

MAE 5776

ANÁLISE MULTIVARIADA

Júlia M Pavan Soler

pavan@ime.usp.br

1º Sem/2020 - IME

Análise Multivariada

$$Y_{n \times p} = (Y_{ij}) \in \mathfrak{R}^{n \times p}$$

Já vimos 😊

- ✓ Estatísticas descritivas multivariadas, Episódios de Concentração, Boxplot Bivariado
- ✓ Distribuição N_p , Distribuições Amostrais (T^2 e W_p)
- ✓ $N_p(\mu_g; \Sigma_g)$: Inferências sobre μ_g (T^2 , MANOVA, ICS, Correções para Múltiplos testes)

Decomposições: SS_T e $Y_{n \times p}$

Técnicas Multivariadas:

Já vimos 😊

- ✓ 1. Análise de Componentes Principais (CP)
- ✓ 2. Escalonamento Multidimensional (CoP)
- ✓ 3. Análise de Correspondência
- ✓ 4. Análise Fatorial

Quais são os critérios de otimização?

- Análise Discriminante (MANOVA)
- Análise de Agrupamento
- Análise de Correlação Canônica

Análise Discriminante

- ✓ Solução de Fisher: $G=2$ (solução explícita)
 $G>2$ (maximizar $\Sigma^{-1}\Sigma_B$)



Regra geral de Classificação de Observações)

Análise Discriminante

Foco está na classificação de observações, mais do que na obtenção de vetores reducionistas

Problema Geral de Classificação

Caso de Duas Populações (G=2)

Suposição: Uma população está estratificada em 2 subpopulações, τ_1 e τ_2 , e de cada subpopulação é retirada uma amostra de tamanho n_1 e n_2 , respectivamente.

Com base na amostra, para encontrar uma regra de discriminação de observações de cada população, uma alternativa é **particionar o espaço amostral Ω em duas regiões, R_1 e R_2** , que favoreçam às populações τ_1 e τ_2 , respectivamente, tal que, para uma observação Y_0 tem-se que, se

$$Y_0 \in R_1 \Rightarrow \text{a observação é de } \tau_1$$

$$Y_0 \in R_2 \Rightarrow \text{a observação é de } \tau_2$$

Regra discriminante

Como determinar R_1 e R_2 ?

Análise Discriminante

Problema Geral de Discriminação/Classificação - Solução Probabilística

Caso de Duas Populações

Probabilidades a priori: $\tau_1 \Rightarrow p_1(y)$ $\tau_2 \Rightarrow p_2(y)$ $p_1 + p_2 = 1$

Função densidade de probabilidades: $\tau_1 \Rightarrow f_1(y)$ $\tau_2 \Rightarrow f_2(y)$

Probabilidade de Classificação Errada: $\left\{ \begin{array}{l} P(2|1) = P(Y_i \in R_2 | \tau_1) = \int_{R_2 = \Omega - R_1} f_1(y) dy \\ P(1|2) = P(Y_i \in R_1 | \tau_2) = \int_{R_1 = \Omega - R_2} f_2(y) dy \end{array} \right.$

Probabilidade de Classificação Correta: $\left\{ \begin{array}{l} P(1|1) = P(Y_i \in R_1 | \tau_1) = \int_{R_1 = \Omega - R_2} f_1(y) dy \\ P(2|2) = P(Y_i \in R_2 | \tau_2) = \int_{R_2 = \Omega - R_1} f_2(y) dy \end{array} \right.$

Análise Discriminante

Problema Geral de Classificação - Caso de Duas Populações

Notação

Probabilidade de Classificação

Verdade	Predito	
	τ_1	τ_2
τ_1	$P(1,1)$	$P(2,1)$
τ_2	$P(1,2)$	$P(2,2)$

Custo de Classificação

Verdade	Predito	
	τ_1	τ_2
τ_1	0	$c(2 1)$
τ_2	$c(1 2)$	0

$$P(1,1) = P(1|1)p_1 \quad P(2,1) = P(2|1)p_1$$

$$P(1,2) = P(1|2)p_2 \quad P(2,2) = P(2|2)p_2$$

Logo, o custo esperado de classificação errada (*CECE*) é dado por:

$$\begin{aligned} CECE &= c(2|1)P(2,1) + c(1|2)P(1,2) \\ &= c(2|1)P(2|1)p_1 + c(1|2)P(1|2)p_2 \end{aligned}$$

⇒ Obter R_1 e R_2 que minimizem *CECE*

Análise Discriminante

Problema Geral de Classificação - Caso de Duas Populações

Minimizar o custo esperado de classificação errada:

$$\begin{aligned} CECE &= c(2|1)P(2|1)p_1 + c(1|2)P(1|2)p_2 \\ &= c(2|1)p_1 \int_{R_2} f_1(y) dy + c(1|2)p_2 \int_{R_1} f_2(y) dy \\ &= c(2|1)p_1 + \int_{R_1} [c(1|2)p_2 f_2(y) - c(2|1)p_1 f_1(y)] dy \end{aligned}$$

$\leq 0 \Rightarrow$ mínimo *CECE*

Somando e subtraindo

$c(2|1)p_1 \int_{R_1} f_1(y) dy$ tem-se:

R_1 e R_2 são conjuntos de valores $Y \in \mathfrak{R}^p$ para os quais:

$$R_1: \frac{f_1(y)}{f_2(y)} \geq \frac{c(1|2)p_2}{c(2|1)p_1}$$

$$R_2: \frac{f_1(y)}{f_2(y)} < \frac{c(1|2)p_2}{c(2|1)p_1}$$

Discriminação sob Estimação

Problema Geral de Classificação - Caso de Duas Populações Normais

Função densidade de probabilidades:

↙ heterocedasticidade

$$\tau_g \Rightarrow f_g(y) = \frac{1}{(2\pi)^{p/2} |\Sigma_g|^{1/2}} \exp \left\{ -\frac{1}{2} (Y - \mu_g)' \Sigma_g^{-1} (Y - \mu_g) \right\}; \quad g = 1, 2; Y \in \mathfrak{R}^p$$

Classificar uma observação em τ_1 se $Y \in \mathfrak{R}^p$ pertencer à região R_1 dada por:

$$R_1 : -\frac{1}{2} Y' (\Sigma_1^{-1} - \Sigma_2^{-1}) Y + (\mu_1' \Sigma_1^{-1} - \mu_2' \Sigma_2^{-1}) Y - c \geq \ln \left[\frac{c(1|2) p_2}{c(2|1) p_1} \right]$$

em que, $c = \frac{1}{2} \ln \left(\frac{|\Sigma_1|}{|\Sigma_2|} \right) + \frac{1}{2} (\mu_1' \Sigma_1^{-1} \mu_1 - \mu_2' \Sigma_2^{-1} \mu_2)$

R2 é dada pelo complementar de R1 em Ω .



Sob Heterocedasticidade \Rightarrow Função Discriminante Quadrática (em $Y \in \mathfrak{R}^p$)

Regra de Discriminação Amostral: obter estimador de MVS

Análise Discriminante

Problema Geral de Classificação - Caso de Duas Populações Normais

Regra de discriminação: (os parâmetros são substituídos por sua estimativas)

Função discriminante quadrática

Critério flexível: permite heterocedasticidade, custos e priors diferentes

Alocar Y_0 em τ_1 se

X_0^Q

$$-\frac{1}{2} Y_0' (S_1^{-1} - S_2^{-1}) Y_0 + (\bar{X}_1' S_1^{-1} - \bar{X}_2' S_2^{-1}) Y_0 - \hat{c}_Q \geq \ln \left[\frac{c(1|2)p_2}{c(2|1)p_1} \right]$$

Alocar Y_0 em τ_2 caso contrário

em que,
$$\hat{c}_Q = \frac{1}{2} \ln \left(\frac{|S_1|}{|S_2|} \right) + \frac{1}{2} \left(\bar{Y}_1' S_1^{-1} \bar{Y}_1' - \bar{Y}_2' S_2^{-1} \bar{Y}_2' \right)$$

Análise Discriminante

Problema Geral de Classificação - Caso de Duas Populações Normais

$$Y_i \in \tau_k ; Y_i \stackrel{iid}{\sim} N_p(\mu_g; \Sigma_g) \quad g = 1, 2$$

$$\Rightarrow \text{Suposição: } \Sigma_1 = \Sigma_2 = \Sigma$$

Regra de discriminação:

$$\left\{ \begin{array}{l} \text{Alocar } Y_0 \text{ em } \tau_1 \text{ se} \\ \left(\bar{Y}_1 - \bar{Y}_2 \right)' S_c^{-1} X_0^L - \frac{1}{2} \left(\bar{Y}_1 - \bar{Y}_2 \right)' S_c^{-1} \hat{c} \geq \ln \left[\frac{c(1|2)p_2}{c(2|1)p_1} \right] \\ \text{Alocar } Y_0 \text{ em } \tau_2 \text{ caso contrário} \end{array} \right.$$

\Rightarrow Note que a função discriminante X_0^L é linear em Y_0

Análise Discriminante

Problema Geral de Classificação - Caso de Duas Populações Normais

$$Y_i \in \tau_k ; Y_i \stackrel{iid}{\sim} N_p(\mu_g; \Sigma) \quad g = 1, 2$$

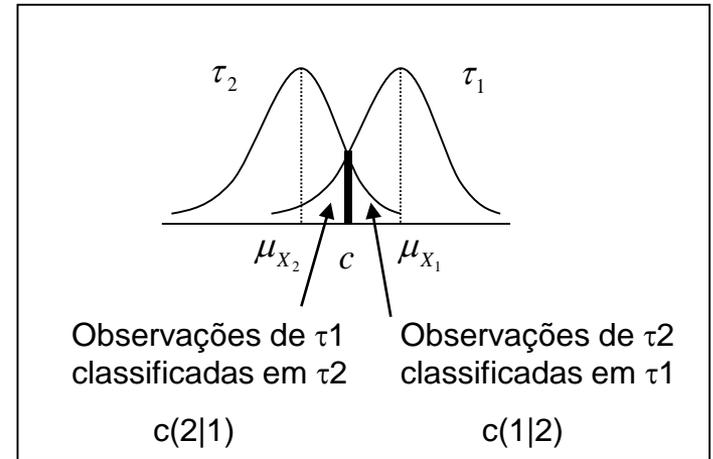
⇒ Função Discriminante Linear

↑ homocedasticidade

Alocar Y_0 em τ_1 se

$$X_0 - \hat{c} \geq \ln \left[\frac{c(1|2)p_2}{c(2|1)p_1} \right]$$

Alocar Y_0 em τ_2 caso contrário



- Se os custos e as prioris são iguais \Rightarrow função discriminante linear de Fisher
- Se $c(2|1) > c(1|2)$ e $p_1 = p_2 \Rightarrow$ o limite “c” é deslocado para a esquerda
- Se $p_1 < p_2$ e $c(2|1) = c(1|2) \Rightarrow$ o limite “c” é deslocado para a direita

Análise Discriminante

Banco	Condição	Y1	Y2	Y3	Y4
B1	1	0,8888	0,7391	1,0255	0,3938
B2	1	1,6655	0,7268	0,878	0,0004
B3	1	2,2111	0,9166	0,9492	0,342
B4	1	1,4351	0,9133	0,9577	0,2325
B5	1	2,1414	0,002	1,0245	0,3966
B6	1	1,192	0,4972	1,034	0,3095
B7	1	1,5895	0,2593	1,0453	0,557
B8	1	1,3272	0,4126	1,0448	0,3482
B9	1	1,8847	0,388	0,9864	0,0337
B10	1	0,5229	0,9473	1,1244	0,118
n		10	10	10	10
Média		1,4852	0,5802	1,007	0,2732
D.P.		0,533	0,319	0,0674	0,1762
B11	2	0,4922	0,3166	1,1127	0,1628
B12	2	1,4427	0,0589	0,9019	0,1355
B13	2	0,5438	0,5358	1,03	0,1481
B14	2	0,1904	0,7087	0,9917	0,2625
B15	2	0,1102	0,7378	1,528	0,0783
B16	2	2,006	0,014	1,0321	0,0816
B17	2	0,2321	0,9234	0,9753	0,0045
B18	2	0,9019	0,1634	1,1414	0,5485
B19	2	1,9757	0,3395	0,9997	0,0751
B20	2	0,7276	0,3139	1,1077	0,2957
n		10	10	10	10
Média		0,862	0,4112	1,0821	0,1793
D.P.		0,712	0,3055	0,1726	0,1567

Condição:

1: Com problemas

2: Sem problemas

Objetivo:

Obter uma função de discriminação com base nas 4 variáveis de indicadores econômicos

⇒ Obtenha a função discriminante linear e quadrática

⇒ Quais suposições estão implícitas em cada caso?

Análise Discriminante

Dados dos Bancos

$$\bar{Y}_{g=1} = \begin{pmatrix} 1,486 \\ 0,580 \\ 1,007 \\ 0,273 \end{pmatrix}$$

$$S_{g=1} = \begin{pmatrix} 0,284 & & & \\ -0,070 & 0,102 & & \\ -0,021 & -0,004 & 0,005 & \\ 0,008 & -0,022 & 0,004 & 0,031 \end{pmatrix}$$

$$\bar{Y}_{g=2} = \begin{pmatrix} 0,862 \\ 0,414 \\ 1,082 \\ 0,179 \end{pmatrix}$$

$$S_{g=2} = \begin{pmatrix} 0,505 & & & \\ -0,164 & 0,091 & & \\ -0,051 & 0,014 & 0,030 & \\ -0,012 & -0,016 & 0,002 & 0,025 \end{pmatrix}$$

$$S_c = \begin{pmatrix} 0,395 & & & \\ -0,117 & 0,096 & & \\ -0,036 & 0,005 & 0,017 & \\ -0,002 & -0,019 & 0,003 & 0,028 \end{pmatrix}$$

Usar o teste M de Box
para verificar a
homocedasticidade!

Análise Discriminante

Dados dos Bancos

homocedasticidade

Suposição: $Y_i \in \tau_g ; Y_i \stackrel{iid}{\sim} N_p(\mu_g; \Sigma_g) \quad g = 1, 2 \quad \Sigma_1 = \Sigma_2 = \Sigma$

Custos de classificação Errada e Prioris **iguais** para as populações

⇒ **Função Discriminante Linear de Fisher**

$$X_0 - c \geq \ln \left[\frac{c(1|2)p_2}{c(2|1)p_1} \right] \Rightarrow X_0 - c - \ln \left[\frac{c(1|2)p_2}{c(2|1)p_1} \right] \geq 0$$

$$\underbrace{(\bar{Y}_1 - \bar{Y}_2)' S_c^{-1} Y_0}_{X_0^L} - \underbrace{\frac{1}{2} (\bar{Y}_1 - \bar{Y}_2)' S_c^{-1} (\bar{Y}_1 + \bar{Y}_2)}_c - \underbrace{\ln \left[\frac{c(1|2)p_2}{c(2|1)p_1} \right]}_{=0}$$



$$4.36Y_1 + 8.91Y_2 + 0.52Y_3 + 9.71Y_4 - 12.27$$

Análise Discriminante

Dados dos Bancos

Suposição: $Y_i \in \tau_g ; Y_i \stackrel{iid}{\sim} N_p(\mu_g; \Sigma_g) \quad g = 1, 2$ heterocedasticidade

Custos de classificação Errada e Probabilidades a Priori **iguais** para as populações

⇒ Função Discriminante Quadrática


$$\underbrace{-\frac{1}{2} Y_0' (S_1^{-1} - S_2^{-1}) Y_0 + (\bar{Y}_1' S_1^{-1} - \bar{Y}_2' S_2^{-1}) Y_0}_{X_0^Q} - \hat{c}_Q \geq \ln \left[\frac{c(1|2)p_2}{c(2|1)p_1} \right] = 0$$

$$\begin{aligned} & -0,214Y_1^2 + 14,535Y_2^2 - 204,116Y_3^2 + 14,038Y_4^2 \\ & + 9,332Y_1Y_2 + -38,603Y_1Y_3 + 16,846Y_1Y_4 - 35,125Y_2Y_3 + 31,732Y_2Y_4 + 43,362Y_3Y_4 \\ & + 38,194Y_1 + 17,076Y_2 + 478,004Y_3 - 73,415Y_4 - 273,776 \end{aligned}$$

Análise Discriminante

Dados dos Bancos – Avaliação empírica da Regra de Classificação

Banco	Condição	Regra Linear		Regra Quadrática	
		X	Grupo	X	Grupo
B1	1	3,336	1	6,329	1
B2	1	2,701	1	4,108	1
B3	1	10,223	1	27,94	1
B4	1	5,825	1	13,043	1
B5	1	1,403	1	2,861	1
B6	1	1,425	1	3,046	1
B7	1	3,146	1	6,822	1
B8	1	1,539	1	3,359	1
B9	1	0,635	1	1,247	1
B10	1	1,222	1	1,151	1
B11	2	-4,74	2	-1,808	2
B12	2	-3,57	2	-5,13	2
B13	2	-2,514	2	-2,313	2
B14	2	-1,223	2	-4,802	2
B15	2	-2,862	2	-39,071	2
B16	2	-1,862	2	-1,397	2
B17	2	-1,4	2	-3,083	2
B18	2	-0,792	2	0,713	1
B19	2	0,945	1	1,411	1
B20	2	-2,484	2	-1,175	2

Regra Linear:

	Predito	
Real	1	2
1	10	0
2	1	9

Regra Quadrática:

	Predito	
Real	1	2
1	10	0
2	2	8

Função linear classifica melhor!

Testar a igualdade das matrizes de covariância (Teste de Box). Decidir pela função linear (de Fisher) no caso da não rejeição de $H_0 : \Sigma_1 = \Sigma_2$.

Chi-Sq (approx.) = 13.733, df = 10, p-value = 0.1855

Análise Discriminante

Problema Geral de Classificação – Caso de Muitas Populações

As Regiões de Classificação que minimizam $CEEC$ são definidas por alocar Y_0 à população τ_k , $k=1,2,\dots,G$, que atinge o mínimo erro de classificação, dado por:

$$\sum_{\substack{g=1 \\ g \neq k}}^G p_g f_g(y) c(k|g)$$

Logo, se todos os custos são iguais, devemos alocar Y_0 à população τ_k se:

$$p_k f_k(y) > p_g f_g(y) \quad g = 1, \dots, G; g \neq k$$

ou, equivalentemente: $\ln p_k f_k(y) > \ln p_g f_g(y) \quad g = 1, \dots, G; g \neq k$

Análise Discriminante

Problema Geral de Classificação – Caso de Muitas Populações

Alocar Y_0 a τ_k se: $\ln p_k f_k(y) > \ln p_g f_g(y) \quad g = 1, \dots, G; g \neq k$

Caso Especial (N_p): $Y_i \stackrel{iid}{\sim} N_p(\mu_g; \Sigma_g)$ heterocedasticidade

$$f_g(y) = \frac{1}{(2\pi)^{p/2} |\Sigma_g|^{1/2}} \exp\left\{-\frac{1}{2}(Y - \mu_g)' \Sigma_g^{-1} (Y - \mu_g)\right\}, \quad g = 1, 2, \dots, G$$

$$\ln p_k f_k(y) = \ln p_k - \frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} (Y - \mu_k)' \Sigma_k^{-1} (Y - \mu_k) = \max_g \ln p_g f_g(y)$$

Define-se Escore Discriminante Quadrático (de $Y \in \mathbb{R}^p$) para a g -ésima população:



$$d_g^Q(y) = -\frac{1}{2} \ln |\Sigma_g| - \frac{1}{2} (Y - \mu_g)' \Sigma_g^{-1} (Y - \mu_g) + \ln p_g \quad g = 1, \dots, G$$

Análise Discriminante

Problema Geral de Classificação – Caso de Muitas Populações

$$\ln p_k f_k(y) > \ln p_g f_g(y) \quad g = 1, \dots, G; g \neq k$$

heterocedasticidade

$Y_i \stackrel{iid}{\sim} N_p(\mu_g; \Sigma_g) \Rightarrow$ Alocar Y a τ_k se o escore quadrático $d_k^Q(y)$ é maior que os demais

$$\text{em que, } d_k^Q(y) = -\frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} (Y - \mu_k)' \Sigma_k^{-1} (Y - \mu_k) + \ln p_k \quad k = 1, \dots, G$$

Se $Y_i \stackrel{iid}{\sim} N_p(\mu_g; \Sigma)$, isto é, $\Sigma_1 = \dots = \Sigma_g$

homocedasticidade

$$d_k^Q(y) \Rightarrow d_k(y) = \mu_k' \Sigma^{-1} Y - \frac{1}{2} \mu_k' \Sigma^{-1} \mu_k + \ln p_k \quad k = 1, \dots, G$$

Escore discriminante linear para a população τ_k

Análise Discriminante

Problema Geral de Classificação – Caso de Muitas Populações

$$Y_i \stackrel{iid}{\sim} N_p(\mu_g; \Sigma_g)$$

escore discriminante quadrático máximo

$$d_k^Q(y)$$

$$-\frac{1}{2} \ln |\Sigma_k| - \frac{1}{2} (Y - \mu_k)' \Sigma_k^{-1} (Y - \mu_k) + \ln p_k$$

$$Y_i \stackrel{iid}{\sim} N_p(\mu_g; \Sigma)$$

escore discriminante linear máximo

$$d_k(y)$$

$$\mu_k' \Sigma^{-1} Y - \frac{1}{2} \mu_k' \Sigma^{-1} \mu_k + \ln p_k$$

O Escore Discriminante linear pode ser comparado para duas populações, de tal modo que, a condição “ $d_k(y)$ é maior “, fica equivalente a:

$$0 \leq d_k(y) - d_g(y) = (\mu_k - \mu_g)' \Sigma^{-1} Y - \frac{1}{2} (\mu_k - \mu_g)' \Sigma^{-1} (\mu_k + \mu_g) + \ln \left(\frac{p_k}{p_g} \right)$$



Alocar Y a τ_k se:

$$\underbrace{(\mu_k - \mu_g)' \Sigma^{-1} Y}_{\text{Função de Fisher}} - \underbrace{\frac{1}{2} (\mu_k - \mu_g)' \Sigma^{-1} (\mu_k + \mu_g)}_c \geq \ln \left(\frac{p_g}{p_k} \right)$$

Análise Discriminante

Validação Empírica de um Algoritmo de Classificação Amostral

Métricas de validação via a Matriz de Classificação

Matriz de Classificação (ou de Confusão)

Verdade	Predito		
	$\tau_1 +$	$\tau_2 -$	
$\tau_1 +$	$n_{1c} \mathbf{V+}$	$n_{1M} \mathbf{F-}$	n_1
$\tau_2 -$	$n_{2M} \mathbf{F+}$	$n_{2c} \mathbf{V-}$	n_2

- Taxa de Erro Aparente (proporção de itens mal classificados):

$$TxErro = \frac{n_{1M} + n_{2M}}{n_1 + n_2} = \frac{F_+ + F_-}{n} \quad \text{Estima Pr(classificação errada)}$$

- Acurácia: $Acurácia = \frac{n_{1c} + n_{2c}}{n_1 + n_2} = \frac{V_+ + V_-}{n} \quad \text{Estima Pr(classificação correta)}$

Métricas de Validação via a Matriz de Classificação

Matriz de Classificação (ou de Confusão)

Verdade	Predito		
	$\tau_1 +$	$\tau_2 -$	
$\tau_1 +$	n_{1c} V+	n_{1M} F-	n_1
$\tau_2 -$	n_{2M} F+	n_{2c} V-	n_2

- Sensibilidade = $\frac{V_+}{V_+ + F_-}$ = Pr(classificação + | +)

- Especificidade = $\frac{V_-}{F_+ + V_-}$ = Pr(classificação - | -)

Poder Preditivo via a Curva ROC:
Sensibilidade x (1-Especificidade)

- Preditivo Positivo = $\frac{V_+}{F_+ + V_+}$ Precisão do classificador

- Preditivo Negativo = $\frac{V_-}{F_- + V_-}$

- Escore F1 = $2 \frac{\textit{Precisão} * \textit{Sensibilidade}}{\textit{Precisão} + \textit{Sensibilidade}}$

Média harmônica da precisão e sensibilidade

Análise Discriminante

Validação de um Algoritmo de Classificação

Matriz de Classificação (ou de Confusão)

Verdade	Predito		
	τ_1	τ_2	
τ_1	n_{1c} V+	n_{1M} F+	n_1
τ_2	n_{2M} F-	n_{2c} V-	n_2

$TxErro$ **subestima** a Probabilidade de erro de classificação (populacional), assim como as demais métricas:

$$TxErro = \frac{n_{1M} + n_{2M}}{n_1 + n_2} = \frac{F_+ + F_-}{n} \rightarrow p_1 \int_{R_2} f_1(y) dy + p_2 \int_{R_1} f_2(y) dy$$


Alternativas

- Método de Particionamento (*Data Split*): particiona os dados em **Amostra de Treinamento e Amostra de Validação (Teste)**
- Método de “**Validação Cruzada**” (Cross-validation)

Análise Discriminante

Validação de um Algoritmo de Classificação Amostral

Validação Cruzada pelo método Leave-One-Out ($Fold=N$)

1. Inicie com as observações de τ_1 . Omita uma obs deste grupo e obtenha a função de classificação baseada nos remanescentes $N-1=(n_1-1)+n_2$ observações (supondo $G=2$)
2. Classifique a obs omitida usando a função calculada no passo 1
3. Repetir os passos 1 e 2 até que todas as obs de τ_1 tenham sido classificadas. Calcule o número de erros de classificação neste grupo
4. Repita os passos de 1 a 3 para as observações do grupo 2.

Taxa de Erro de Classificação esperada é dada por:

$$TxErro = \frac{n_{1M}^{Cross} + n_{2M}^{Cross}}{n_1 + n_2}$$

Algoritmos de CV
podem usar $Fold=k$

Análise Discriminante

Normalização de Variáveis

Unidades Amostrais		Variáveis							
		1	2	...	j	...	p		
G1	1	Y_{111}	Y_{112}	...	Y_{11j}	...	Y_{11p}	$\bar{Y}_{1 \times p \times 1}$	$S_{1 \times p \times p}$
	2	Y_{121}	Y_{122}	...	Y_{12j}	...	Y_{12p}		
		
	n_1	Y_{1n11}	Y_{1n12}	...	Y_{1n1j}	...	Y_{1n1p}		
G2	1	Y_{211}	Y_{212}	...	Y_{21j}	...	Y_{21p}	$\bar{Y}_{2 \times p \times 1}$	$S_{2 \times p \times p}$
	2	Y_{221}	Y_{222}	...	Y_{22j}	...	Y_{22p}		
		
	n_2	Y_{2n21}	Y_{2n22}	...	Y_{2n2j}	...	Y_{2n2p}		

$\bar{Y}_{p \times 1}$ $S_{c \times p \times p}$

Na AD a normalização das variáveis é usada com a finalidade de facilitar a interpretação dos pesos das variáveis na função discriminante e no cálculo de “c”. O Ida do R adota a “normalização” das variáveis para calcular as funções discriminantes, mas o lmda não. A normalização da variável j avaliada no indivíduo i do grupo g é dada por:

$$Y_{gij}^* = \left(\frac{Y_{gij} - \bar{Y}_j}{S_{gj}} \right)$$

Média: para cada j independente de grupo

Variância: para cada grupo g e variável j

$$\bar{Y}_j = \frac{1}{n_1 + n_2} \sum_{g=1}^2 \sum_{i=1}^{n_g} Y_{gij}$$

Média da variável j (j=1,...,p), independente de grupo

$$S_{gj} = \frac{1}{n_g - 1} \sum_{i=1}^{n_g} (Y_{gij} - \bar{Y}_{gj})^2$$

Variância da variável j no grupo g

Dados dos Bancos - Funções Discriminantes Lineares - Classes Preditas

- Dados originais (linDA), prioris iguais
1 1 1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 2 1 2
- Dados normalizados (lda), prioris amostrais
1 1 1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 2 1 2
- Dados normalizados (lda), prioris iguais
1 1 1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 2 1 2
- Dados normalizados (lda), prioris proporcionais: $p_1=2p_2$, $p_1+p_2=1$
1 1 1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 2 1 2
- Dados normalizados (lda), prioris iguais, CV (Leave-One-Out)
1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 2 1 1 2
- Dados normalizados, prioris iguais, *Data Split*: 70% Treinamento, 30% Teste (set.seed(1314):obs preditas 3,4,6,14,16,19)
1 1 1 2 1 1

Dados dos Bancos - Função Discriminante Quadrática - Classes Preditas

- Dados normalizados (lda), prioris iguais
1 1 1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 1 1 2

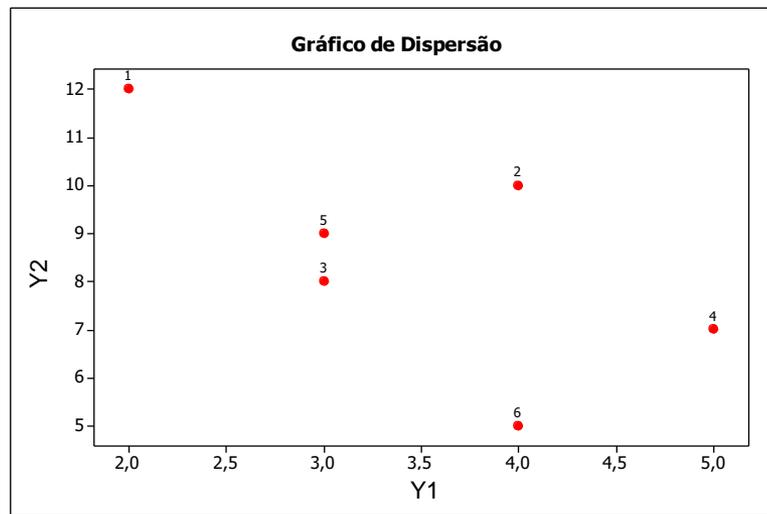
Compare as regras de classificação!

Análise Discriminante

Considere os dados (hipotéticos) a seguir em que duas variáveis foram observadas em três indivíduos do grupo 1 e em três indivíduos do grupo 2:

$$G_1 = \begin{pmatrix} 2 & 4 & 3 \\ 12 & 10 & 8 \end{pmatrix} \quad G_2 = \begin{pmatrix} 5 & 3 & 4 \\ 7 & 9 & 5 \end{pmatrix}$$

1. Calcule a função discriminante de Fisher para a diferença entre os grupos. Qual é a regra de classificação de observações? Que suposições são feitas?
2. Calcule também o escore discriminante para cada grupo via o método geral de classificação. Suponha que $p_1=p_2$. E se $p_1=2p_2$?
3. Calcule a taxa observada de erro de classificação. Classifique a observação (4,7).
4. Calcule a taxa de erro de classificação via validação cruzada.
5. Obtenha a função discriminante para os dados “normalizados”.



Diferentes formulações da função discriminante linear.

Grupo	Y1	Y2	$X = -0,33Y1 + 0,67Y2$	$X^* = 0,33Y1 + 0,67Y2 - 4,54$	$X1 = 7,33Y1 + 4,33Y2 - 32,67$	$X2 = 7,67Y1 + 3,67Y2 - 28,17$	Grupo Pred
1	2	12	7,38	2,84	33,95	31,21	1
1	4	10	5,38	0,84	39,95	39,21	1
1	3	8	4,37	-0,17	23,96	24,2	2
2	5	7	3,04	-1,5	34,29	35,87	2
2	3	9	5,04	0,5	28,29	27,87	1
2	4	5	2,03	-2,51	18,3	20,86	2

c=4,54

Solução usando pacote lda do R: valores Y estão normalizados para ter variância 1

```

X = 0.2182179 Y1* - 0.4364358 Y2*
LD1= X-c; c=((-3.7097)+(-2.1821))/2=-2.946
LD1 <= 0 grupo1, cc grupo2
> fit.values$class
[1] 1 1 2 2 1 2

```

LD1

```

1 -1.8548521 alocar G1
2 -0.5455447 alocar G1
3 0.1091089 alocar G2
4 0.9819805 alocar G2
5 -0.3273268 alocar G1
6 1.6366342 alocar G2

```

Note as seguintes formulações da função discriminante linear (G=2):

$$X = (\bar{Y}_k - \bar{Y}_g)' S_c^{-1} Y; \quad c = \frac{1}{2} (\bar{Y}_k - \bar{Y}_g)' S_c^{-1} (\bar{Y}_k + \bar{Y}_g)$$

$$X^* = (\bar{Y}_k - \bar{Y}_g)' S_c^{-1} Y - c$$

$$X_{gi} = \bar{Y}_g' S_c^{-1} Y_i - \frac{1}{2} \bar{Y}_g' S_c^{-1} \bar{Y}_g = d_g(y_i)$$

Note que, sob normalidade e homocedasticidade, $Y | \tau_g \sim N_p(\mu_g; \Sigma)$, $g = 1, 2$:

$$X_c = (\mu_1 - \mu_2)' \Sigma^{-1} (Y - \mu); \quad \mu = \frac{1}{2} (\mu_1 + \mu_2)$$

$$X_c | Y \in \tau_1 \sim N\left(\frac{1}{2} d_M^2; d_M^2\right),$$

$$X_c | Y \in \tau_2 \sim N\left(-\frac{1}{2} d_M^2; d_M^2\right); \quad d_M^2 = (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2)$$

Assim, a probabilidade de classificação errada é,

$$P(Y \text{ alocado em } \tau_1 | Y \in \tau_2) = P(X_c(y) > 0 | Y \in \tau_2) = P\left(Z > \frac{1}{2} d_M\right) = \Phi\left(-\frac{1}{2} d_M\right)$$

##Comandos R

#Análise discriminante

```
dat<-matrix(c(2,4,3,5,3,4,12,10,8,7,9,5,1,1,1,2,2,2),6,3)
```

```
xbar<-colMeans(dat[,1:2])
```

```
xbar1<-colMeans(dat[1:3,1:2])
```

```
xbar2<-colMeans(dat[4:6,1:2])
```

```
cov1<-cov(dat[1:3,1:2])
```

```
cov2<-cov(dat[4:6,1:2])
```

```
library(biotools)
```

```
mt<-boxM(dat[, -3], dat[, 3])
```

```
library(Discriminer)
```

```
fitlda<-linDA(dat[, -3], dat[, 3])
```

```
library(MASS) ##outra alternativa de analise
```

```
fit<- lda(dat[,3] ~ dat[,1] + dat[,2],prior=c(1,1)/2)
```

```
#fit<- lda(dat[,3] ~ dat[,1] + dat[,2],prior=c(2,1)/3) ; #p1=2p2, p1+p2=1
```

```
fit.values <- predict(fit, data.frame(dat[,1:2]))
```

```
fit.values$x
```

```
fit.values$class
```

```
ct <- table(dat[,3],fit.values$class) #tabela com as classificações
```

```
diag(prop.table(ct, 1)) # % de classif correta
```

```
sum(diag(prop.table(ct)))
```

```
fit$svd # (SSB-\lambda SSW)a=0
```

```
mv<-aggregate(fit.values$x, data.frame(dat[,3]), FUN=mean)
```

```
colMeans(mv[2])
```

Análise Discriminante via Modelo de Regressão Logística Dicotômica

$Y_i = 1$: se o indivíduo é do grupo $G=1$; $Y_i = 0$ se o indivíduo é do grupo $G=2$

$$E(Y | X, \beta) = P(Y = 1 | X, \beta) = p(X) = \frac{e^{\beta_0 + \sum_{j=1}^p X_{ij}\beta_j}}{1 + e^{\beta_0 + \sum_{j=1}^p X_{ij}\beta_j}}$$
$$P(Y = 0 | X, \beta) = 1 - p(X) = \frac{1}{1 + e^{\beta_0 + \sum_{j=1}^p X_{ij}\beta_j}}$$

$$odds = \frac{p(X)}{1 - p(X)}$$

$$\ln(odds) = \beta_0 + \sum_{j=1}^p X_{ij}\beta_j$$



Estimação do vetor β via Máxima Verossimilhança:

$$L(\beta) = \prod_{i=1}^n p(X_i)^{Y_i} (1 - p(X_i))^{1 - Y_i} \rightarrow \hat{\beta}$$



Regra de classificação:

$$\hat{p}(X) = \frac{e^{\hat{\beta}_0 + \sum_{j=1}^p X_{ij}\hat{\beta}_j}}{1 + e^{\hat{\beta}_0 + \sum_{j=1}^p X_{ij}\hat{\beta}_j}} \begin{cases} \geq 0.5 & \rightarrow \text{classificar em } G=1 \\ < 0.5 & \rightarrow \text{classificar em } G=2 \end{cases}$$

Outros valores
podem ser adotados

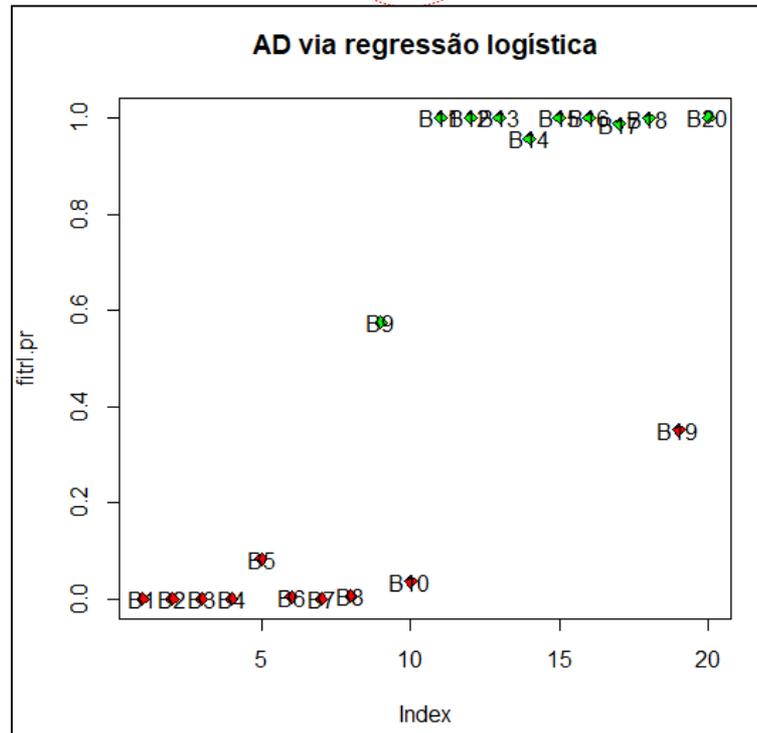
Pode ser estendido
para regressão
politômica ($G > 2$)

Análise Discriminante via Modelo de Regressão Logística Dicotômica

Banco	Condição	Y1	Y2	Y3	Y4
B1	1	0,8888	0,7391	1,0255	0,3938
B2	1	1,6655	0,7268	0,878	0,0004
B3	1	2,2111	0,9166	0,9492	0,342
B4	1	1,4351	0,9133	0,9577	0,2325
B5	1	2,1414	0,002	1,0245	0,3966
B6	1	1,192	0,4972	1,034	0,3095
B7	1	1,5895	0,2593	1,0453	0,557
B8	1	1,3272	0,4126	1,0448	0,3482
B9	1	1,8847	0,388	0,9864	0,0337
B10	1	0,5229	0,9473	1,1244	0,118
n		10	10	10	10
Média		1,4852	0,5802	1,007	0,2732
D.P.		0,533	0,319	0,0674	0,1762
B11	2	0,4922	0,3166	1,1127	0,1628
B12	2	1,4427	0,0589	0,9019	0,1355
B13	2	0,5438	0,5358	1,03	0,1481
B14	2	0,1904	0,7087	0,9917	0,2625
B15	2	0,1102	0,7378	1,528	0,0783
B16	2	2,006	0,014	1,0321	0,0816
B17	2	0,2321	0,9234	0,9753	0,0045
B18	2	0,9019	0,1634	1,1414	0,5485
B19	2	1,9757	0,3395	0,9997	0,0751
B20	2	0,7276	0,3139	1,1077	0,2957
n		10	10	10	10
Média		0,862	0,4112	1,0821	0,1793
D.P.		0,712	0,3055	0,1726	0,1567

Coefficients: **Cargas**

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	25.10	63.20	0.397	0.691
Y1	-17.63	30.22	-0.584	0.560
Y2	-49.04	94.33	-0.520	0.603
Y3	29.56	148.89	0.199	0.843
Y4	-50.23	93.59	-0.537	0.591



Matriz de classificação

	$p < 0.5$	$p \geq 0.5$
1	9	1
2	1	9

18/20 corretas