		SAS = A + C

QUADRO 3.1B.1 OBSERVAÇÕES MAL CLASSIFICADAS NA EXECUÇÃO 01B

segundo a PROPOSTA e o SAS (A)

obs de Π_1 classificada em Π_2			obs de Π_2 classificada em Π_1			
01	42	75	103	131	166	198
7	45	79	105	134	167	
12	55	84	106	137	181	
15	59	88	108	139	182	
18	60	89	109	143	184	
19	61	98	110	150	185	
23	62		113	151	187	
25	67		124	152	188	
33	68		126	160	191	
41	70		127	162	195	

PROPOSTA (B)

SAS (C)

de Π_1 em Π_2		de Π_2 em Π_1		de Π_1 em Π_2		de Π_2 em Π_1	
8	101	149		6	64	107	174
14	102	156		24	69	115	176
22	114	165		28	73	123	197
29	116	172		38	77	128	199
32	120	175		39	82	144	
35	122	183		44	87	145	
48	125	189		46	91	146	
62	140	200		49	93	164	
63	141			54	99	171	
	147			63		173	

TOTAL DE MAL CLASSIFICADAS

$$\left\{ \begin{array}{l} \text{PROPOSTA} = A + B \\ \text{SAS} = A + C \end{array} \right.$$

QUADRO 3.2B.1 OBSERVAÇÕES MAL CLASSIFICADAS NA EXECUÇÃO OSB

segundo a PROPOSTA e o SAS (A)

obs de Π_1 classificada em Π_2		obs de Π_2 classificada em Π_1		
4	64	109	168	196
7	66	111	169	197
8	69	113	173	
10	70	126	178	
11	76	129	182	
28	77	132	184	
46	81	143	185	
48	91	148	188	
58		155	191	
63		163	194	

PROPOSTA (B)

SAS (C)

de Π_1 em Π_2	de Π_2 em Π_1	de Π_1 em Π_2	de Π_2 em Π_1	
6	78	104	21	118
13	87	119	27	156
17	88	121	44	157
23	95	131	80	158
28	96	152	89	160
31		153		183
33		159		187
43		166		192
45				
74				

TOTAL DE MAL CLASSIFICADAS { PROPOSTA = A + B
SAS = A + C

QUADRO 3.2B.2 - OBSERVAÇÕES MAL CLASSIFICADAS NA EXECUÇÃO 07B

segundo a PROPOSTA e o SAS (A)

obs de Π_1 classificada em Π_2		obs de Π_2 classificada em Π_1			
1	59	101	123	156	186
3	60	102	124	160	187
18	61	103	125	165	189
25	67	105	127	166	195
36	78	106	133	170	198
37	83	108	134	172	199
40	84	110	139	175	200
50	98	116	141	176	
51		120	144	180	
57		122	146	181	

PROPOSTA (B)

SAS (C)

de Π_1 em Π_2	de Π_2 em Π_1	de Π_1 em Π_2	de Π_2 em Π_1
15	162	20	151
		41	
		65	

TOTAL DE MAL CLASSIFICADAS

$$\left\{ \begin{array}{l} \text{PROPOSTA} = A + B \\ \text{SAS} = A + C \end{array} \right.$$

QUADRO 3.3B.1 OBSERVAÇÕES MAL CLASSIFICADAS NA EXECUÇÃO O9B

=====

segundo a PROPOSTA e o SAS (A)

obs de Π_1 classificada em Π_2	obs de Π_2 classificada em Π_1
29	146
32	154
39	
41	
49	
66	
75	
90	
97	
98	

=====

PROPOSTA (B)

SAS (C)

de Π_1 em Π_2	de Π_2 em Π_1	de Π_1 em Π_2	de Π_2 em Π_1
87	119		
94			

TOTAL DE MAL CLASSIFICADAS	{	PROPOSTA = A + B
		SAS = A + C

QUADRO 3.4B.1 OBSERVAÇÕES MAL CLASSIFICADAS NA EXECUÇÃO 18B

=====

segundo a PROPOSTA e o SAS (A)

obs de Π_1 classificada em Π_2	obs de Π_2 classificada em Π_1
15	119
45	144
51	146
57	154
59	159
78	166
	169
	182

=====

PROPOSTA (B)		SAS (C)	
--------------	--	---------	--

de Π_1 em Π_2	de Π_2 em Π_1	de Π_1 em Π_2	de Π_2 em Π_1
		12	
		25	
		67	

TOTAL DE MAL CLASSIFICADAS	{	PROPOSTA = A + B
		SAS = A + C

3.3 EXEMPLO DE APLICAÇÃO

3.3.1 INTRODUÇÃO

Como aplicação da técnica, usaram-se dados de discriminação de notas de 1000 Francos Suíços verdadeiros e falsos, já utilizadas em análise efetuada por Flury e Riedwyl (1983), relacionados, nos quadros 3.C1 e 3.C2.

A seguir apresenta-se a descrição dos dados usados para construir a função de discriminação amostral, além de fazer a avaliação correspondente pelo cálculo da Razão de Erro Aparente. Faz-se também, uma comparação da estimativa da probabilidade de má classificação com a obtida pelo SAS.

Os programas usados foram: Programa n^o 5 e Programa n^o 6 escritos em linguagem FORTRAN e SAS respectivamente e estão no apêndice.

3.3.2 DESCRIÇÃO DOS DADOS

Têm-se as medições de seis variáveis em 200 notas de banco, 100 das quais são verdadeiras (vêm de Π_1) e as outras 100 são falsas (vêm de Π_2).

As variáveis medidas foram:

X_1 : Comprimento das notas de banco.

X_2 : Largura do lado esquerdo das notas.

X_3 : Largura do lado direito.

X_4 : Largura da margem inferior.

X_5 : Largura da margem superior.

X_6 : Comprimento da diagonal medida desde o canto inferior esquerdo até o canto superior direito.

onde: $\tilde{x}_i^{(g)} = (x_{i1}^{(g)}, x_{i2}^{(g)}, \dots, x_{i6}^{(g)})$

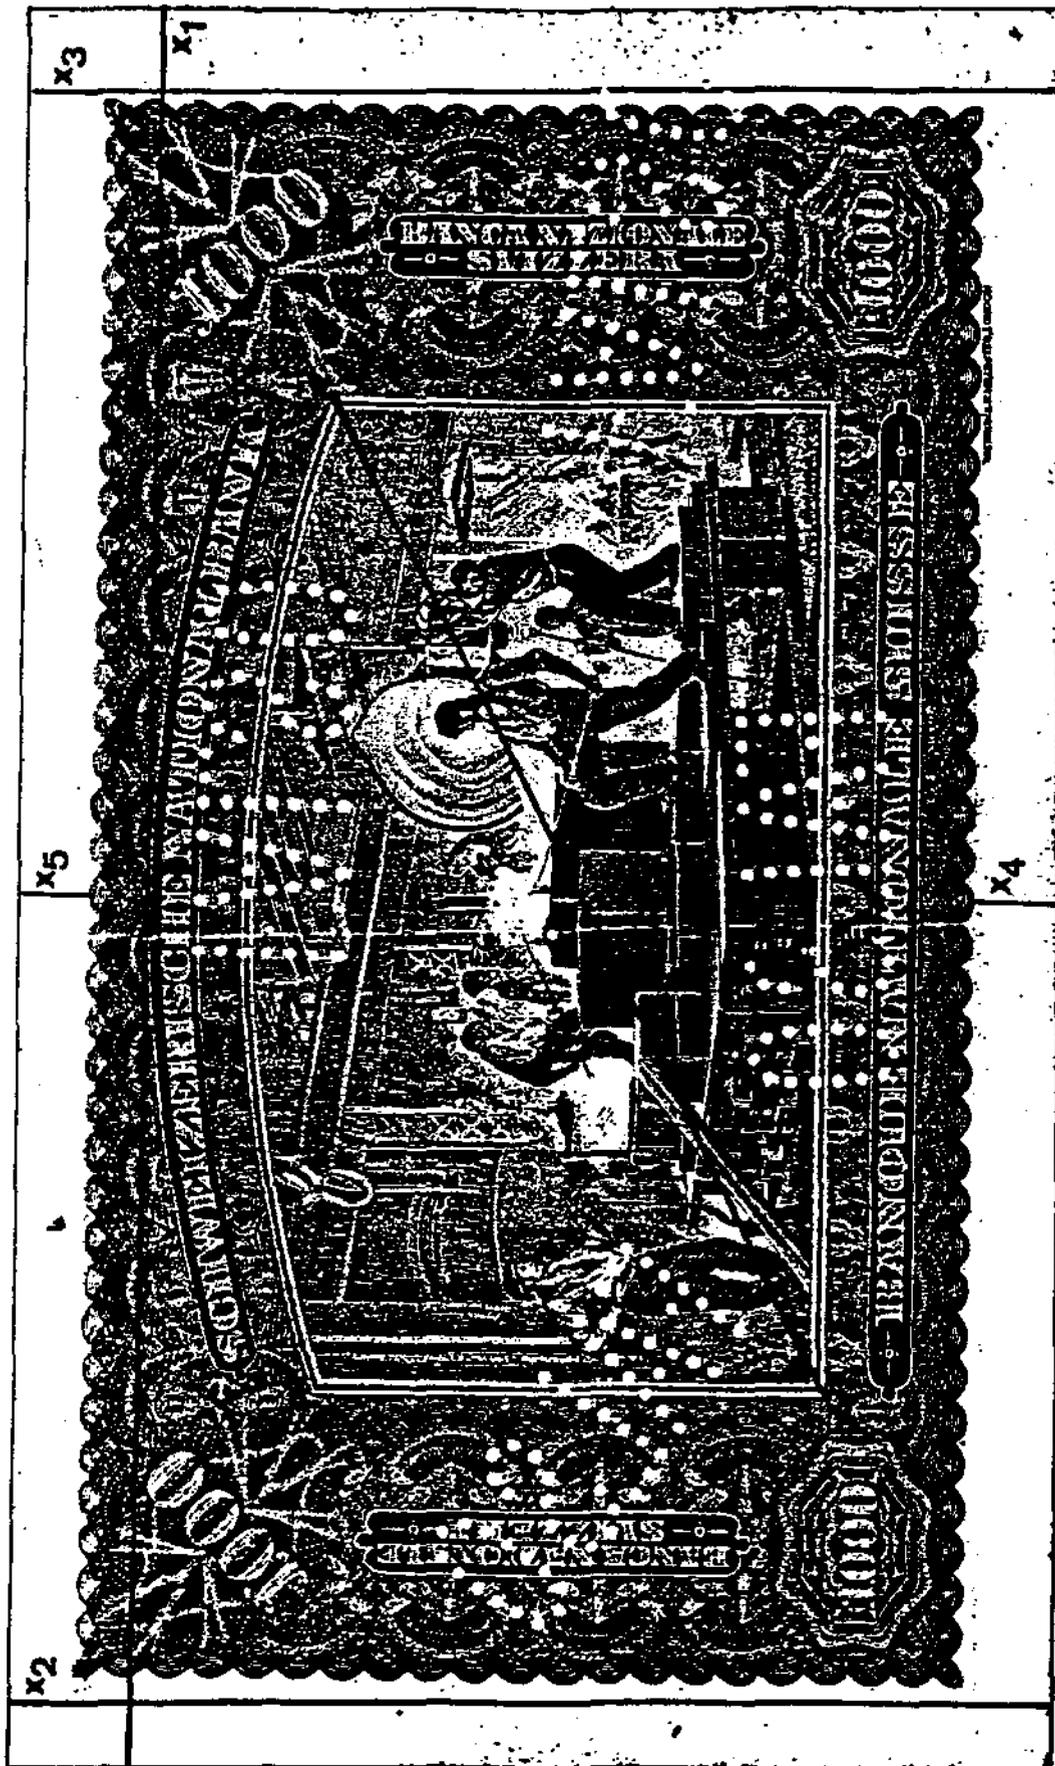
$$g = 1, 2$$

$$i = 1, 2, \dots, n_g$$

$$n_1 = n_2 = 100$$

é o vetor que contém as medições da i -ésima nota no g -ésimo grupo, resultando nas matrizes de dados $X^{(1)}$ e $X^{(2)}$ que ficam no quadro 3.C1 e 3.C2.

Abbildung 1



QUADRO 3. C1

MEDIDAS DE NOTAS DE BANCO
VERDADEIRAS

X_1	X_2	X_3	X_4	X_5	X_6	G-OBS
214.8	131.0	131.1	09.0	09.7	141.0	1001
214.6	129.7	129.7	08.1	09.5	141.7	1002
214.8	129.7	129.7	08.7	09.6	142.2	1003
214.8	129.7	129.6	07.5	10.4	142.0	1004
215.0	129.6	129.7	10.4	07.7	141.8	1005
215.7	130.8	130.5	09.0	10.1	141.4	1006
215.5	129.5	129.7	07.9	09.6	141.6	1007
214.5	129.6	129.2	07.2	10.0	141.7	1008
214.9	129.4	129.7	08.2	11.0	141.9	1009
215.2	130.4	130.3	09.2	10.0	140.7	1010
215.3	130.4	130.3	07.9	11.7	141.8	1011
215.1	129.5	129.6	07.7	10.5	142.2	1012
215.2	130.8	129.6	07.9	10.8	141.4	1013
214.7	129.7	129.7	07.7	10.9	141.7	1014
215.1	129.9	129.7	07.7	10.8	141.8	1015
214.5	129.8	129.8	09.3	08.5	141.6	1016
214.6	129.9	130.1	08.2	09.8	141.7	1017
215.0	129.9	129.7	09.0	09.0	141.9	1018
215.2	129.6	129.6	07.4	11.5	141.5	1019
214.7	130.2	129.9	08.6	10.0	141.9	1020
215.0	129.9	129.3	08.4	10.0	141.4	1021
215.6	130.5	130.0	08.1	10.3	141.6	1022
215.3	130.6	130.0	08.4	10.8	141.5	1023
215.7	130.2	130.0	08.7	10.0	141.6	1024
215.1	129.7	129.9	07.4	10.8	141.1	1025
215.3	130.4	130.4	08.0	11.0	142.3	1026
215.5	130.2	130.1	08.1	09.8	142.4	1027
215.1	130.3	130.3	09.8	09.5	141.9	1028
215.1	130.0	130.0	07.4	10.5	141.8	1029

QUADRO 3. C1 (cont.)

MEDIDAS DE NOTAS DE BANCO
VERDADEIRAS

X_1	X_2	X_3	X_4	X_5	X_6	G-OBS
214.8	129.7	129.3	08.3	09.0	142.0	1030
215.2	130.1	129.8	07.9	10.7	141.8	1031
214.8	139.7	129.7	08.6	09.1	142.3	1032
215.0	130.0	129.6	07.7	10.5	140.7	1033
215.6	130.4	130.1	08.4	10.3	141.0	1034
215.9	130.4	130.0	08.9	10.6	141.4	1035
214.6	130.2	130.2	09.4	09.7	141.8	1036
215.5	130.3	130.0	08.4	09.7	141.8	1037
215.3	129.9	129.4	07.9	10.0	142.0	1038
215.3	130.3	130.1	08.5	09.3	142.1	1039
213.9	130.3	129.0	08.1	09.7	141.3	1040
214.4	129.8	129.2	08.9	09.4	142.3	1041
214.8	130.1	129.6	08.8	09.9	140.9	1042
214.9	129.6	129.4	09.3	09.3	141.7	1043
214.9	130.4	129.7	09.0	09.8	140.9	1044
214.8	129.4	129.1	08.2	10.2	141.0	1045
214.3	129.5	129.4	08.3	10.2	141.8	1046
214.8	129.9	129.7	08.3	10.2	141.5	1047
214.8	129.9	129.7	07.3	10.9	142.0	1048
214.6	129.7	129.8	07.9	10.3	141.1	1049
214.5	129.0	129.6	07.8	09.8	142.0	1050
214.6	129.8	129.4	07.2	10.0	141.3	1051
215.3	130.6	130.0	09.5	09.7	141.1	1052
214.5	130.1	130.0	07.8	10.9	140.9	1053
215.4	130.2	130.2	07.8	10.9	141.6	1054
214.5	129.4	129.5	07.9	10.0	141.4	1055
215.2	129.7	129.4	08.2	09.4	142.0	1056
215.7	130.0	129.4	09.2	10.4	141.2	1057
215.0	129.6	129.4	08.8	09.0	141.1	1058

QUADRO 3. C1 (cont.)

MEDIDAS DE NOTAS DE BANCO

VERDADEIRAS

X_1	X_2	X_3	X_4	X_5	X_6	G-OBS
215.1	130.1	129.9	07.9	11.0	141.3	1059
215.1	130.0	129.8	08.2	10.3	141.4	1060
215.1	129.6	129.3	08.3	09.9	141.6	1061
215.3	129.7	129.4	07.5	10.5	141.5	1062
215.4	129.8	129.4	08.0	10.6	141.5	1063
214.5	130.0	129.5	08.0	10.8	141.4	1064
215.0	130.0	129.8	08.6	10.6	141.5	1065
215.2	130.6	130.0	08.8	10.6	140.8	1066
214.8	129.5	129.2	07.7	10.3	141.3	1067
214.8	129.7	129.3	09.1	09.5	141.5	1068
215.1	129.6	129.8	08.6	09.8	141.8	1069
214.9	130.2	130.2	08.0	11.2	139.6	1070
213.8	129.8	129.5	08.4	11.1	140.9	1071
215.2	129.9	129.5	08.2	10.3	141.4	1072
215.0	129.6	130.2	08.7	10.0	141.2	1073
214.4	129.9	129.6	07.5	10.5	141.8	1074
215.2	129.9	129.7	07.2	10.6	142.1	1075
214.1	129.6	129.3	07.6	10.7	141.7	1076
214.9	129.9	130.1	08.8	10.0	141.2	1077
214.6	129.8	129.4	07.4	10.6	141.0	1078
215.2	130.5	129.8	07.9	10.9	140.9	1079
214.6	129.9	129.4	07.9	10.0	141.8	1080
215.1	129.7	129.7	08.6	10.3	140.6	1081
214.9	129.8	129.6	07.5	10.3	141.0	1082
215.2	129.7	129.1	09.0	09.7	141.9	1083
215.2	130.1	129.9	07.9	10.8	141.3	1084
215.4	130.7	130.2	09.0	11.1	141.2	1085
215.1	129.9	129.6	08.9	10.2	141.5	1086
215.2	129.9	129.7	08.7	09.5	141.6	1087

QUADRO 3. C1 (cont.)

MEDIDAS DE NOTAS DE BANCO
VERDADEIRAS

X_1	X_2	X_3	X_4	X_5	X_6	G-OBS
215.0	129.6	129.2	08.4	10.2	142.1	1088
214.9	130.3	129.9	07.4	11.2	141.5	1089
215.0	129.9	129.7	08.0	10.5	142.0	1090
214.7	129.7	129.3	08.6	09.6	141.6	1091
215.4	130.0	129.9	08.5	09.7	141.4	1092
214.9	129.4	129.5	08.2	09.9	141.5	1093
214.5	129.5	129.3	07.4	10.7	141.5	1094
214.7	129.6	129.5	08.3	10.0	142.0	1095
215.6	129.9	129.9	09.0	09.5	141.7	1096
215.0	130.4	130.0	09.1	10.2	141.1	1097
214.4	129.7	129.5	08.0	10.3	141.2	1098
215.1	130.0	129.8	09.1	10.2	141.5	1099
214.7	130.0	129.4	07.8	10.0	141.2	1100

Fonte : Flury (1983).

G : Grupo de notas verdadeiras (1).

OBS : Número de observação dentro de cada grupo.

QUADRO 3. C2

MEDIDAS DE NOTAS DE BANCO
FALSAS

X_1	X_2	X_3	X_4	X_5	X_6	G-OBS
214.4	130.1	130.3	09.7	11.7	139.8	2001
214.9	130.5	130.2	11.0	11.5	139.5	2002
214.9	130.3	130.1	08.7	11.7	140.2	2003
215.0	130.4	130.6	09.9	10.9	140.3	2004
214.7	130.2	130.3	11.8	10.9	139.7	2005
215.0	130.2	130.2	10.6	10.7	139.9	2006
215.3	130.3	130.1	09.3	12.1	140.2	2007
214.8	130.1	130.4	09.6	11.5	139.9	2008
215.0	130.2	129.9	10.0	11.9	139.4	2009
215.2	130.6	130.8	10.4	11.2	140.3	2010
215.2	130.4	130.3	08.0	11.5	139.2	2011
215.1	130.5	130.3	10.6	11.5	140.1	2012
215.4	130.7	131.1	09.7	11.8	140.6	2013
214.9	130.4	129.9	11.4	11.0	139.9	2014
215.1	130.3	130.0	10.6	10.8	139.7	2015
215.5	130.4	130.0	08.2	11.2	139.2	2016
214.7	130.6	130.1	11.8	10.5	139.8	2017
214.7	130.4	130.1	12.1	10.4	139.9	2018
214.8	130.5	130.2	11.0	11.0	140.0	2019
214.4	130.2	129.9	10.1	12.0	139.2	2020
214.8	130.3	130.4	10.1	12.1	139.6	2021
215.1	130.6	130.3	12.3	10.2	139.6	2022
215.3	130.8	131.1	11.6	10.6	140.2	2023
215.1	130.7	130.4	10.5	11.2	139.7	2024
214.7	130.5	130.5	09.9	10.3	140.1	2025
214.9	130.0	130.3	10.2	11.4	139.6	2026
215.0	130.4	130.4	09.4	11.6	140.2	2027
215.5	130.7	130.3	10.2	11.8	140.0	2028
215.1	130.2	130.2	10.1	11.3	140.3	2029

QUADRO 3. C2 (cont.)

MEDIDAS DE NOTAS DE BANCO
FALSAS

X_1	X_2	X_3	X_4	X_5	X_6	G-OBS
214.5	130.2	130.6	09.8	12.1	139.9	2030
214.3	130.2	130.0	10.7	10.5	139.8	2031
214.5	130.2	139.8	12.3	11.2	139.2	2032
214.9	130.5	130.2	10.6	11.5	139.9	2033
214.6	130.2	130.4	10.5	11.8	139.7	2034
214.2	130.0	130.2	11.0	11.2	139.5	2035
214.8	130.1	130.1	11.9	11.1	139.5	2036
214.6	129.8	130.2	10.7	11.1	139.4	2037
214.9	130.7	130.3	09.3	11.2	138.3	2038
214.6	130.4	130.4	11.3	10.8	139.8	2039
214.5	130.5	130.2	11.8	10.2	139.6	2040
214.8	130.2	130.3	10.0	11.9	139.3	2041
214.7	130.0	129.4	10.2	11.0	139.2	2042
214.6	130.2	130.4	11.2	10.7	139.9	2043
215.0	130.5	130.4	10.6	11.1	139.9	2044
214.5	129.8	129.8	11.4	10.0	139.3	2045
214.9	130.6	130.4	11.9	10.5	139.8	2046
215.0	130.5	130.4	11.4	10.7	139.9	2047
215.3	130.6	130.3	09.3	11.3	138.1	2048
214.7	130.2	130.1	10.7	11.0	139.4	2049
214.9	129.9	130.0	09.9	12.3	139.4	2050
214.9	130.3	129.9	11.9	10.6	139.8	2051
214.6	129.9	129.7	11.9	10.1	139.0	2052
214.6	129.7	129.3	10.4	11.0	139.3	2053
214.5	130.1	130.1	12.1	10.3	139.4	2054
214.5	130.3	130.0	11.0	11.5	139.5	2055
215.1	130.0	130.3	11.6	10.5	139.7	2056
214.2	129.7	129.6	10.3	11.4	139.5	2057
214.4	130.1	130.0	11.3	10.7	139.2	2058

MEDIDAS DE NOTAS DE BANCO

FALSAS

X_1	X_2	X_3	X_4	X_5	X_6	G-OBS
214.8	130.4	130.6	12.5	10.0	139.3	2059
214.6	130.6	130.1	08.1	12.1	137.9	2060
215.6	130.1	129.7	07.4	12.2	138.4	2061
214.9	130.5	130.1	09.9	10.2	138.1	2062
214.6	130.1	130.0	11.5	10.6	139.5	2063
214.7	130.1	130.2	11.6	10.9	139.1	2064
214.3	130.3	130.0	11.4	10.5	139.8	2065
215.1	130.3	130.6	10.3	12.0	139.7	2066
216.3	130.7	130.4	10.0	10.1	138.8	2067
215.6	130.4	130.1	09.6	11.2	138.6	2068
214.8	129.9	129.8	09.6	12.0	139.6	2069
214.9	130.0	129.9	11.4	10.9	139.7	2070
213.9	130.7	130.5	08.7	11.5	137.8	2071
214.2	130.6	130.4	12.0	10.2	139.6	2072
214.8	130.5	130.3	11.8	10.5	139.4	2073
214.8	129.6	130.0	10.4	11.6	139.2	2074
214.8	130.1	130.0	11.4	10.5	139.6	2075
214.9	130.4	130.2	11.9	10.7	139.0	2076
214.3	130.1	130.1	11.6	10.5	139.7	2077
214.5	130.4	130.0	09.9	12.0	139.6	2078
214.8	130.5	130.3	10.2	12.1	139.1	2079
214.5	130.2	130.4	08.2	11.8	137.8	2080
215.0	130.4	130.1	11.4	10.7	139.1	2081
214.8	130.6	130.6	08.0	11.4	138.7	2082
215.0	130.5	130.1	11.0	11.4	139.3	2083
214.6	130.5	130.4	10.1	11.4	139.3	2084
214.7	130.2	130.1	10.7	11.1	139.5	2085
214.7	130.4	130.0	11.5	10.7	139.4	2086
214.5	130.4	130.0	08.0	12.2	138.5	2087

QUADRO 3. C2 (cont.)

MEDIDAS DE NOTAS DE BANCO
FALSAS

X_1	X_2	X_3	X_4	X_5	X_6	G-OBS
214.8	130.0	129.7	11.4	10.6	139.2	2088
214.8	129.9	130.2	09.6	11.9	139.4	2089
214.6	130.3	130.2	12.0	09.1	139.2	2090
215.1	130.2	129.8	10.2	12.0	139.4	2091
215.4	130.5	130.6	08.8	11.0	138.6	2092
214.7	130.3	130.2	10.8	11.1	139.2	2093
215.0	130.5	130.3	09.6	11.0	138.5	2094
214.9	130.3	130.5	11.6	10.6	139.8	2095
215.0	130.4	130.3	09.9	12.1	139.6	2096
215.1	130.3	129.9	10.3	11.5	139.7	2097
214.8	130.3	130.4	10.6	11.1	140.0	2098
214.7	130.7	130.8	11.2	11.2	139.4	2099
214.3	129.9	129.9	10.2	11.5	139.6	2100

FONTE : Flury (1983)

G : Grupo de notas falsas (2).

OBS : Número de observações dentro de cada grupo.

3.3.3 RESULTADOS OBTIDOS.

Consideramos as duas amostras onde os seus parâmetros populacionais são desconhecidos. As medidas descritivas que são as estimativas dos parâmetros \bar{M}_1 , \bar{M}_2 , V_1 e V_2 obtidas através dos dados do quadro 3.C1 e 3.C2 são as seguintes:

$$\bar{X}^{(1)} = \begin{pmatrix} 214.9690 \\ 129.9430 \\ 129.7200 \\ 8.3050 \\ 10.1710 \\ 141.5150 \end{pmatrix}$$

(14)

$$\bar{X}^{(2)} = \begin{pmatrix} 214.8230 \\ 130.3000 \\ 130.1930 \\ 10.5300 \\ 11.1330 \\ 139.4500 \end{pmatrix}$$

Matriz de covariâncias da amostra um: (S_1)

$$\begin{pmatrix} 0.150372 & 0.058198 & 0.057495 & 0.057130 & 0.014246 & 0.005045 \\ 0.058198 & 0.132603 & 0.055952 & 0.056648 & 0.048035 & -0.044810 \\ 0.057495 & 0.085952 & 0.126420 & 0.058179 & 0.029673 & -0.023472 \\ 0.057130 & 0.056648 & 0.058179 & 0.413206 & -0.260460 & 0.000628 \\ 0.014246 & 0.048035 & 0.029673 & -0.260460 & 0.415009 & -0.076023 \\ 0.005045 & -0.044810 & -0.023472 & 0.000628 & -0.076023 & 0.200688 \end{pmatrix}$$

Matriz de covariâncias da amostra dois: (S_2)

0.124498	0.031602	0.024045	-0.100596	0.019448	0.011619
0.031602	0.064790	0.046783	-0.024041	-0.011918	-0.004987
0.024045	0.046783	0.088727	-0.018574	0.000134	0.034221
-0.100596	-0.024041	-0.018574	1.281313	-0.490192	0.238489
0.019448	-0.011918	0.000134	-0.490192	0.404455	-0.022071
0.011619	-0.004987	0.034221	0.238489	-0.022071	0.311162

Com a sub-rotina FO2AEF obtemos os autovalores e autovetores da matriz $S_1^{-1}S_2$ que são os seguintes:

$$\begin{array}{ll}
 r_6 = 0.283892 & r_5 = 0.545285 \\
 r_4 = 0.906826 & r_3 = 1.052638 \\
 r_2 = 1.678315 & r_1 = 6.120406
 \end{array}$$

(15)

b_6	b_5	b_4	b_3	b_2	b_1
-0.390511	-1.340457	2.002322	-1.389171	-0.062965	0.977541
-1.194453	3.372635	1.341897	1.030241	0.109882	0.660427
-0.361893	-2.581479	-1.650547	1.910784	1.334965	0.426138
-0.510676	-0.248453	-0.043216	-0.362239	-0.469081	-2.237451
-0.836594	0.023098	-0.746921	-1.320852	0.523342	-1.538391
0.587390	0.626593	0.580347	0.154213	1.934701	-1.069888

As combinações com máximo e mínimo quociente de variâncias são, respectivamente:

$$Y_{\max}^{(g)} = 0.9775X_1^{(g)} + 0.6604X_2^{(g)} + 0.4261X_3^{(g)} \\ - 2.2374X_4^{(g)} - 1.5384X_5^{(g)} - 1.0599X_6^{(g)}$$

(16)

$$Y_{\min}^{(g)} = -0.3905X_1^{(g)} - 1.1844X_2^{(g)} - 0.3619X_3^{(g)} \\ - 0.5107X_4^{(g)} - 0.8366X_5^{(g)} + 0.5874X_6^{(g)}$$

Com as quais obtém-se a amostra de dados transformados bivariados:

$$\tilde{y}_i^{(g)} = \begin{pmatrix} Y_{i\max}^{(g)} \\ Y_{i\min}^{(g)} \end{pmatrix} \quad \begin{array}{l} i = 1, \dots, n_g \\ g = 1, 2 \\ n_1 = n_2 \end{array}$$

apresentados no quadro 3.D1 e 3.D2 respectivamente.

QUADRO 3. D1

TRABALHO DE APLICAÇÃO
 DADOS TRANSFORMADOS DAS NOTAS DE BANCO
 VERDADEIRAS (1)

Y_{\max}	Y_{\min}	GRUPO
167.854767	-217.688538	1
167.783569	-214.512863	1
165.952850	-214.687378	1
167.576447	-214.825089	1
165.625565	-214.159653	1
167.307495	-217.683624	1
168.930963	-214.665741	1
167.574371	-214.717728	1
165.135437	-215.460205	1
166.917587	-217.367889	1
166.142899	-217.519119	1
166.924316	-214.771698	1
168.031525	-217.304062	1
166.622559	-215.518875	1
167.193627	-215.771591	1
166.753922	-214.464447	1
167.400879	-215.198563	1
166.850220	-214.831818	1
166.962891	-216.024719	1
166.196899	-215.777710	1
167.013763	-215.510956	1
166.292557	-216.695526	1
166.730927	-217.328094	1
167.311234	-216.431671	1
168.559814	-215.863037	1
166.508682	-216.727081	1
166.170654	-215.854691	1
164.908661	-216.392639	1

QUADRO 3. D1 (cont.)

TRABALHO DE APLICAÇÃO
 DADOS TRANSFORMADOS DAS NOTAS DE BANCO
 VERDADEIRAS (1)

Y_{max}	Y_{min}	GRUPO
168.520157	-215.595413	1
167.812378	-213.953873	1
167.172318	-216.104233	1
166.639798	-214.159271	1
166.746628	-216.210968	1
168.233828	-217.117950	1
166.480316	-217.470245	1
165.004501	-216.063522	1
168.102554	-215.951370	1
167.832458	-215.056503	1
168.023331	-215.449692	1
167.313538	-215.105148	1
165.166991	-214.345734	1
166.867050	-216.194656	1
165.505707	-214.647549	1
166.911850	-216.646652	1
166.966614	-215.063385	1
165.600052	-214.677261	1
166.786798	-215.635101	1
167.429443	-215.416336	1
167.678896	-215.468628	1
167.072693	-213.523056	1
169.390259	-214.717361	1
166.385925	-217.204559	1
167.443253	-216.548111	1
168.179855	-216.578064	1
167.398743	-214.535492	1
165.616943	-214.940506	1

QUADRO 3. D1 (cont.)

TRABALHO DE APLICAÇÃO
 DADOS TRANSFORMADOS DAS NOTAS DE BANCO
 VERDADEIRAS (1)

Y _{max}	Y _{min}	GRUPO
165.613373	-216.800583	1
167.819672	-214.732727	1
167.185838	-216.648042	1
167.376617	-215.999237	1
167.078995	-214.939453	1
168.356079	-215.325317	1
167.247314	-215.822815	1
166.340546	-215.972504	1
165.816376	-216.356689	1
166.787781	-217.737167	1
167.526642	-214.793015	1
165.783142	-215.074402	1
166.562698	-215.072464	1
168.456366	-218.012863	1
164.697617	-216.209213	1
167.280487	-215.810272	1
166.739929	-215.749008	1
167.375626	-215.108932	1
168.399704	-215.211746	1
166.330994	-214.802017	1
166.573914	-216.083176	1
168.337708	-215.497681	1
166.087218	-217.277939	1
167.360153	-214.900620	1
167.088776	-216.278900	1
166.953949	-215.487335	1
165.581055	-215.039520	1
167.591064	-216.517776	1

TRABALHO DE APLICAÇÃO
 DADOS TRANSFORMADOS DAS NOTAS DE BANCO
 VERDADEIRAS (1)

Y_{\max}	Y_{\min}	GRUPO
165.493927	-218.292557	1
165.707001	-216.022491	1
167.265701	-215.351227	1
165.723434	-214.872574	1
167.721283	-216.601257	1
166.674103	-215.517288	1
166.566266	-214.804932	1
167.964294	-215.803833	1
167.166382	-214.702515	1
167.315399	-214.854095	1
166.195435	-214.704330	1
166.964752	-215.674271	1
166.214172	-217.171082	1
167.025818	-215.274307	1
165.410736	-216.316467	1
168.383606	-215.360489	1

Fonte : Dados da matriz 3.C1 transformados segundo a proposta (16).

QUADRO 3. D2

TRABALHO DE APLICAÇÃO
 DADOS TRANSFORMADOS DAS NOTAS DE BANCO
 FALSAS (2)

Y_{max}	Y_{min}	GRUPO
163.157333	-218.903381	2
161.584656	-220.212997	2
165.506454	-218.519470	2
164.323105	-218.743744	2
160.154694	-219.601868	2
163.186005	-218.785233	2
163.939651	-219.316742	2
163.568939	-218.920761	2
163.084503	-219.667847	2
163.155685	-219.639435	2
168.884766	-218.891037	2
168.086778	-219.770584	2
163.870270	-219.913818	2
160.841034	-219.536026	2
163.322693	-219.072510	2
169.064240	-218.750778	2
160.642972	-219.613922	2
160.087524	-219.385818	2
161.726151	-219.461960	2
162.332367	-219.685715	2
162.424698	-219.991013	2
160.874008	-219.964340	2
161.857468	-220.195587	2
163.366692	-219.978577	2
165.188278	-218.325363	2
163.134811	-219.101028	2
164.385696	-219.060364	2
163.144333	-220.271133	2

QUADRO 3. D2 (cont.)

TRABALHO DE APLICAÇÃO
DADOS TRANSFORMADOS DAS NOTAS DE BANCO
FALSAS (2)

Y_{\max}	Y_{\min}	GRUPO
163.055496	-218.835907	2
162.503906	-219.497391	2
162.606400	-218.381989	2
158.695831	-220.142838	2
162.055666	-219.773788	2
161.623688	-219.688019	2
161.031677	-219.091446	2
159.781769	-219.785019	2
162.221680	-218.830627	2
167.296366	-220.073807	2
161.398209	-219.440155	2
161.297662	-219.319046	2
163.165406	-219.793228	2
163.596123	-218.597549	2
161.537720	-219.007797	2
162.653973	-219.550583	2
162.185455	-218.142776	2
160.942612	-219.851654	2
161.679382	-219.624496	2
167.679474	-220.311737	2
162.694794	-219.227631	2
162.439606	-219.590210	2
160.377609	-219.396027	2
161.352051	-218.780334	2
162.703125	-218.207352	2
160.377686	-219.159424	2
160.976318	-219.745529	2
161.476501	-219.082428	2

QUADRO 3. D2 (cont.)

TRABALHO DE APLICAÇÃO
DADOS TRANSFORMADOS DAS NOTAS DE BANCO
FALSAS (2)

Y_{\max}	Y_{\min}	GRUPO
161.836365	-218.325790	2
161.623932	-219.127792	2
160.754700	-219.827896	2
168.576157	-220.139877	2
169.965501	-219.220901	2
167.486938	-219.349854	2
161.207794	-219.048141	2
161.129471	-219.696533	2
161.106247	-218.858917	2
162.403534	-220.140320	2
168.303589	-219.800217	2
166.708059	-219.893433	2
163.177383	-218.957108	2
160.942657	-219.092041	2
167.814957	-219.993896	2
160.708054	-219.495865	2
161.383911	-219.840851	2
162.313873	-218.980057	2
162.676966	-218.932755	2
161.265564	-220.177643	2
160.675293	-218.817108	2
162.628342	-219.662796	2
162.820358	-220.538483	2
168.685867	-219.590424	2
162.333389	-219.866394	2
169.437469	-219.292343	2
162.005585	-220.219680	2
163.756104	-219.742386	2

QUADRO 3. D2 (cont.)

TRABALHO DE APLICAÇÃO
DADOS TRANSFORMADOS DAS NOTAS DE BANCO
FALSAS (2)

Y_{max}	Y_{min}	GRUPO
162.434967	-219.252548	2
161.455811	-219.587921	2
167.737701	-219.505920	2
161.751129	-219.023331	2
163.713684	-219.135681	2
161.365723	-218.893539	2
162.538300	-219.856506	2
168.889343	-219.539886	2
162.637848	-219.635483	2
166.686493	-219.742371	2
161.304520	-219.459930	2
163.096160	-220.050247	2
162.874451	-219.468689	2
162.420395	-219.174850	2
161.896881	-220.500793	2
162.157974	-218.686172	2

Fonte : Dados da matriz 3.C2 transformados segundo a proposta (16).

Desta maneira, sob a suposição de normalidade das variáveis originais, obtemos as variáveis normais bivariadas, cujos parâmetros foram apresentados na secção (2.3.1) do capítulo 2.

Com os dados amostrais transformados que estão nos quadros 3.D1 e 3.D2, estimam-se os parâmetros $\hat{\mu}^{(1)}$, $\hat{\mu}^{(2)}$, $\hat{\Sigma}_1$, $\hat{\Sigma}_2$, por:

$$\begin{aligned} \hat{\mu}^{(1)} = \bar{y}^{(1)} = \begin{bmatrix} 167.0185 \\ 215.7292 \end{bmatrix} & \quad \hat{\Sigma}_1 = \begin{bmatrix} 1 & 0 \\ 0 & .1 \end{bmatrix} \\ \hat{\mu}^{(2)} = \bar{y}^{(2)} = \begin{bmatrix} 163.0435 \\ -219.4238 \end{bmatrix} & \quad \hat{\Sigma}_2 = \begin{bmatrix} 6.1204 & 0 \\ 0 & 0.2839 \end{bmatrix} \end{aligned}$$

$$\widehat{\ln(\lambda_1 \lambda_2)} = \ln(r_1 r_2) = 0.5525$$

A função de discriminação amostral é portanto:

$$D(x) = x' \left[\hat{\Sigma}_1^{-1} - \hat{\Sigma}_2^{-1} \right] x - 2x' \left[\hat{\Sigma}_1^{-1} \bar{y}^{(1)} - \hat{\Sigma}_2^{-1} \bar{y}^{(2)} \right] - \hat{d} \quad (17)$$

com:

$$\hat{d} = \frac{1}{2} \ln \left[r_1 r_2 \right] - \frac{1}{2} \left[\bar{y}^{(1)'} \bar{y}^{(2)} - \bar{y}^{(2)'} \hat{\Sigma}_2^{-1} \bar{y}^{(2)} \right]$$

Supondo probabilidades a priori e custos de má classificação iguais, tem-se:

$$D(x) = 0.8366Y_{\max}^2 - 2.5224Y_{\min}^2 - 280.7582Y_{\max} - 1114.366Y_{\min} - 99504 \quad (18)$$

função que é proposta para classificar uma nova nota com medições $\underline{x} \in \mathbb{R}^6$, como verdadeira ou falsa, onde a relação entre \underline{x} e \underline{y} é:

$$\underline{y} = \begin{pmatrix} b'_1 & \underline{x} \\ b'_p & \underline{x} \end{pmatrix} \quad \begin{matrix} b'_1, b'_p \in \mathbb{R}^6 \\ \underline{y} \in \mathbb{R}^2 \end{matrix}$$

A avaliação de (18), cria Razão de Erro Aparente (REA) para estimar a Probabilidade Total de Má Classificação, já apresentado na secção (2.3.3) do capítulo 2, onde cada observação transformada dos quadros 3.D1 e 3.D2 foi avaliada em (18), isto é foram re-classificadas pelo método proposto.

Paralelamente, foi feita a discriminação pelo "PROC DISCRIM" do SAS e têm-se os seguintes resultados:

GRUPO	DECISÃO ESTATÍSTICA				TOTALS	
	MÉTODO PROPOSTO		SAS			
	Π_1	Π_2	Π_1	Π_2		
VERDADEIRO						
Π_1	100	0	99	1	100	
Π_2	0	100	0	100	100	(19)
TOTALS	100	100	99	101	200	

Segundo (19) pode-se dizer que para os conjuntos de dados dos quadros 3.C1 e 3.C2, este método é tão bom quanto a Regra de Classificação Quadrática de Anderson com a que classifica o SAS, sendo que o método proposto leva vantagem, já que os conjuntos de notas de banco de dimensão 6 se reduzem à dimensão 2, onde a interpretação é mais fácil, além da representação gráfica.

Para maior detalhes ver os quadros A2, A3, A4, e A5 do apêndice.

Pode-se perguntar se os resultados serão semelhantes se as transformações são obtidas com os autovetores da matriz $S_2^{-1}S_1$ em lugar dos autovetores de $S_1^{-1}S_2$. Aplicando o método para $S_2^{-1}S_1$, tem-se:

$$\begin{array}{ll} r_6 = 0.163388 & r_5 = 0.595836 \\ r_4 = 0.949989 & r_3 = 1.102748 \\ r_2 = 1.833902 & r_1 = 3.522463 \end{array}$$

e autovetores amostrais associados:

\tilde{b}_1	\tilde{b}_2	\tilde{b}_3	\tilde{b}_4	\tilde{b}_5	\tilde{b}_6
-0.395134	0.048603	1.353993	-2.102674	-1.815269	-0.732920
-0.266953	-0.084819	-1.004152	-1.409150	4.567278	-2.241777
-0.172250	-1.030455	-1.862397	1.733269	-3.495682	-0.679210
0.904406	0.362086	0.353066	0.045382	-0.336460	-0.998486
0.621837	-0.403970	1.287403	0.784386	0.031280	-1.570138
0.429420	-1.493403	-0.150308	-0.609433	0.848543	1.102427

Com as variáveis transformadas:

$$Y_{\max}^{(g)} = -0.7329X_1^{(g)} - 2.2418X_2^{(g)} - 0.6792X_3^{(g)} + 0.9585X_4^{(g)} + 1.5701X_5^{(g)} + 1.1024X_6^{(g)}$$

$$Y_{\min}^{(g)} = -0.3951X_1^{(g)} - 0.2669X_2^{(g)} - 0.1723X_3^{(g)} - 0.9044X_4^{(g)} - 0.6218X_5^{(g)} + 0.4284X_6^{(g)}$$

Neste caso a tabela de classificação foi:

GRUPO	DECISÃO ESTATÍSTICA				TOTAIS
	MÉTODO PROPOSTO		SAS		
	π_1	π_2	π_1	π_2	
VERDADEIRO					
π_1	99	1	99	1	100
π_2	1	99	0	100	100
TOTAIS	100	100	99	101	200

onde a estimativa da probabilidade total de má classificação foi de 1%.

Portanto para o conjunto de dados do exemplo de aplicação, vê-se que os resultados obtidos com os autovetores da matriz $S_2^{-1}S_1$ são bem semelhantes aos obtidos com os autovetores da matriz $S_1^{-1}S_2$.

CAPITULO 4

CONCLUSÕES DOS RESULTADOS EXPERIMENTAIS E DO EXEMPLO DE APLICAÇÃO

Nos problemas que envolvem regras de classificação é de fundamental importância avaliar o erro de má classificação fornecida por uma função discriminante. Neste estudo além de apresentá-la (função discriminante), ela também foi avaliada mediante simulações de Monte Carlo e um exemplo de aplicação, segundo a apresentação do capítulo anterior.

Agora as conclusões de tais simulações para os casos em duas e três dimensões separadamente, e também as correspondentes ao exemplo proposto.

Com $p = 2$ observou-se que:

10.-Quando aceitamos a hipótese de homogeneidade das matrizes de covariâncias V_1 e V_2 ;

Segundo o novo critério de discriminação, os autovalores da matriz $S_1^{-1}S_2$ estão próximos do valor "um", e as estimativas das probabilidades de má classificação, ou seja, as Razões de Erro Aparente estão próximos de 0.5, como pode ser observado nas colunas "PROPOSTA DE DISCRIMINAÇÃO" das execuções 01A, 02A, 07A.

Na situação exposta para obter os resultados das colunas "SAS", o pacote estatístico SAS, usa a Função Discriminante de Fisher, com a qual também se obtém probabilidades de má classificação próximos de 0.5.

Apesar das regiões de má classificação geradas com os dois métodos não serem exatamente as mesmas, como pode ser observado nos quadros 3.1A.1, 3.2A.2 em geral há uma alta porcentagem de elementos comuns mal classificados, em ambos os métodos, a qual fica expressa na parte (A) dos quadros antes assinalados e com quase o mesmo número de elementos nas partes (B) e (C), portanto as Razões de Erro Aparente são muito parecidas.

Cabe mencionar ainda que, quando a hipótese de homogeneidade é aceita, a transformação proposta muda a estrutura inicial dos dados em duas distribuições normais bivariadas com matrizes de covariâncias iguais à identidade, como pode ser visto nos gráficos 1 e 2.

20.-Quando a hipótese de homogeneidade das matrizes é rejeitada;

A referida transformação muda a estrutura inicial dos dados da seguinte maneira: O primeiro grupo transforma-se num conjunto com matriz de covariâncias identidade e o segundo, se transforma em um conjunto com matriz de covariâncias diagonal, cuja primeira variável tem como variância o máximo autovalor e a segunda, o mínimo autovalor da matriz $V_1^{-1}V_2$. (ver gráfico 3 e 4).

Segundo a regra proposta, as estimativas das probabilidades de má classificação decrescem aproximadamente de 32% no quadro 3.1A até 1% no quadro 3.4A, sendo que temos nos quadros 3.2A e 3.3A, 26% e 10% respectivamente, dependendo da relação existente entre os autovalores máximo e mínimo que em geral afastam-se da "unidade".

Nesta situação, para obter os resultados das colunas "SAS" dos quadros apresentados, o sistema estatístico SAS usa a Função Quadrática Amostral de Anderson, e observou-se então que as Razões de Erro Aparente são semelhantes às geradas com (12) do capítulo 3, ou seja, com a proposta deste trabalho.

Como era de esperar, as regiões de má classificação são as mesmas em ambos os métodos, como pode ser observado nos quadros 3.1A.2 , 3.2A.1, 3.4A.1, onde nos subconjuntos (B) e (C) não há nenhum elemento.

Caso $p=3$ observou-se que:

3). -Toda vez que a hipótese de homogeneidade entre V_1 e V_2 é aceita;

Os autovalores máximo e mínimo da matriz $S_1^{-1}S_2$ estão próximos da unidade e as estimativas das probabilidades de má classificação próximas de 0.5 como pode ser observado nas colunas "PROPOSTA DE DISCRIMINAÇÃO" das execuções 01B, 02B, 13B.

Pode-se ressaltar ainda que, para a obtenção dos valores apresentados nas colunas "S₀", usou-se a Função Linear Discriminante de Fisher.

As regiões de classificação geradas pelos dois métodos são diferentes, como pode ser visto no quadro 3.1B.1, mas tem uma alta porcentagem de elementos comuns - parte (A) dos quadros, e o número de observações das partes (B) e (C) são quase iguais dando origem a Razões de Erro Aparente muito próximas.

4).-Quando a hipótese de homogeneidade das matrizes V_1 e V_2 é rejeitada;

Têm-se execuções tais como as 05B e 06B, onde a Função de Discriminação Quadrática Amostral de Anderson discrimina melhor que a proposta, resultado que se obtém comparando as Razões de Erro Aparente respectivas. Entretanto, nas execuções 07B, 14B, 15B, 16B e 18B, este método classifica melhor. Também há situações onde ambos os métodos geram as mesmas regiões de classificação, como pode ser observado nos resultados das execuções 11B, 12B.

Nesta situação, a transformação usada muda a estrutura inicial dos dados em duas distribuições normais bivariadas com as mesmas características que no caso $p=2$, como se pode observar no gráfico 5.

Por outro lado considerando-se o conjunto de dados do exemplo apresentado, podemos dizer que este método classifica tão bem como a função discriminante quadrática de Anderson, com a possibilidade de se poder escolher a matriz $S_1^{-1}S_2$ ou $S_2^{-1}S_1$ melhor condicionada, devendo-se ficar com aquela que conduz a menores estimativas das probabilidades de má classificação, como se pode observar nos resultados obtidos no item (3.3) do capítulo 3. Além disso, os dois conjuntos de dados de dimensão seis apresentados nos quadros 3.C1 e 3.C2 foram transformados em outros conjuntos de dimensão dois, quadros 3.D1 e 3.D2, onde a visualização gráfica é bem mais fácil. (ver o gráfico 6).

Das exposições feitas até aqui, pode-se dizer de maneira mais geral, baseados nos resultados apresentados que:

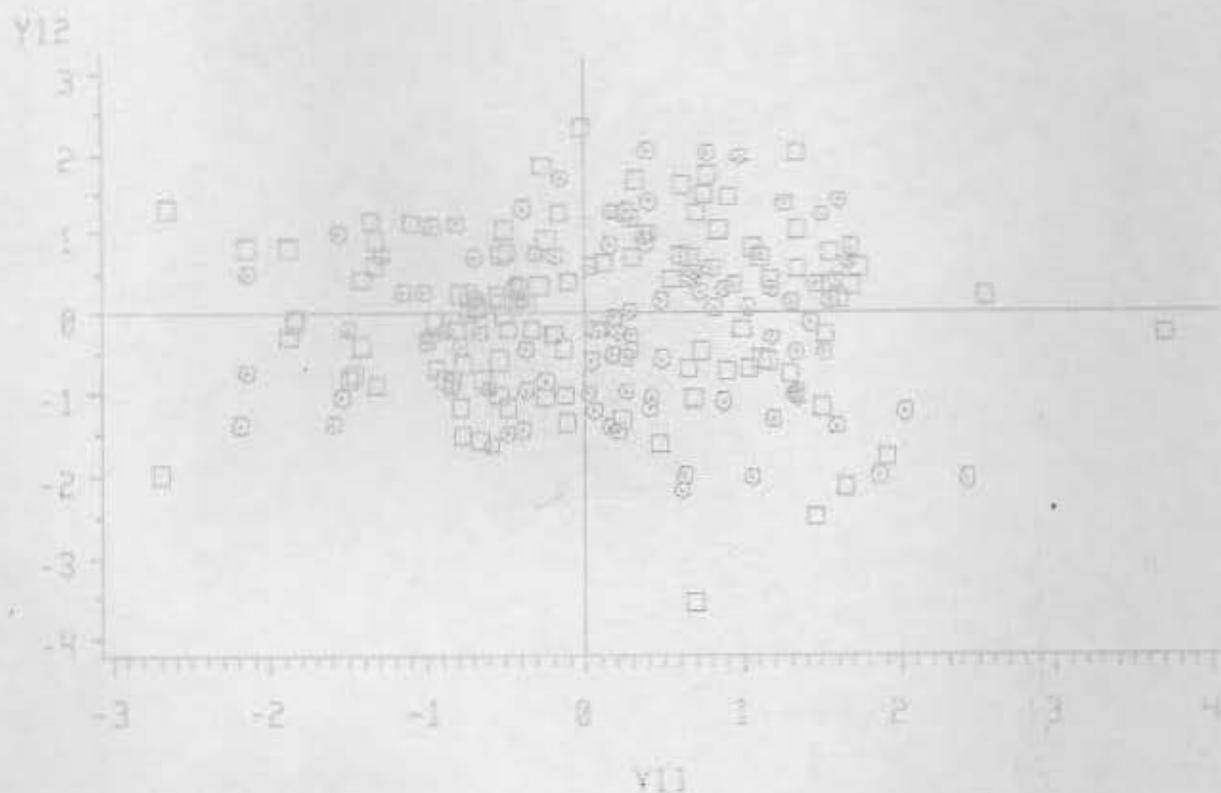
No caso de se terem amostras de duas populações bivariadas, a regra de classificação conduz às mesmas estimativas das probabilidades de má classificação que o SAS, ou seja, os dois métodos discriminam igualmente sempre que a hipótese de homogeneidade das matrizes é rejeitada.

No entanto, quando o número de variáveis medidas em ambos os grupos é três, há situações nas quais os métodos conduzem a estimativas um pouco diferentes para as probabilidades de má classificação.

Vê-se que nos casos estudados, existe um decréscimo significativo na estimativa de probabilidade de má classificação e os métodos se aproximam quando os afastamentos entre as matrizes de covariâncias vai-se acentuando, ou seja, quando a diferença entre os autovalores máximo e mínimo vai aumentando.

Considere-se o presente trabalho como uma primeira tentativa de abordagem do problema de discriminação e classificação, por outro ponto de vista, para duas populações multivariadas com estruturas de covariâncias diferentes, e que ainda existem incógnitas por responder, tal como a generalização para mais de duas populações.

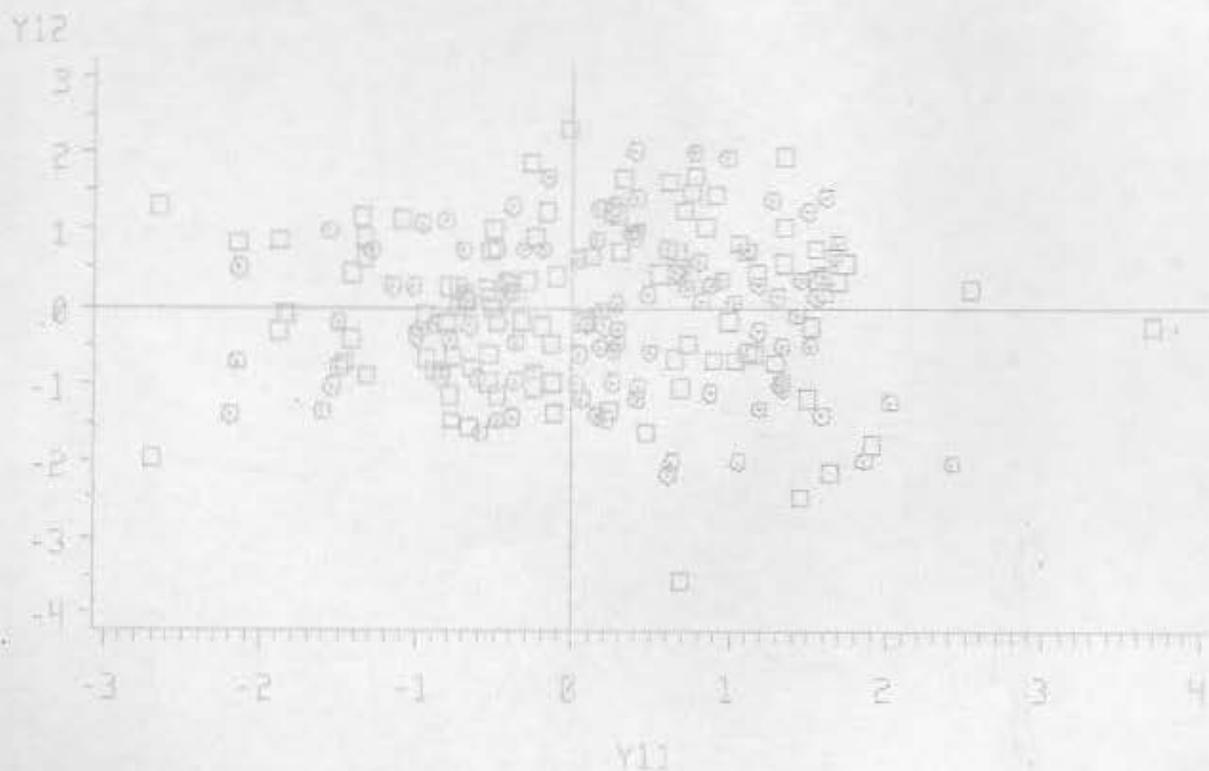
GRAFICO 1
DADOS SIMULADOS TRANSFORMADOS
EXECUCAO NUMERO 01A
O NUMERO DE VAR. ORIGINAIS E DOIS



CIRCULO: GRUPO 01
QUADRADO: GRUPO 02

GRAFICO 2

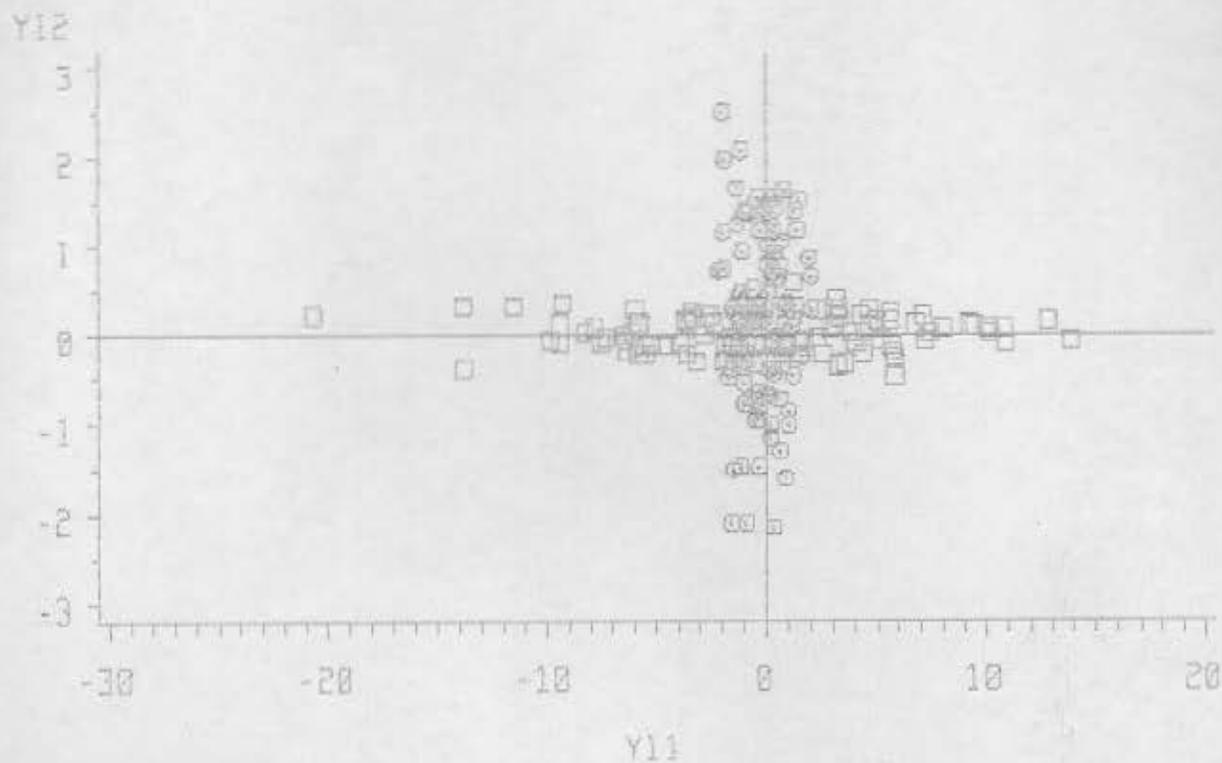
DADOS SIMULADOS TRANSFORMADOS
EXECUCAO NUMERO 070
O NUMERO DE VAR ORIGINAIS E DOIS.



CIRCULO: GRUPO UM
QUADRADO: GRUPO DOIS

GRAFICO 3

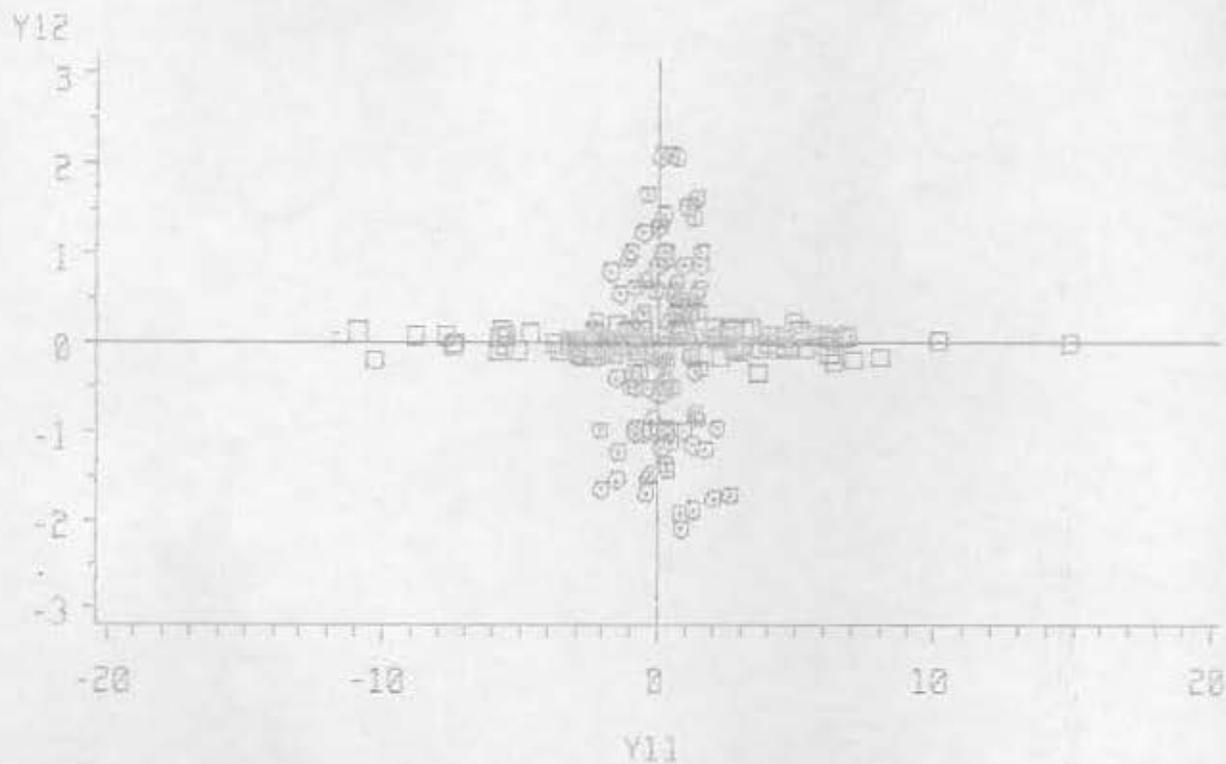
DADOS SIMULADOS TRANSFORMADOS
EXECUCAO NUMERO 09A
O NUMERO DE VAR ORIGINAIS E DOIS



CIRCULO: GRUPO 01
QUADRADO: GRUPO 02

GRAFICO 4

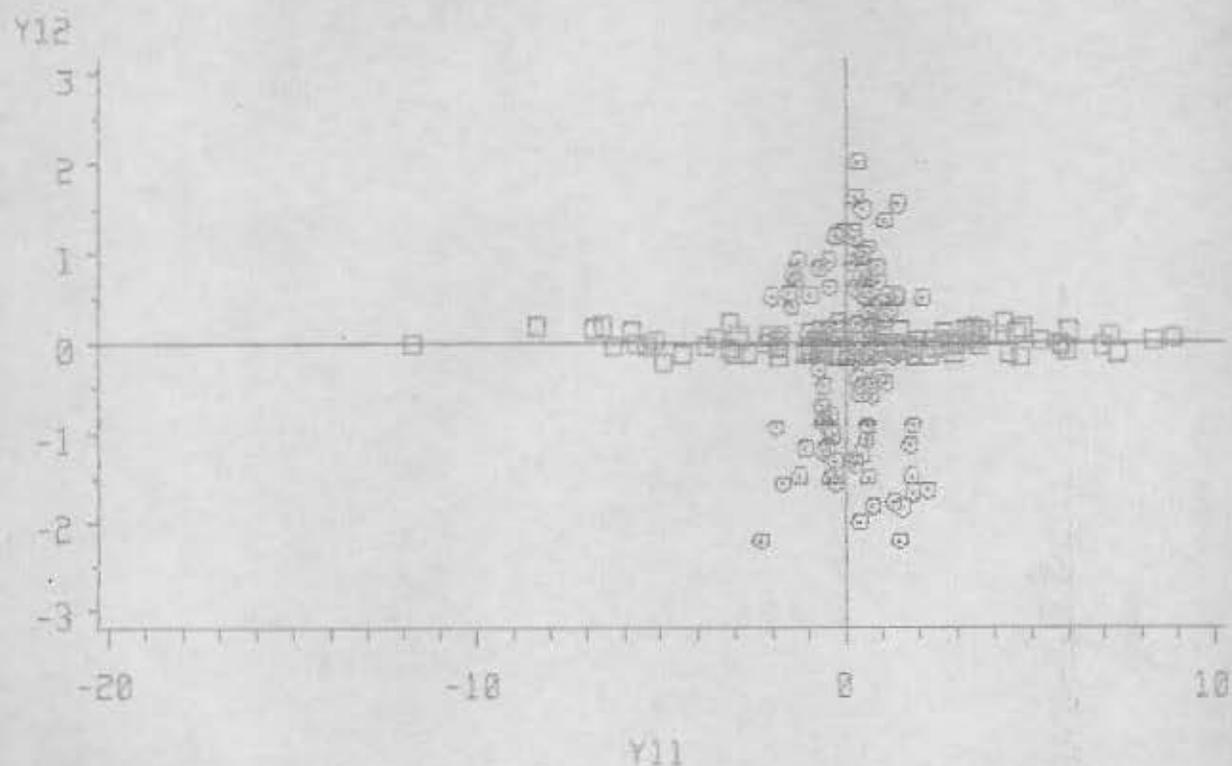
DADOS SIMULADOS TRANSFORMADOS
EXECUCAO NUMERO 13A
O NUMERO DE VAR ORIGINAIS E DOIS



CIRCULO: GRUPO UM
QUADRADO: GRUPO DOIS

GRAFICO 5

DADOS SIMULADOS TRANSFORMADOS
EXECUCAO NUMERO 09B
O NUMERO DE VAR ORIGINAIS E DOIS

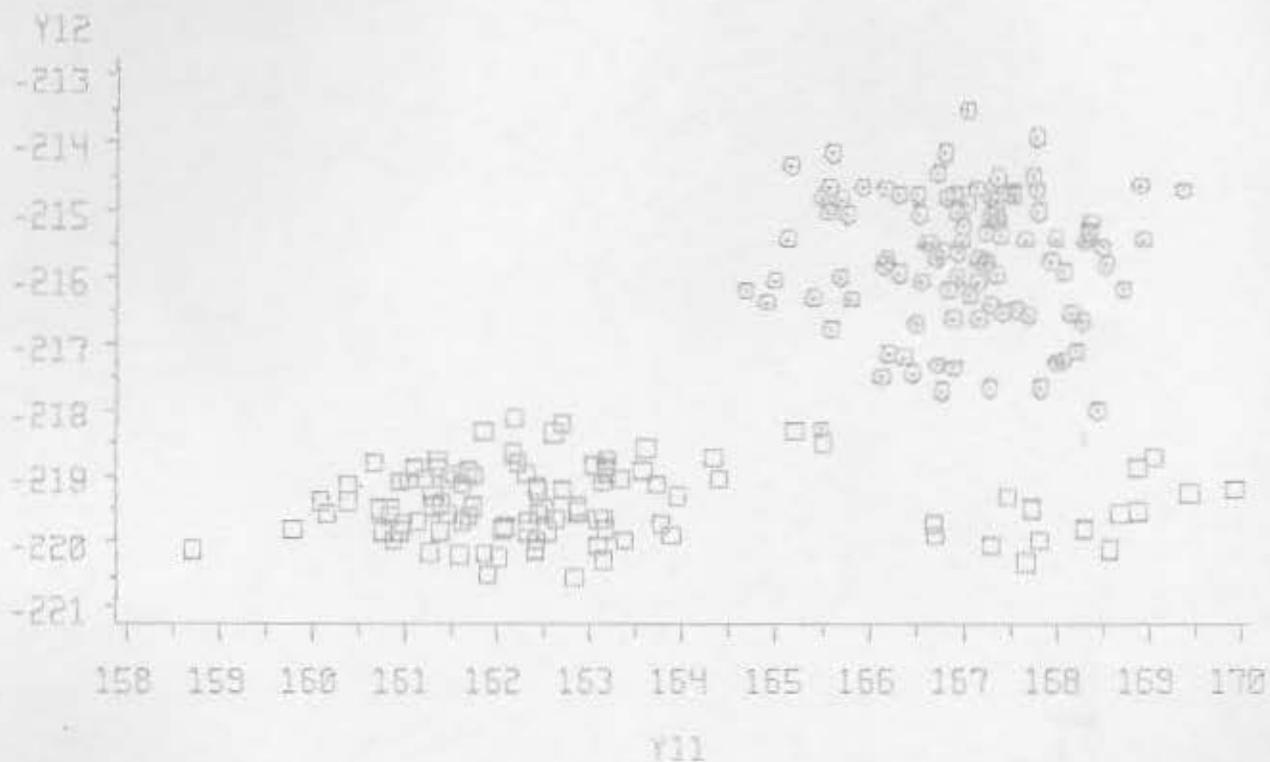


CIRCULO: GRUPO UM
QUADRADO: GRUPO DOIS

GRAFICO 6

DADOS TRANSFORMADOS DAS NOTAS DE BANCO

O NUMERO DE VARIÁVEIS ORIGINAIS E SEIS



CIRCULO: GRUPO UM
QUADRADO: GRUPO DOIS

APENDICE

```

C      PROGRAMA 1
C      -----
C
C      PROGRAMA PARA GERAR AMOSTRAS DE DUAS POPULAÇÕES
C      -----
C      NORMAIS DE DIMENSAO DOIS E FAZER DISCRIMINAÇÃO.
C      -----
C
C      GERA DUAS AMOSTRAS COM DISTRIBUICAO NORMAL BIVARIADA
C      CALCULA OS VETORES DE MEDIAS AS MATRIZES DE COVARIANCIAS
C
C      USA A SUBROTINA FORAEF DA NAG PARA OBTEN OS
C      AUTOVALORES E AUTOVECTORES DA MATRIZ INVERC(S10)*S2
C      REALIZA AS TRANSFORMACOES DAS VARIAVEIS GERADAS USANDO
C      OS AUTOVALORES E AUTOVECTORES DA MATRIZ INVERC(S10)*S2.
C
C      REALIZA OS CALCULOS PARA A FUNCAO DE DISCRIMINAGAO PROPOSTA
C
C      RECLASSIFICA COM A FUNÇÃO DE DISCRIMINAGAO PROPOSTA OS
C      ELEMENTOS AMOSTRAIS GERADOS NO INICIO DO PROGRAMA.
C
DOUBLE PRECISION R, RR, V1, V2, SOMAX, SOMAY, SOMAZ, XMED, YMED, ZMED, ZMEDA
DOUBLE PRECISION SOMAX2, SOMAY2, SOMAZ2, VARX, VARY, VARZ, VARZZ, VARXX
DOUBLE PRECISION A, B, VECP
DOUBLE PRECISION Z1, W, W1, W1T, W1SOM, W2SOM, W1M, W2M, WMED, VARYY
DOUBLE PRECISION P2, DIF, RES, DIFL, SWI1, SWI2, TL1, TQA
DOUBLE PRECISION DISC, AV, VEC, DL, E
DIMENSION XC(2,300), YC(2,300), ZC(2,300), TETA(10), L1(300)
DIMENSION RC(2,2), RRC(2,2,2), V1(10), V2(10), A1(10), A2(10)
DIMENSION SOMAX(2), SOMAY(2), SOMAZ(2), XMED(2), YMED(2), ZMED(2)
DIMENSION ZMEDA(2,2), NTAC(2), XT(300,2), YT(300,2), ZT(300,2)
DIMENSION SOMAX2(2,2), SOMAY2(2,2), SOMAZ2(2,2), ZTT(2,300,2)
DIMENSION VARX(2,2), VARY(2,2), VARZ(2,2), VARZZ(2,2,2), VARYY(2,2,2)
DIMENSION AC(2,2), BC(2,2), VARXX(2,2,2), L2(1,300)
DIMENSION VEC(2,2), AV(2), DL(2), EC(2)
DIMENSION Z1(300,2), W1(300,2), WC(2,300,2), W1T(2,300)
DIMENSION W1SOM(2), W1M(2), W2M(2), WMED(2,2)
DIMENSION SWI1(2,2), SWI2(2,2), P2(2), DIF(2,2)

```

DIMENSION TOAC(300), DIFL(2), RESE(500,20), TLIC(300)
DIMENSION DISCC(300,20), INDC(300,20), TQAC(300), VECPC(2,20)

C PARAMETROS INICIAIS DA SIMULAGAO

C

TYPE *, 'ENTRE COM O NUMERO DE POPULAG₇OES'

ACCEPT *, NP

TYPE *, 'ENTRE COM O NUMERO DE SIMULAG₇OES MONTE CARLO'

ACCEPT *, NMC

TYPE *, 'ENTRE COM DUAS SEMENTES'

ACCEPT *, S1, S2

C

C ENTRADA DO TAMANHO DE AMOSTRA E PARAMETROS DE CADA POPULAGAO

C

DO I=1, NP

TYPE *, 'ENTRE COM O TAMANHO (NTA) DA AMOSTRA DA POPULAG₇AO', I

ACCEPT *, NTACID

TYPE *, 'ENTRE COM OS PARAMETROS V1, V2 DA POPULAGAO', I

ACCEPT *, V1CID, V2CID

TYPE *, 'ENTRE COM OS PARAMETROS A1, A2 DA POPULAGAO', I

ACCEPT *, A1CID, A2CID

TYPE *, 'ENTRE COM O VALOR DE TETACRADO DA POPULAGAO', I

ACCEPT *, TETACID

END DO

C

C COMEÇANDO A SIMULAG₇AO

C

DO 1000 IMC=1, NMC

C

DO 5 I=1, 2

DO 5 J=1, 2

DO 5 K=1, 2

VARZZCI, J, K)=0.0

VARXXCI, J, K)=0.0

VARYYCI, J, K)=0.0

S

CONTINUE

C

AMOSTRANDO NTA UNIDADES DE CADA POPULAG₇AO

C

DO 500 IP=1, NP

C GERANDO OS VETORES ALEATORIOS RCO, ID

C

```
NT=NTACIPD
DO ITA=1,NT
DO I=1,2
XC(I,ITA)=0.0
YC(I,ITA)=0.0
ZC(I,ITA)=0.0
XTC(ITA,ID)=0.0
YTC(ITA,ID)=0.0
ZTC(ITA,ID)=0.0
END DO
END DO
```

C

```
DO ITA=1,NT
L1(ITA)=1
L2(1,ITA)=1
CALL RANDUC(S1,S2,U1)
CALL RANDUC(S1,S2,U2)
XC(1,ITA)=SQRT(-2.0*ALOG(U1))*COS(6.283185307*U2)
XC(2,ITA)=SQRT(-2.0*ALOG(U1))*SIN(6.283185307*U2)
```

C

C

DETERMINAGAO DO VETOR $Y=D*X+A$

C

```
YC(1,ITA)=V1C(IP)*XC(1,ITA)+A1C(IP)*L2(1,ITA)
YC(2,ITA)=V2C(IP)*XC(2,ITA)+A2C(IP)*L2(1,ITA)
END DO
```

C

C

DETERMINAGAO DO VETOR $Z=R*Y$

C

DADO QUE TEMOS DOIS GRUPOS PRECISAMOS GUARDAR EM DUAS

C

MATRIZES: ZTC(IP,ITA,ID)

```
SENO=SIN(TETAC(IP))
COSENO=COS(TETAC(IP))
R(1,1)=COSENO
R(1,2)=-1.0*SENO
R(2,1)=SENO
R(2,2)=COSENO
DO I=1,2
```

```

DO ITA=1,NT
  ZCI,ITAD=0.0
  DO K=1,2
    ZCI,ITAD=ZCI,ITAD+FCI,KD*YCK,ITAD
  END DO
  ZTCIP,ITA,ID=ZCI,ITAD
END DO
END DO
DO I=1,2
  DO ITA=1,NT
    XTCITA,ID=XCI,ITAD
    YTCITA,ID=YCI,ITAD
    ZTCITA,ID=ZCI,ITAD
  END DO
END DO
DO I=1,2
  DO J=1,2
    RRCIP,I,J)=RCI,J)
  END DO
END DO

```

C
C
C

CALCULO DOS VETORES DE MEDIAS DE X , Y , Z EM CADA GRUPO

```

DO I=1,2
  SOMAXCID=0.0
  XMEDCID=0.0
  SOMAYCID=0.0
  YMEDCID=0.0
  SOMAZCID=0.0
  ZMEDCID=0.0
  DO ITA=1,NT
    SOMAXCID=SOMAXCID+XCI,ITAD)*L1CITA)
    SOMAYCID=SOMAYCID+YCI,ITAD)*L1CITA)
    SOMAZCID=SOMAZCID+ZCI,ITAD)*L1CITA)
  END DO
  XMEDCID=SOMAXCID/(1.0*NT)
  YMEDCID=SOMAYCID/(1.0*NT)
  ZMEDCID=SOMAZCID/(1.0*NT)

```

```
ZMEDACI,IPD=ZMED,IJ
```

```
END DO
```

```
C  
C CALCULANDO AS MATRIZES DE COVARIANCIAS DAS VARIAVEIS ORIGINAIS
```

```
C  
C a) ZERANDO AS MATRIZES DE COVARIANCIAS
```

```
C  
C  
C DO I=1,2  
C DO J=1,2  
C VARXCI,JD=0.0  
C VARYCI,JD=0.0  
C VARZCI,JD=0.0  
C  
C END DO  
C  
C END DO
```

```
C  
C b) CALCULANDO AS MATRIZES DE SOMA DE QUADRADOS
```

```
C  
C  
C DO I=1,2  
C DO J=I,2  
C SOMAX2CI,JD=0.0  
C SOMAY2CI,JD=0.0  
C SOMAZ2CI,JD=0.0  
C  
C DO K=1,NT  
C SOMAX2CI,JD=SOMAX2CI,JD+XCI,K)*XTCK,JD  
C SOMAY2CI,JD=SOMAY2CI,JD+YCI,K)*YTCK,JD  
C SOMAZ2CI,JD=SOMAZ2CI,JD+ZCI,K)*ZTCK,JD  
C  
C END DO  
C SOMAX2CJ,ID=SOMAX2CI,JD  
C SOMAY2CJ,ID=SOMAY2CI,JD  
C SOMAZ2CJ,ID=SOMAZ2CI,JD  
C  
C END DO  
C  
C END DO
```

```
C c) CALCULO DAS MATRIZES DE COVARIANCIAS DOS VETORES X Y E Z
```

```
C  
C  
C DO I=1,2  
C DO J=I,2  
C VARXCI,JD=(SOMAX2CI,JD-1.0*NT*XMEDCI)*XMEDCJD)/(1.0*(NT-1))  
C VARYCI,JD=(SOMAY2CI,JD-1.0*NT*YMEDCI)*YMEDCJD)/(1.0*(NT-1))
```

```

VARZC1,JD=C(SOMAZZC1,JD-1,0)*NT*ZMEIX(1)*ZMEIX(JD)/C(1,0)*CNT(1)
VARXC1,JD=VARXC1,JD
VARYC1,JD=VARYC1,JD
VARZC1,JD=VARZC1,JD
END DO
DO J=1,2
VARXXCIP,I,JD=VARXC1,JD
VARYYCIP,I,JD=VARYC1,JD
VARZZCIP,I,JD=VARZC1,JD
END DO
END DO
C
500 CONTINUE
C
C CALCULANDO OS AUTOVALORES E AUTOVECTORES
C DA MATRIZ INV(VARZC1)*VARZC2)
C USANDO A SUBROUTINA DA NAG
C
DO 540 I=1,2
DO 540 J=1,2
BCI,JD=VARZZC1,I,JD
ACI,JD=VARZZC2,I,JD
540 CONTINUE
N=2
IA=2
IB=2
IV=2
IFAIL=1
CALL F02AEFCA,IA,B,IB,N,AV,VEC,IV,DL,E,IFAIL)
TYPE *, 'VOLTOU DA SUBROUTINA'
IF (IFAIL.EQ.0) THEN
TYPE *, ' AUTOVALORES'
TYPE *,AV(2)
TYPE *, ' '
TYPE *,AV(1)
WRITE(90,95)(AV(I),I=1,N)
TYPE 95,(AV(I),I=1,N)
WRITE(90,97)((VECCI,JD),J=1,N),I=1,N)

```

```
TYPE 97, (VECC1, J), J=1, ND, I=1, ND
95 FORMAT(2H0 EIGENVALUES:1H, 2F18.6)
97 FORMAT(13H0 EIGENVECTORS:(1H, 2(2X, F18.6)))
```

```
ELSE
```

```
TYPE 96, IFAIL
WRITE(90, 96) IFAIL
96 FORMAT(25H0 ERROR IN FO2AEF IFAIL= ,I2)
STOP
END IF
```

```
C
C CALCULANDO AS COMBINACOES LINEARES USANDO OS AUTOVETORES
C OBTEN-SE AS VARIAVEIS DE INTERESSE
```

```
C REDEFININDO A MATRIZ DE AUTOVETORES
```

```
C
C VECPC(1,1)=VECC(1,2)
C VECPC(2,1)=VECC(2,2)
C VECPC(1,2)=VECC(1,1)
C VECPC(2,2)=VECC(2,1)
```

```
C
C TYPE *, 'MATRIZ AUTOVETORES ORDENADOS'
```

```
DO I=1,2
```

```
TYPE *, (VEPC(I, J), J=1, 2)
```

```
END DO
```

```
DO 550 IP=1,2
```

```
NT=NTAC(IP)
```

```
DO 510 I=1,NT
```

```
DO 510 J=1,2
```

```
Z1(I, J)=0.0
```

```
WC(IP, I, J)=0.0
```

```
Z1(I, J)=ZTTC(IP, I, J)
```

```
W1(I, J)=0.0
```

```
510 CONTINUE
```

```
DO 511 I=1,NT
```

```
DO 511 J=1,2
```

```
DO K=1,2
```

```
W1(I, J)=W1(I, J)+Z1(I, K)*VECP(K, J)
```

```
END DO
```

```

        WCIP,I,JD=W1(I,J)
        W1TC(I,JD)=W1(I,J)
511    CONTINUE
C
C        CALCULANDO OS VETORES DE MEDIAS DAS VARIÁVEIS TRANSFORMADAS
DO 520 I=1,2
        W1SOMCID=0.0
        W1MCID=0.0
        DO ITA=1,NT
            W1SOMCID=W1SOMCID+W1TC(I,ITA)*L1(CITA)
        END DO
        W1MCID=W1SOMCID/(1.0*NT)
        WMEDX(I,IP)=W1MCID
520    CONTINUE
550    CONTINUE
C
C        CALCULANDO A FUNÇÃO DISCRIMINANTE
C
C        a) Inversa das matrizes de covariâncias das transformações
C
        DO 595 I=1,2
            DO 595 J=1,2
                SWI1(I,JD)=0.0
                SWI2(I,JD)=0.0
595    CONTINUE
                SWI1(1,1)=SWI1(1,1)+1.0
                SWI1(2,2)=SWI1(2,2)+1.0
                SWI2(1,1)=SWI2(1,1)+1.0/AV(2)
                SWI2(2,2)=SWI2(2,2)+1.0/AV(1)
            DO 596 I=1,2
                DO 596 J=1,2
                    DIF(I,JD)=0.0
                    DIF(I,JD)=DIF(I,JD)+SWI1(I,JD)-SWI2(I,JD)
596    CONTINUE
C
C        b) Calculando os termos constantes da função
C
DO I=1,2

```

```

W1MCI0=0.0
W2MCI0=0.0
W1MCI0=WMEIX1,10
W2MCI0=WMEIX1,20
END DO
XIND1=0.0
XIND2=0.0
DO I=1,2
  P2CI0=0.0
  DIFLCI0=0.0
  DO J=1,2
    P2CI0=P2CI0+SWI2CI,J)*W2MCI0
  END DO
  DIFLCI0=W1MCI0-P2CI0
  XIND1=XIND1+W1MCI0*W1MCI0
  XIND2=XIND2+W2MCI0*P2CI0
END DO
  XX=AVCI0)*AVC20

```

C

```
XINDT=XIND1-XIND2-LOGCXX)
```

C

C

c)Calculando os termos quadratico e linear

```

DO 600 IP=1,2
  NT=NTACIP0
  DO I=1,NT
    INDCI,IP0=0
    DO J=1,2
      W1CI,J0=0.0
      W1TCJ,ID=0.0
      W1CI,J0=WCIP,I,J0
      W1TCJ,J0=W1CI,J0
    END DO
  END DO
  DO I=1,NT
    DISCCI,IP0=0.0
    TQACID=0.0
    TLICID=0.0
    DO J=1,2

```

```

        RESCI,JD=0.0
        DO K=1,2
            RESCI,JD=RESCI,JD+W1CI,K)*DIFCK,JD
        END DO
    END DO
END DO
DO I=1,NT
    DO J=1,2
        TQACID=TQACID+RESCI,JD)*W1TCJ,ID
    END DO
END DO
DO I=1,NT
    DO J=1,2
        TLI CID=TLI CID+W1CI,JD)*DIFLCJD
    END DO
END DO
C
C      d)Obtencao da fungao de discriminacao
C      usando os resultados anteriores
DO I=1,NT
    DISCCI,IPD=TQACID-2*TLI CID+X1INDT
    IF(DISCCI,IPD.LE.0) THEN
        INDCI,IPD=1
    ELSE
        INDCI,IPD=2
    END IF
END DO
600  CONTINUE
1000 CONTINUE
STOP
END

```

```

C      PROGRAMA 2
C      PROGRAMA PARA GERAR AMOSTRAS DE DOIS POPULAÇÕES NORMAIS
C      -----
C      DE DIMENSÃO TRES E FAZER DISCRIMINAÇÃO
C      -----
C      GERA DUAS AMOSTRAS DE DIMENSÃO TRES.
C
C      CALCULA OS VETORES DE MEDIAS E AS MATRIZES DE COVARIANCIAS
C      PARA AS AMOSTRAS GERADAS.
C      USA A SUBROTINA FO2AEF DA BIBLIOTECA DA NAG PARA OBTER OS
C
C      AUTOVALORES E AUTOVETORES DA MATRIZ INV(S1)*S2
C
C      REALIZA OS CALCULOS CONDUCENTES A OBTENCAO DA FUNCAO
C      DISCRIMINANTE.
C
C      RECLASSIFICA AS OBSERVACOES AMOSTRAIS SEGUNDO A PROPOSTA DE
C      DISCRIMINACAO.
C

```

```

DOUBLE PRECISION RR,RRR,SOMAX,SOMAY,SOMAZ,XMED,YMED,ZMED,ZMEDA
DOUBLE PRECISION SOMAX2,SOMAY2,SOMAZ2,VARX,VARY,VARZ,VARZZ
DOUBLE PRECISION A,B,SI,R,V,DL,AUTOVE
DOUBLE PRECISION Z1,W,W1,W1T,W1SOM,W2SOM,W1M,W2M,WMED
DOUBLE PRECISION P2,DIFF,RES,DIFFL,SW11,SW12,TLI,TQA
DOUBLE PRECISION DISC
DIMENSION XC(3,300),YC(3,300),ZC(3,300),TETAC(10),L1(300)
dimension L2(1,300),A1(10),A2(10),A3(10)
DIMENSION RRC(3,3),RRRC(2,3,3),V1(10),V2(10),V3(10)
DIMENSION SOMAX(3),SOMAY(3),SOMAZ(3),XMED(3),YMED(3),ZMED(3)
DIMENSION ZMEDAC(3,2),NTAC(2),XTC(300,3),YTC(300,3),ZTC(300,3)
DIMENSION SOMAX2(3,3),SOMAY2(3,3),SOMAZ2(3,3),ZTTC(2,300,3)
DIMENSION VARX(3,3),VARY(3,3),VARZ(3,3),VARZZ(2,3,3)
DIMENSION AC(3,3),BC(3,3),RC(3),VC(3,3),AUTOVE(3,2)
DIMENSION Z1(300,3),W1(300,2),WC(2,300,2),W1TC(2,300)
DIMENSION W1SOM(2),W1M(2),W2M(2),WMED(2,2),P2(2)
DIMENSION SW11(2,2),SW12(2,2),DIFFC(2,2),RESC(300,2)
DIMENSION TQAC(300),DIFFL(2),TLI(300)
DIMENSION DISCC(300,2),INDICAC(300,2)

```

C

C ENTRADA DE PARAMETROS INICIAIS

C

TYPE *, 'ENTRE COM O NUMERO DE POPULAÇÕES'

ACCEPT *, NP

TYPE *, 'ENTRE COM O NUMERO DE SIMULAÇÕES MONTE CARLO'

ACCEPT *, NMC

TYPE *, 'ENTRE COM DUAS SEMENTES'

ACCEPT *, S1, S2

C

C ENTRADA DO TAMANHO DE AMOSTRA E PARAMETROS DE CADA POPULAÇÃO

DO I=1, NP

TYPE *, 'ENTRE COM O TAMANHO (NTA) DA AMOSTRA DA POPULAÇÃO', I

ACCEPT *, NTACID

TYPE *, 'ENTRE COM OS PARAMETROS V1, V2, V3 DA POPULAÇÃO', I

ACCEPT *, V1CID, V2CID, V3CID

TYPE *, 'ENTRE COM OS PARAMETROS A1, A2, A3 DA POPULAÇÃO', I

ACCEPT *, A1CID, A2CID, A3CID

TYPE *, 'ENTRE COM O VALOR DE TETACRADO DA POPULAÇÃO', I

ACCEPT *, TETACID

END DO

C

C COMEÇANDO A SIMULAÇÃO

C

DO 1000 IMC=1, NMC

C

DO 5 I=1, 2

DO 5 J=1, 3

DO 5 K=1, 3

VARZZ(I, J, K)=0.0

S

CONTINUE

C

AMOSTRANDO NTA UNIDADES DE CADA POPULAÇÃO

DO 500 IP=1, NP

NT=NTACIP

C

C

GERANDO OS VETORES ALEATORIOS N(O, I)

DO ITA=1, NT

DO I=1, 3

XCI, ITA)=0.0

```
YC1,1TA)=0.0
ZC1,1TA)=0.0
XTCITA,1D)=0.0
YTCITA,1D)=0.0
ZTCITA,1D)=0.0
END DO
```

```
END DO
```

```
DO ITA=1,NT
```

```
  L1CITA)=1
```

```
  L2C1,1TA)=1
```

```
  CALL RANDUC(S1,S2,U1)
```

```
  CALL RANDUC(S1,S2,U2)
```

```
  CALL RANDUC(S1,S2,U3)
```

```
  CALL RANDUC(S1,S2,U4)
```

```
XC1,1TA)=SQRT(-2.0*ALOG(U1)))*COS(6.283185307*U2)
```

```
XC2,1TA)=SQRT(-2.0*ALOG(U1)))*SIN(6.283185307*U2)
```

```
XC3,1TA)=SQRT(-2.0*ALOG(U3)))*COS(6.283185307*U4)
```

```
C
```

```
C
```

```
DETERMINACAO DO VETOR Y=D*X
```

```
C
```

```
  YC1,1TA)=V1CIPD)*XC1,1TA)+A1CIPD)*L2C1,1TA)
```

```
  YC2,1TA)=V2CIPD)*XC2,1TA)+A2CIPD)*L2C1,1TA)
```

```
  YC3,1TA)=V3CIPD)*XC3,1TA)+A3CIPD)*L2C1,1TA)
```

```
END DO
```

```
C
```

```
C
```

```
DETERMINACAO DO VETOR Z=R*Y
```

```
C
```

```
  SENO=SIN(TETACIPD)
```

```
  COSENO=COS(TETACIPD)
```

```
  RRC1,1D)=COSENO
```

```
  RRC1,2D)=-1*SENO
```

```
  RRC1,3D)=0.0
```

```
  RRC2,1D)=SENO
```

```
  RRC2,2D)=COSENO
```

```
  RRC2,3D)=0.0
```

```
  RRC3,1D)=0.0
```

```
  RRC3,2D)=0.0
```

```
  RRC3,3D)=1.0
```

```

DO I=1,3
  DO ITA=1,NT
    ZC1,ITA)=0.0
    DO K=1,3
      ZC1,ITA)=ZC1,ITA)+RRC1,K)*YCK,ITA)
    END DO
    ZTTC1P,ITA,ID)=ZC1,ITA)
  END DO
END DO
DO I=1,3
  DO J=1,3
    RRC1P,I,JD)=RRC1,JD)
  END DO
END DO
DO ITA=1,NT
  DO I=1,3
    XTCITA,ID)=XCI,ITA)
    YTCITA,ID)=YCI,ITA)
    ZTCITA,ID)=ZCI,ITA)
  END DO
END DO

```

C
C
C
C

CALCULO DOS VETORES DE MEDIAS DE X , Y , Z PARA CADA AMOSTRA

```

DO I=1,3
  SOMAXCID)=0.0
  XMEDCID)=0.0
  SOMAYCID)=0.0
  YMEDCID)=0.0
  SOMAZCID)=0.0
  ZMEDCID)=0.0
DO ITA=1,NT
  SOMAXCID)=SOMAXCID)+XCI,ITA)*L1CITA)
  SOMAYCID)=SOMAYCID)+YCI,ITA)*L1CITA)
  SOMAZCID)=SOMAZCID)+ZCI,ITA)*L1CITA)
END DO
XMEDCID)=SOMAXCID)/(1.0)*NT)

```

```
YMED(I) = SOMAY(I) / (C1.0 * NT)
ZMED(I) = SOMAZ(I) / (C1.0 * NT)
ZMEDACI(I) = ZMED(I)
```

```
END DO
```

```
C
```

```
C CALCULANDO AS MATRIZES DE COVARIANCIAS PARA AS AMOSTRAS
```

```
C
```

```
C a) ZERANDO AS MATRIZES DE COVARIANCIAS
```

```
C
```

```
DO I=1,3
```

```
DO J=1,3
```

```
VARXCI,J) = 0.0
```

```
VARYCI,J) = 0.0
```

```
VARZCI,J) = 0.0
```

```
END DO
```

```
END DO
```

```
C
```

```
C b) CALCULANDO AS MATRIZES DE SOMA DE QUADRADOS
```

```
C
```

```
DO I=1,3
```

```
DO J=1,3
```

```
SOMAX2CI,J) = 0.0
```

```
SOMAY2CI,J) = 0.0
```

```
SOMAZ2CI,J) = 0.0
```

```
END DO
```

```
END DO
```

```
DO I=1,3
```

```
DO J=I,3
```

```
DO K=1,NT
```

```
SOMAX2CI,J) = SOMAX2CI,J) + XCI,K) * XTCK,J)
```

```
SOMAY2CI,J) = SOMAY2CI,J) + YCI,K) * YTCK,J)
```

```
SOMAZ2CI,J) = SOMAZ2CI,J) + ZCI,K) * ZTCK,J)
```

```
END DO
```

```
SOMAX2C(J,I) = SOMAX2CI,J)
```

```
SOMAY2C(J,I) = SOMAY2CI,J)
```

```
SOMAZ2C(J,I) = SOMAZ2CI,J)
```

```
END DO
```

```
END DO
```

```

C          C) CALCULO DAS MATRIZES DE COVARIANCIAS
C
      DO I=1,3
        DO J=1,3
          VARXC1,J)=(SOMAXZC1,J)-1.0*NT*XMECX1)*XMECXJ)/(1.0*NT-1)
          VARYC1,J)=(SOMAYZC1,J)-1.0*NT*YMECX1)*YMECXJ)/(1.0*NT-1)
          VARZC1,J)=(SOMAZZC1,J)-1.0*NT*ZMECX1)*ZMECXJ)/(1.0*NT-1)
          VARXCJ,I)=VARXC1,J)
          VARYCJ,I)=VARYC1,J)
          VARZCJ,I)=VARZC1,J)
        END DO
      DO J=1,3
        VARZZCIP,1,J)=VARZC1,J)
      END DO
    END DO
500  CONTINUE
C
C          REDEFININDO AS MATRIZES DE COVARIANCIAS DAS DUAS POPULAÇÕES
C
      DO 550 I=1,3
        DO 550 J=1,3
          BCI,J)=VARZZC1,I,J)
          ACI,J)=VARZZC2,I,J)
550  CONTINUE
C
C          CALCULANDO OS AUTOVALORES E AUTOVETORES DA MATRIZ INV(B)*A
C          USANDO A SUBROUTINA DA NAG
C
      N=3
      TYPE *, 'BCI, J)'
      DO I=1, N
        TYPE *, (BCI, J), J=1, N)
      END DO
      TYPE *, 'ACI, J)'
      DO I=1, N
        TYPE *, (ACI, J), J=1, N)
      END DO
      IA=3

```

```

IB=3
IV=3
IFAIL=1
CALL FO2AEFCA,IA,B,IB,N,E,V,IV,DL,E,IFAILD
TYPE *, 'VOLTOU DA SUBROTINA'
IFC(FAIL.EQ.0) THEN
WRITEC(80,95)C(RC(I),I=1,N)
TYPE 95,C(RC(I),I=1,N)
WRITEC(80,97)C(CVCI,J),J=1,N,I=1,N)
TYPE 97,C(CVCI,J),J=1,N,I=1,N)
95 FORMAT(12H0 EIGENVALUES/1H,3F18.6)
97 FORMAT(13H0 EIGENVECTORS/1H,3C2X,F15.6)
ELSE
TYPE 96,IFAIL
WRITEC(80,96)IFAIL
96 FORMAT(25H0 ERROR IN FO2AEF IFAIL= ,I2)
STOP
END IF
XX=RC(3)*RC(1)
DO I=1,3
AUTOVECI,1)=VC(I,3)
AUTOVECI,2)=VC(I,1)
END DO
C
TYPE *, 'MATRIZ ORDENADA DE AUTOVETORES'
DO I=1,3
TYPE *,(AUTOVECI,J),J=1,2)
END DO
C
C CALCULANDO AS COMBINACOES LINEARES USANDO OS AUTOVETORES
C OBTEN-SE AS VARIAVEIS DE INTERESSE
C
DO 200 IP=1,2
NT=NTAC(IP)
DO 110 I=1,NT
DO J=1,3
Z1(I,J)=0.0
Z1(I,J)=ZTT(IP,I,J)

```

```

      END DO
DO 110 J=1,2
  WCIP,I,JD)=0.0
  W1CI,JD)=0.0
  DO K=1,3
    W1CI,JD)=W1CI,JD)+Z1CI,K)*AUTOVECK,JD)
  END DO
  WCIP,I,JD)=W1CI,JD)
  W1TCJ,JD)=W1CI,JD)
110  CONTINUE
DO 120 I=1,2
  W1SOMCID)=0.0
  W1MCID)=0.0
  DO ITA=1,NT
    W1SOMCID)=W1SOMCID)+W1TCI,ITA)*L1CITAD)
  END DO
  W1MCID)=W1SOMCID)/(1.0*NT)
  WMEXI,IPD)=W1MCID)
120  CONTINUE
200  CONTINUE
TYPE 210
210  FORMAT(/,10X,'OS VETORES DE MEDIAS TRANSFORMADOS SAO: ',/ )
DO I=1,2
TYPE *,(WMEXI,IPD),IP=1,2)
END DO

C
C  OBTENCAO DA FUNCAO DISCRIMINANTE
C
C  a) Inversa das matrizes de covariâncias das combinações
C  segundo o objetivo proposto.
C
do 595 I=1,2
do 595 J=1,2
  swi1(i,j)=0
  swi2(i,j)=0
595  continue
SWI1(1,1)=swi1(1,1)+1.0
SWI1(2,2)=swi1(2,2)+1.0

```

```

      SWI1C1,1D=swi2C1,1D+1.0/PC1D
      SWI2C2,2D=swi2C2,2D+1.0/PC1D
DO 220 I=1,2
      DO 220 J=1,2
          difqC1,jD=0.0
          DIFQ1,J=diffqC1,jD+SWI1C1,JJ-SWI2C1,JJ
220    CONTINUE
C
C      b)Calculando os termos constantes da função
C
DO  I=1,2
      W1MCI0=0.0
      W2MCI0=0.0
      W1MCI0=WMEIX1,IJ
      W2MCI0=WMEIX1,2J
END DO
      XIIND1=0.0
      XIIND2=0.0
DO  I=1,2
      P2C1D=0.0
      DIFLC1D=0.0
      DO  J=1,2
          P2C1D=P2C1D+SWI2C1,JJ*W2MCI0
      END DO
      DIFLC1D=W1MCI0-P2C1D
      XIIND1=XIIND1+W1MCI0*W1MCI0
      XIIND2=XIIND2+W2MCI0*P2C1D
END DO
C      Termo independente total
C
      XIINDT=XIIND1-XIIND2-ALOGCXXD
C
      TYPE *, 'TERMOS INDEPENDENTES'
      TYPE *, XIINDT, XIIND1, XIIND2, ALOGCXXD
C      c)Calculando os termos quadraticos e linear
DO 300 IP=1,2
      NT=NTACIPD
      DO  I=1,NT

```

```

INDICACI,IPD=0
DO J=1,2
  W1CI,JD=0.0
  W1TCJ,JD=0.0
  W1CI,JD=W1CIP,T,JD
  W1TCJ,JD=W1TCJ,JD
END DO
END DO
DO I=1,NI
  DISCCI,IPD=0.0
  TQACID=0.0
  TLICID=0.0
  DO J=1,2
    RESCI,JD=0.0
    DO K=1,2
      RESCI,JD=RESCI,JD+W1CI,KD*DIFOCK,JD
    END DO
  END DO
  DO J=1,2
    TLICID=TLICID+W1CI,JD*DIFLCJD
    TQACID=TQACID+RESCI,JD*W1TCJ,JD
  END DO
END DO
C      d)Calculando a funcao discriminante com os resultados
C      anteriores
DO I=1,NI
  DISCCI,IPD=TQACID-2*TLICID+XIINDT
  IF(DISCCI,IPD).LE.0) THEN
    INDICACI,IPD=1
  ELSE
    INDICACI,IPD=2
  END IF
END DO
300  CONTINUE
1000 CONTINUE
800  CONTINUE
STOP
END

```

PROGRAMA N^o 3

DISCRIMINAÇÃO COM O PROC DISCRIM (SAS)

```
OPTIONS LS=80;
TITLE 'ANALISE DISCRIMINANTE';
DATA SIMUL;
TITLE2 'DADOS SIMULADOS EM DUAS VARIÁVEIS';
INFILE SIM001A.DAT;
INPUT X1 5-15 X2 20-30 ESPEC 47 ;
IF ESPEC=1 THEN TIPO='PRIMEIRA POPULAÇÃO';
      ELSE TIPO='SEGUNDA POPULAÇÃO';
LABEL X1='PRIMEIRA VARIÁVEL NORMAL';
      X2='SEGUNDA VARIÁVEL NORMAL';
      ESPEC ='POPULAÇÃO DE PROCEDENÇA';
PROC PRINT;
PROC DISCRIM SIMPLE LISTERR POOL=TEST;
CLASS TIPO;
VAR X1-X2;
```

PROGRAMA N.º 4

DISCRIMINAÇÃO COM O PROC DISCRIM (SAS)

```
OPTIONS LS=80;
TITLE 'ANALISE DISCRIMINANTE';
DATA SIMUL;
TITLE2 'DADOS SIMULADOS EM TRES VARIÁVEIS';
INFILE SIM001B.DAT;
INPUT X1 5-15 X2 20-30 X3 32-45 ESPEC 60;
IF ESPEC=1 THEN TIPO='PRIMEIRA POPULAÇÃO';
      ELSE TIPO='SEGUNDA POPULAÇÃO';
LABEL X1='PRIMEIRA VARIÁVEL NORMAL';
      X2='SEGUNDA VARIÁVEL NORMAL';
      X3='TERCEIRA VARIÁVEL NORMAL';
      ESPEC = 'POPULAÇÃO DE PROCEDENÇA';
PROC PRINT;
PROC DISCRIM SIMPLE LISTERR POOL=TEST;
CLASS TIPO;
VAR X1-X3;
```

```

C   PROGRAMA  S
C   -----
C
C
C   PROGRAMA PARA CALCULAR OS VETORES DE MEDIAS, MATRIZES DE
C   -----
C
C   COVARIANCIAS DOS DADOS CONSIDERADOS NA APLICACÃO.
C   -----
C
C   ARQUIVO FOR010.DAT CONTEM AS MEDICOES DAS NOTAS VEERDADEIRAS.
C
C   ARQUIVO FOR050.DAT CONTEM AS MEDICOES DAS NOTAS FALSAS.
C
C   CALCULA OS AUTOVALORES E AUTOVETORES DA MATRIZ INV(S1)*S2.
C
C   REALIZA TRANSFORMACOES COM OS AUTOVETORES ASSOCIADOS AOS
C   AUTOVALORES MAXIMO E MINIMO DA MATRIZ INV(S1)*S2.
C
C   APRESENTA-SE A FUNCAO DE DISCRIMINACAO SEGUNDO A PROPOSTA.
C
C   RECLASSIFICA AS OBSERVACOES AMOSTRAIS AVALIANDOAS NA
C   FUNCAO PROPOSTA
C
double precision somax1,somax2,somay1,somay2
double precision x1med,x2med,y1med,y2med,somaqx1,somaqx2
double precision varx1,varx2,a,b,r,v,autove
double precision swi1,swi2,difq,l1,quay1,quadry1
double precision quay2,quadry2,s1,s2,difl,vliny1,vliny2
dimension x1(100,6),x1t(6,100),x2(100,6),x2t(6,100)
dimension somax1(6),somax2(6),x1med(6),x2med(6),l1(100)
dimension Y1(100,2),Y2(100,2),Y1T(2,100),Y2T(2,100)
dimension somay1(2),somay2(2),y1med(2),y2med(2)
dimension somaqx1(6,6),somaqx2(6,6)
dimension varx1(6,6),varx2(6,6),A(7,7),B(7,7),R(7),DL(6)
dimension V(7,7),autove(6,2)
dimension swi1(2,2),swi2(2,2),difq(2,2)
dimension s1(2),s2(2),difl(2),vliny1(100),vliny2(100)

```

```
dimension quadrx1(100),quadrx2(100),quay1(100,20),quay2(100,20)
dimension indica1(100),indica2(100)
dimension discrim1(100),discrim2(100)
```

C

C LENDO OS ARQUIVOS DE DADOS

C

```
do I=1,100
  read(10,*) (X1(I,J),J=1,6)
```

end do

```
do I=1,100
  read(50,*) (X2(I,J),J=1,6)
```

end do

C

C Calculando a matriz transposta yt,wt

C

```
do I=1,100
  L1(I)=1
  do J=1,6
    X1t(J,I)=X1(I,J)
    X2t(J,I)=X2(I,J)
```

end do

end do

C

C

C CALCULANDO OS VETORES DE MEDIAS

C

```
DO I=1,6
  SOMAX1(I)=0
  X1MED(I)=0
  SOMAX2(I)=0
  X2MED(I)=0
end do
  do I=1,6
    DO J=1,100
      SOMAX1(I)=SOMAX1(I)+X1T(I,J)*L1(J)
      SOMAX2(I)=SOMAX2(I)+X2T(I,J)*L1(J)
    END DO
    X1MED(I)=SOMAX1(I)/(1.0*100)
    X2MED(I)=SOMAX2(I)/(1.0*100)
  END DO
```

C
C
C CALCULANDO AS MATRIZES DE COVARIANCIAS

C
C a) Zerando as matrizes de covariâncias.

C
C
C do i=1,6
C do j=1,6
C varx1(i,j)=0.0
C varx2(i,j)=0.0
C end do
C end do

C
C b) Calculando a matriz soma de quadrados

C
C
C DO I=1,6
C DO J=1,6
C SOMAQX1(I,J)=0.0
C SOMAQX2(I,J)=0.0
C end do
C end do
C do l=1,6
C do j=l,6
C DO K=1,100
C SOMAQX1(I,J)=SOMAQX1(I,J)+X1t(I,K)*X1(K,J)
C SOMAQX2(I,J)=SOMAQX2(I,J)+X2t(I,K)*X2(K,J)
C END DO
C SOMAQX1(J,I)=SOMAQX1(I,J)
C SOMAQX2(J,I)=SOMAQX2(I,J)
C END DO
C END DO

C
C c) CALCULANDO AS MATRIZES DE COVARIANCIAS

C
C
C DO I=1,6
C DO J=1,6
C VARX1(I,J)=(SOMAQX1(I,J)-1.0*100*X1MED(I)*X1MED(J))/(1.0*99.0)
C VARX2(I,J)=(SOMAQX2(I,J)-1.0*100*X2MED(I)*X2MED(J))/(1.0*99.0)
C VARX1(J,I)=VARX1(I,J)
C VARX2(J,I)=VARX2(I,J)
C END DO

END DO

C
C DEFININDO AS MATRIZES DE COVARIANCIAS DAS DUAS POPULACOES
C PARA USAR A SUBROUTINA FOZAEF DA NAG
C

```
DO 550 I=1,6  
  DO 550 J=1,6  
    ACI,JD=VARX2CI,JD  
    BCI,JD=VARX1CI,JD
```

550 CONTINUE

C
C CALCULANDO OS AUTOVALORES E AUTOVETORES DA MATRIZ
C INVCVARX1D*VARX2 USANDO A SUBROUTINA DA NAG
C

N=6

TYPE *, 'BCI, JD'

DO I=1,N

TYPE *,(BCI,JD),J=1,ND

END DO

TYPE *, 'ACI, JD'

DO I=1,N

TYPE *,(ACI,JD),J=1,ND

END DO

TYPE *, 'LEU OS DADOS'

IA=7

IB=7

IV=7

IFAIL=1

CALL FOZAEFCA,IA,B,IB,N,R,V,IV,DL,E,IFAILD

TYPE *, 'VOLTOU DA SUBROUTINA'

IF(IFAIL.EQ.0) THEN

WRITE(33,95)(RCID),I=1,ND

TYPE 95,(RCID),I=1,ND

WRITE(33,97)((VC(I,JD),J=1,ND),I=1,ND

TYPE 97,((VC(I,JD),J=1,ND),I=1,ND

95 FORMAT(12H0 EIGENVALUES/1H,6F18.6)

97 FORMAT(13H0 EIGENVECTORS/(1H,6(2X,F15.6)))

ELSE

TYPE 96,IFAIL

WRITE(88,960)FALL

96 FORMAT(25H0 ERROR IN FORMAE' LEAVE' , I2)

STOP

END IF

XX=RC6D*RC1D

DO I=1,6

AUTOVECI,1D=VCI,6D

AUTOVECI,2D=VCI,1D

END DO

C

C

C

C CALCULANDO AS COMBINAGOES LINEARES OBTEM-SE AS

C VARIAVEIS DE INTERESE USANDO OS AUTOVETORES

C MAXIMO E MINIMO

C

C

DO I=1,100

DO J=1,2

Y1CI,JD=0.0

Y2CI,JD=0.0

END DO

END DO

C

DO I=1,100

DO J=1,2

DO K=1,6

Y1CI,JD=Y1CI,JD+X1CI,KD*AUTOVECK,JD

Y2CI,JD=Y2CI,JD+X2CI,KD*AUTOVECK,JD

END DO

END DO

END DO

C

C Calculando as matrizes transpostas das variaveis transformadas

C

do I=1,100

do J=1,2

Y1TCJ,1D=Y1CI,JD

Y2TCJ,1D=Y2CI,JD

END DO

END DO

C

C

C Calculando o vetor de medias das variaveis
C transformadas(Y)

C

do I=1,2

somay1(I)=0.0

y1med(I)=0.0

somay2(I)=0.0

y2med(I)=0.0

do J=1,100

somay1(I)=somay1(I)+Y1T(I,J)*L1(I,J)

SOMAY2(I)=SOMAY2(I)+Y2T(I,J)*L1(I,J)

end do

y1med(I)=somay1(I)/(1.0*100)

y2med(I)=somay2(I)/(1.0*100)

end do

C

C

C

C Inversa das matrizes de covariancias das combinaçoes
C segundo o nosso objetivo

C

do 595 I=1,2

do 595 j=1,2

swi1(i,j)=0.0

swi2(i,j)=0.0

595 continue

swi1(1,1)=swi1(1,1)+1.0

swi1(2,2)=swi2(2,2)+1.0

swi2(1,1)=swi2(1,1)+1.0/R(6)

swi2(2,2)=swi2(2,2)+1.0/R(1)

C

do 220 I=1,2

do 220 j=1,2

difq(i,j)=0.0

difq(i,j)=difq(i,j)+swi1(i,j)-swi2(i,j)

220

continue

C

```
C
C CALCULANDO A FUNCAO DISCRIMINANTE
```

```
C a) Calculando o Termo quadratico em y
```

```
C
do I=1,100
  do J=1,2
    quay1(I,J)=0.0
    quay2(I,J)=0.0
    do K=1,2
      quay1(I,J)=quay1(I,J)+y1(I,K)*difq(K,J)
      quay2(I,J)=quay2(I,J)+y2(I,K)*difq(K,J)
    end do
  end do
end do
do i=1,100
  quadry1(i)=0.0
  quadry2(i)=0.0
  do j=1,2
    quadry1(i)=quadry1(i)+quay1(i,j)*y1t(j,i)
    quadry2(i)=quadry2(i)+quay2(i,j)*y2t(j,i)
  end do
end do
```

```
c b)Calculando o Termo Linear em y da Funcao Discriminante
```

```
c
do I=1,2
  s1(i)=0.0
  s2(i)=0.0
  dif1(i)=0.0
  do J=1,2
    s1(i)=s1(i)+swi1(I,J)*y1med(J)
    s2(i)=s2(i)+swi2(I,J)*y2med(J)
  end do
  dif1(i)=dif1(i)+s1(i)-s2(i)
end do
type *,'Calculou o vetor diferenca'
do I=1,2
  type *,dif1(i)
```

```

c
c
c      Calculando o produto 2*y*diferencia
c
c      do I=1,100
c          vliny1(I)=0.0
c          vliny2(I)=0.0
c          do J=1,2
c              vliny1(I)=vliny1(I)+2*y1(I,J)*dif1(J)
c              vliny2(I)=vliny2(I)+2*y2(I,J)*dif1(J)
c          end do
c      end do
c
c
c      e) Calculando o Termo Independente da fun. Discriminante
c
c      ind1=0.0
c      ind2=0.0
c      indt=0.0
c          ind1=ind1+y1med(1)*s1(1)+y1med(2)*s1(2)
c          ind2=ind2+y2med(1)*s2(1)+y2med(2)*s2(2)
c      indt=ind1-ind2-log(XX)
c      type *, 'TERMO INDEPENDENTE'
c      type *, indt, ind1, ind2, log(XX)
c
c
c      f) Calculando a Funcao Discriminante e reclassificando os
c      Elementos das amostras
c
c      do I=1,100
c          discrim1(I)=0.0
c          discrim2(I)=0.0
c          discrim1(I)=discrim1(I)+quadry1(I)-vliny1(I)+indt
c          discrim2(I)=discrim2(I)+quadry2(I)-vliny2(I)+indt
c          if(discrim1(I).le.0) then
c              indica1(I)=1
c          else
c              indica1(I)=2
c          end if
c          if(discrim2(I).le.0) then
c              indica2(I)=1
c          else
c              indica2(I)=2

```

```

        end if
    end do

c
C
C   IMPRIMINDO E GERANDO OS RESULTADOS
C
    type 10
    write(33,10)
10   format(/,15x,'matriz de covariancias da amostra um')
        do I=1,6
            type 15,(varx1(i,j),j=1,6)
            write(33,15)(varx1(i,j),j=1,6)
15   format(/,15x,6(f10.6,3x))
        end do
            type 20
            write(33,20)
20   format(/,15x,'matriz de covariancias da amostra dois')
        do I=1,6
            type 25,(varx2(i,j),j=1,6)
            write(33,25)(varx2(i,j),j=1,6)
25   format(/,15x,6(f10.6,3x))
        end do
            type 31
            write(33,31)
31   format(/,15x,'matriz dados transformados das amostras um e dois')
        do I=1,100
            type 35,(y1(i,j),j=1,2),(y2(i,j),j=1,2)
            write(34,35)(y1(i,j),j=1,2),(y2(i,j),j=1,2)
35   format(/,10x,100(f15.6,2x))
        end do
            type 30
            write(33,30)
30   format(/,15x,'vetores de medias das variaveis transformadas')
        do I=1,2
            type 32,y1med(I),y2med(I)
            write(33,32)y1med(I),y2med(I)
32   format(/,2(3X,f15.6))
        end do
stop
end

```

PROGRAMA N^o 6

DISCRIMINAÇÃO COM O PROC DISCRIM (SAS)
NOTAS DE BANCO VERDADEIRAS E FALSAS

```
OPTIONS LS=80;
TITLE 'ANALISE DISCRIMINANTE';
DATA SIMUL;
TITLE2 'MEDIDAS DAS NOTAS DE BANCO';
INFILE FLURY.DAT;
INPUT X1 X2 X3 X4 X5 X6 ESPEC 41 OBS 42-44;
IF ESPEC=1 THEN TIPO='PRIMEIRA POPULAÇÃO';
           ELTE TIPO='SEGUNDA POPULAÇÃO';
LABEL X1='COMPRIMENTO DAS NOTAS';
      X2='LARGURA DO LADO ESQUERDO';
      X3='LARGURA DO LADO DEREITO';
      X4='LARGURA DA MARGEM INFERIOR';
      X5='LARGURA DA MARGEM SUPERIOR';
      X6='COMP. DA DIAG. MED DESDE O CIE ATE CID';
      ESPEC = 'POPULAÇÃO DE PROCEDENÇA';
      OBS = 'NUMERO DE OBSERVAÇÃO';
PROC PRINT;
  PROC DISCRIM SIMPLE LISTERR POOL=TEST;
CLASS TIPO;
VAR X1-X6;
```

QUADRO A1

OBTENÇÃO DE AUTOVALORES E RAZÃO DE EPPO APARENTE PARA DIFERENTES
PARAMETROS DE ENTRADA.

DIF ENT ANG	PARAMETROS DE ENTRADA						RESULTADOS AMOSTRAIS				
	POP. UM			POP. DOIS			REA	n _{1m}	n _{2m}	AUTOVALORES	
	v ₁	v ₂	θ	v ₁	v ₂	θ				MÁX	MIN
15	3	0.5	0	0.5	3	15	0.090	7	11	37.680	0.038
15	3	0.5	15	0.5	3	30	0.090	7	11	37.680	0.038
15	3	0.5	45	0.5	3	60	0.090	7	11	37.680	0.038
15	3	0.5	90	0.5	3	105	0.090	7	11	37.680	0.038
15	3	0.5	180	0.5	3	195	0.090	7	11	37.680	0.038
45	3	0.5	0	0.5	3	45	0.135	11	16	22.060	0.066
45	3	0.5	45	0.5	3	90	0.135	11	16	22.060	0.066
45	3	0.5	90	0.5	3	135	0.135	11	16	22.060	0.066
60	3	0.5	60	0.5	3	120	0.185	14	23	12.564	0.115
60	3	0.5	120	0.5	3	180	0.185	14	23	12.564	0.115
90	3	0.5	0	0.5	3	90	0.480	32	64	1.427	1.016
90	3	0.5	90	0.5	3	180	0.480	32	64	1.427	1.016
90	3	0.5	270	0.5	3	360	0.480	32	64	1.427	1.016
90	3	0.5	180	0.5	3	270	0.480	32	64	1.427	1.016
180	3	0.5	0	0.5	3	180	0.095	8	11	39.646	0.037
180	3	0.5	180	0.5	3	360	0.095	8	11	39.645	0.037

FONTE : Simulações com o Programa n^o 1

Dif Ent Ang : Diferença entre ângulos das duas populações.

QUADRO A2

ANÁLISE DISCRIMINANTE

MEDIDAS DAS NOTAS VERDADEIRAS E FALSAS

DISCRIMINANT ANALYSIS TESTE HOMOGENEITY
OF WITHIN COVARIANCE MATRICES

NOTATION K = NUMBER OF GROUPS
P = NUMBER OF VARIABLES
N = TOTAL NUMBER OF OBSERVATIONS
NCI) = NUMBER OF OBSERVATIONS IN THE I'TH GROUPS

$$V = \frac{\prod | \text{WITHIN SS MATRIX (I)} |^{NCI)/2}}{\prod | \text{POOLED SS MATRIX} |^{N/2}}$$

$$RHO = 1.0 - \left| \begin{array}{cc} 1 & 1 \\ \text{SUM} \text{-----} & \text{-----} \\ NCI) - 1 & N-K \end{array} \right| \frac{2P^2 + 3p - 1}{6CP + 10CK - 10}$$

$$DF = 0.5 (K - 1)CP + 1)P$$

UNDER NULL HYPOTHESIS: $-2 RHO LN \left[\frac{N^{PN/2} V}{\prod NCI)^{PNCI)/2}} \right]$

IS DISTRIBUTED APPROXIMATELY AS CHI-SQUARE(DF)

TEST CHI-SQUARE VALUE = 121.76518909
WITH 21 DF PROB > 0.0001

Since the chi-square value is significant at the 0.1000 level, the within covariance matrices will be used in the discriminant function

QUADRO A3

RESULTADOS DA APLICAÇÃO CONSIDERANDO A MATRIZ $S_1^{-1}S_2$

Vetores de médias das variáveis transformadas

$$\bar{Y}^{(1)} = \begin{bmatrix} 167.018450 \\ -215.729188 \end{bmatrix} \quad \bar{Y}^{(2)} = \begin{bmatrix} 163.043472 \\ -219.423832 \end{bmatrix}$$

Matriz diferença das inversas : $\hat{\Sigma}_1^{-1} - \hat{\Sigma}_2^{-1}$

$$\begin{bmatrix} 0.8366121331 & 0.0000000000 \\ 0.0000000000 & -2.5224626115 \end{bmatrix}$$

Vetor $\hat{\Sigma}_1^{-1} \bar{Y}^{(1)}$

$$\begin{bmatrix} 167.018450 \\ -215.729188 \end{bmatrix}$$

vetor $\hat{\Sigma}_2^{-1} \bar{Y}^{(2)}$

$$\begin{bmatrix} 26.639325 \\ -772.912244 \end{bmatrix}$$

$$\hat{\Sigma}_1^{-1} \bar{Y}^{(1)} - \hat{\Sigma}_2^{-1} \bar{Y}^{(2)} :$$

$$\begin{bmatrix} 140.379125 \\ 557.183056 \end{bmatrix}$$

INDT (Termo independente)

-99504

QUADRO A4

OBSERVAÇÕES DAS AMOSTRAS DE NOTAS VERDADEIRAS
E FALSAS AVALIADAS NA FUNÇÃO DE DISCRIMINAÇÃO
PROPOSTA

GRUPO VERDA- DEIRO	NÚMERO OBSERVAÇÃO	$D(x)$	DECISÃO ESTATÍSTICA
1	001	-9.361799	Pertence à população = 1
1	002	-86.070702	Pertence à população = 1
1	003	-77.696114	Pertence à população = 1
1	004	-76.234184	Pertence à população = 1
1	005	-93.809860	Pertence à população = 1
1	006	-9.248865	Pertence à população = 1
1	007	-80.132515	Pertence à população = 1
1	008	-79.546623	Pertence à população = 1
1	009	-51.947102	Pertence à população = 1
1	010	-14.156910	Pertence à população = 1
1	011	-9.889459	Pertence à população = 1
1	012	-77.280579	Pertence à população = 1
1	013	-15.897653	Pertence à população = 1
1	014	-55.116024	Pertence à população = 1
1	015	-49.278294	Pertence à população = 1
1	016	-86.727692	Pertence à população = 1
1	017	-65.071686	Pertence à população = 1
1	018	-75.321953	Pertence à população = 1
1	019	-42.629009	Pertence à população = 1
1	020	-47.286865	Pertence à população = 1
1	021	-55.969963	Pertence à população = 1
1	022	-27.675718	Pertence à população = 1
1	023	-14.564607	Pertence à população = 1
1	024	-33.444485	Pertence à população = 1
1	025	-46.751476	Pertence à população = 1

QUADRO A4

OBSERVAÇÕES DAS AMOSTRAS DE NOTAS VERDADEIRAS
E FALSAS AVALIADAS NA FUNÇÃO DE DISCRIMINAÇÃO
PROPOSTA

GRUPO	NÚMERO	OBSERVAÇÃO	D _{xy}	DECISÃO ESTATÍSTICA
VERDA-				
DEIRO				
1	026	- 25.834316		Pertence à população = 1
1	027	- 45.246223		Pertence à população = 1
1	028	- 27.552956		Pertence à população = 1
1	029	- 53.766724		Pertence à população = 1
1	030	-104.838531		Pertence à população = 1
1	031	- 40.948692		Pertence à população = 1
1	032	- 96.996445		Pertence à população = 1
1	033	- 37.967319		Pertence à população = 1
1	034	- 19.236160		Pertence à população = 1
1	035	- 11.563610		Pertence à população = 1
1	036	- 35.746159		Pertence à população = 1
1	037	- 44.942051		Pertence à população = 1
1	038	- 69.329063		Pertence à população = 1
1	039	- 58.108063		Pertence à população = 1
1	040	- 67.711250		Pertence à população = 1
1	041	- 85.748825		Pertence à população = 1
1	042	- 38.390926		Pertence à população = 1
1	043	- 71.204636		Pertence à população = 1
1	044	- 28.270760		Pertence à população = 1
1	045	- 68.554138		Pertence à população = 1
1	046	- 76.821434		Pertence à população = 1
1	047	- 52.321270		Pertence à população = 1
1	048	- 58.958168		Pertence à população = 1
1	049	- 57.621872		Pertence à população = 1
1	050	-119.942833		Pertence à população = 1

QUADRO A4

OBSERVAÇÕES DAS AMOSTRAS DE NOTAS VERDADEIRAS
E FALSAS AVALIADAS NA FUNÇÃO DE DISCRIMINAÇÃO
PROPOSTA

GRUPO	NUMERO	OBSERVAÇÃO	DECISÃO	ESTATÍSTICA
VERDA-				
DEIRO				
1	051	- 77.468941	Pertence à população = 1	
1	052	- 16.108368	Pertence à população = 1	
1	053	- 30.952880	Pertence à população = 1	
1	054	- 30.278490	Pertence à população = 1	
1	055	- 85.213051	Pertence à população = 1	
1	056	- 68.809158	Pertence à população = 1	
1	057	- 21.707624	Pertence à população = 1	
1	058	- 79.120354	Pertence à população = 1	
1	059	- 28.625576	Pertence à população = 1	
1	060	- 43.688576	Pertence à população = 1	
1	061	- 72.380074	Pertence à população = 1	
1	062	- 61.339840	Pertence à população = 1	
1	063	- 48.014282	Pertence à população = 1	
1	064	- 42.726850	Pertence à população = 1	
1	065	- 32.065708	Pertence à população = 1	
1	066	- 7.737395	Pertence à população = 1	
1	067	- 77.197639	Pertence à população = 1	
1	068	- 65.419037	Pertence à população = 1	
1	069	- 67.591362	Pertence à população = 1	
1	070	- 4.030326	Pertence à população = 1	
1	071	- 30.741774	Pertence à população = 1	
1	072	- 48.364689	Pertence à população = 1	
1	073	- 49.234104	Pertence à população = 1	
1	074	- 67.647644	Pertence à população = 1	
1	075	- 64.517296	Pertence à população = 1	

QUADRO A4

OBSERVAÇÕES DAS AMOSTRAS DE NOTAS VERDADEIRAS
E FALSAS AVALIADAS NA FUNÇÃO DE DISCRIMINAÇÃO
PROPOSTA

GRUPO	NÚMERO	OBSERVAÇÃO	$D(x)$	DECISÃO	ESTATÍSTICA
VERDA-					
DEIRO					
1	076	- 75.188622		Pertence à população = 1	
1	077	- 40.538255		Pertence à população = 1	
1	078	- 56.594208		Pertence à população = 1	
1	079	- 16.349293		Pertence à população = 1	
1	080	- 73.819969		Pertence à população = 1	
1	081	- 36.716961		Pertence à população = 1	
1	082	- 55.998283		Pertence à população = 1	
1	083	- 65.730881		Pertence à população = 1	
1	084	- 31.688032		Pertence à população = 1	
1	085	- 3.894863		Pertence à população = 1	
1	086	- 39.616070		Pertence à população = 1	
1	087	- 60.643903		Pertence à população = 1	
1	088	- 71.237823		Pertence à população = 1	
1	089	- 29.895042		Pertence à população = 1	
1	090	- 55.257893		Pertence à população = 1	
1	091	- 75.583450		Pertence à população = 1	
1	092	- 48.726971		Pertence à população = 1	
1	093	- 79.731102		Pertence à população = 1	
1	094	- 75.196632		Pertence à população = 1	
1	095	- 77.864883		Pertence à população = 1	
1	096	- 51.540543		Pertence à população = 1	
1	097	- 16.303843		Pertence à população = 1	
1	098	- 62.547005		Pertence à população = 1	
1	099	- 31.508945		Pertence à população = 1	
1	100	- 60.329350		Pertence à população = 1	

QUADRO A4

OBSERVAÇÕES DAS AMOSTRAS DE NOTAS VERDADEIRAS
E FALSAS AVALIADAS NA FUNÇÃO DE DISCRIMINAÇÃO
PROPOSTA

GRUPO VERDADEIRO	NÚMERO OBSERVAÇÃO	$D(x)$	DECISÃO ESTATÍSTICA
2	001	24.516405	Pertence à população = 2
2	002	47.578152	Pertence à população = 2
2	003	6.688653	Pertence à população = 2
2	004	14.944605	Pertence à população = 2
2	005	61.122597	Pertence à população = 2
2	006	23.076159	Pertence à população = 2
2	007	22.666847	Pertence à população = 2
2	008	21.637608	Pertence à população = 2
2	009	31.267379	Pertence à população = 2
2	010	30.534107	Pertence à população = 2
2	011	7.394509	Pertence à população = 2
2	012	40.617954	Pertence à população = 2
2	013	26.933705	Pertence à população = 2
2	014	52.304320	Pertence à população = 2
2	015	24.877838	Pertence à população = 2
2	016	6.285749	Pertence à população = 2
2	017	52.798176	Pertence à população = 2
2	018	60.464890	Pertence à população = 2
2	019	42.142292	Pertence à população = 2
2	020	37.778202	Pertence à população = 2
2	021	38.558918	Pertence à população = 2
2	022	54.381523	Pertence à população = 2
2	023	44.745564	Pertence à população = 2
2	024	30.787895	Pertence à população = 2
2	025	5.576639	Pertence à população = 2

QUADRO A4

OBSERVAÇÕES DAS AMOSTRAS DE NOTAS VERDADEIRAS
E FALSAS AVALIADAS NA FUNÇÃO DE DISCRIMINAÇÃO
PROPOSTA

GRUPO	NUMERO	OBSERVAÇÃO	$D(x, y)$	DECISÃO	ESTADÍSTICA
VERDA-					
DEIRO					
2	026	26.572470		Pertence à população = 2	
2	027	17.757343		Pertence à população = 2	
2	028	33.596466		Pertence à população = 2	
2	029	24.628046		Pertence à população = 2	
2	030	35.002754		Pertence à população = 2	
2	031	23.137838		Pertence à população = 2	
2	032	84.325851		Pertence à população = 2	
2	033	40.886139		Pertence à população = 2	
2	034	44.689522		Pertence à população = 2	
2	035	46.564705		Pertence à população = 2	
2	036	67.110481		Pertence à população = 2	
2	037	31.766989		Pertence à população = 2	
2	038	14.998538		Pertence à população = 2	
2	039	45.404102		Pertence à população = 2	
2	040	45.567852		Pertence à população = 2	
2	041	31.368217		Pertence à população = 2	
2	042	17.980928		Pertence à população = 2	
2	043	40.296474		Pertence à população = 2	
2	044	32.372391		Pertence à população = 2	
2	045	23.771164		Pertence à população = 2	
2	046	53.033611		Pertence à população = 2	
2	047	43.722137		Pertence à população = 2	
2	048	15.636989		Pertence à população = 2	
2	049	31.266567		Pertence à população = 2	
2	050	36.205143		Pertence à população = 2	

QUADRO A4

OBSERVAÇÕES DAS AMOSTRAS DE NOTAS VERDADEIRAS
E FALSAS AVALIADAS NA FUNÇÃO DE DISCRIMINAÇÃO
PROPOSTA

GRUPO VERDA- DEIRO	NUMERO OBSERVAÇÃO	$D(x)$	DECI SÃO ESTATISTICA
2	051	56.871506	Pertence à população = 2
2	052	39.980450	Pertence à população = 2
2	053	20.020699	Pertence à população = 2
2	054	54.947834	Pertence à população = 2
2	055	52.064564	Pertence à população = 2
2	056	41.634590	Pertence à população = 2
2	057	29.600187	Pertence à população = 2
2	058	40.502316	Pertence à população = 2
2	059	55.091892	Pertence à população = 2
2	060	15.562108	Pertence à população = 2
2	061	13.284176	Pertence à população = 2
2	062	10.572348	Pertence à população = 2
2	063	44.220356	Pertence à população = 2
2	064	50.048321	Pertence à população = 2
2	065	43.500988	Pertence à população = 2
2	066	39.369274	Pertence à população = 2
2	067	13.694013	Pertence à população = 2
2	068	14.955220	Pertence à população = 2
2	069	24.891947	Pertence à população = 2
2	070	47.604092	Pertence à população = 2
2	071	14.446511	Pertence à população = 2
2	072	53.588459	Pertence à população = 2
2	073	48.080158	Pertence à população = 2
2	074	32.409439	Pertence à população = 2
2	075	38.149681	Pertence à população = 2

QUADRO A4

OBSERVAÇÕES DAS AMOSTRAS DE NOTAS VERDADEIRAS
E FALSAS AVALIADAS NA FUNÇÃO DE DISCRIMINAÇÃO
PROPOSTA

GRUPO VERDADEIRO	NÚMERO OBSERVAÇÃO	DC _{ij}	DECISÃO ESTATÍSTICA
2	076	50.855339	Pertence à população = 2
2	077	48.046829	Pertence à população = 2
2	078	35.005943	Pertence à população = 2
2	079	36.857609	Pertence à população = 2
2	080	12.878863	Pertence à população = 2
2	081	38.782894	Pertence à população = 2
2	082	12.295928	Pertence à população = 2
2	083	43.474178	Pertence à população = 2
2	084	26.797161	Pertence à população = 2
2	085	33.747467	Pertence à população = 2
2	086	45.815014	Pertence à população = 2
2	087	11.645833	Pertence à população = 2
2	088	38.247082	Pertence à população = 2
2	089	22.648733	Pertence à população = 2
2	090	41.004910	Pertence à população = 2
2	091	36.894302	Pertence à população = 2
2	092	12.879281	Pertence à população = 2
2	093	34.753063	Pertence à população = 2
2	094	14.178919	Pertence à população = 2
2	095	46.557697	Pertence à população = 2
2	096	33.201904	Pertence à população = 2
2	097	31.633766	Pertence à população = 2
2	098	33.221828	Pertence à população = 2
2	099	45.187294	Pertence à população = 2
2	100	30.812075	Pertence à população = 2

QUADRO A5

ANÁLISE DISCRIMINANTE SEGUNDO O SAS

NÚMERO DE OBSERVAÇÕES E PORCENTAGENS DE CLASSIFICAÇÃO			
População de Origem	Decisão Estatística		TOTAL
	Π_1	Π_2	
Π_1	99	1	100
	99.00	1.00	100.00
Π_2	0	100	100
	0.00	100.00	100.00
TOTAL	99	101	200
PERCENTAGEM	49.50	50.50	100.00

Fonte: Índices de Flury (1983) analisados com o SAS

REFERENCIA BIBLIOGRÁFICA

1. -ANDERSON, T. W. (1958) An Introduction to Multivariate Statistical Analysis. Wiley & Sons, New York.
2. -ANDERSON, T. W. (1973) An asymptotic expansion of the distribution of the Studentized Classification Statistics. The Annals of Statistics. 1:964-72.
3. -BOX, G. E. P. AND MULLER, M. E. (1958) A Note on the Generation of Random Normal Deviates. The annals of Mathematical Statistics. 29:810-11.
4. -FISHER, R. A. (1936) The use of multiple measurement in taxonomic problems. In: Atchley, W. R. (1975) Multivariate Statistical Methods: Among-Groups Covariation. Dowden, Hutchinson, Stroudsburg, Pennsylvania.
5. -FLURY, B. AND RIEDWYL, H. (1983) Angewandte Multivariate Statistik. Gustav Fischer, Stuttgart. New York.
6. -FLURY, B. (1983) Some relations between the comparison of covariance matrices and principal component analysis. Computational Statistics & Data Analysis. 1: 97-109.
7. -FLURY, B. N. (1985) Analysis of Linear Combinations with Extreme Ratios of Variance. Journal of the American Statistical Association. 80:915-922.
8. -JOHNSON, R. A. AND WICHERN, D. W. (1982) Applied Multivariate Statistical Analysis. Prentice Hall, Glewood Cliffs.

9. -KRUSKAL, W. H. AND TANUR, J. M. (1978) International Encyclopedia of Statistics. 1:628-35.
10. -LACHENBRUCH, P. A. (1975) Discriminant Analysis. Hafner Press, New York.
11. -LACHENBRUCH, P. A. AND MIKEY, M. R. (1968) Estimation of error rates in discriminant analysis. Technometrics. 10:1-10.
12. -MARDIA, K. V.; KENT, J. T. AND BIBBY, J. M. (1979) Multivariate Analysis. Academic Press, London.
13. -PAYNE, W. H.; RABUNG, J. R. AND BOGYO, T. P. (1969) Coding the Lehmer Pseudo-random Number Generator. Communications of the ACM. 12(2):85-86.
14. -RAO, C. R. AND MITRA, S. K. (1971). Generalized Inverse of Matrices and its Applications. Wiley & Sons, New York.
15. -ROY, S. N. (1957) Some Aspects of Multivariate Analysis. Wiley & sons. New York.
16. -WILKINSON, J. H. AND REINSCH, C. (1971). Handbook for Automatic Computation. Linear Algebra, Springer-Verlag. Vol II.