

Discriminação e Classificação

Lupércio França Bessegato
Dep. Estatística/UFJF

Roteiro

1. Introdução
2. Classificação e Discriminação
3. Análise Discriminante
4. Regressão Logística Multinomial
5. Outras Abordagens
6. Referências

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

4

Introdução

Análise Multivariada

- Considera várias variáveis relacionadas simultaneamente
- Variáveis de interesse não-independentes uma das outras
- Associação entre conjuntos de medidas

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

6

Objetos

- Entidades das quais são tomadas medidas
 - √ Itens, pessoas, organizações, etc.
 - √ São portadores de medidas
 - √ São medidos somente com respeito a certas variáveis de interesse

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

7

Variáveis

- Características ou propriedades
 - √ São os aspectos dos objetos que são medidos

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

8

Organização de Dados Multivariados

$$\mathbf{X}_{n \times p} = \begin{matrix} & \begin{matrix} 1 & 2 & \dots & p \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ \vdots \\ n \end{matrix} & \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix} \end{matrix} \quad \begin{matrix} p: \text{número de variáveis} \\ n: \text{número de objetos} \end{matrix}$$

- √ Matriz:
 - Organização em arranjo estrutural de dados multivariados (métricos ou não métricos)
- √ Colunas: variáveis (características medidas de objetos)
- √ Linhas: objetos (lista de características medidas de um objeto)

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

9

Classificação e Agrupamento

- Classificar:
 - √ Número de grupos é conhecido e o objetivo é alocar novas observações a um desses grupos
- Agrupar:
 - √ Não há suposições sobre o número de grupos ou sobre a estrutura dos grupos
 - Técnica mais primitiva

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

10

Análise de Agrupamento e Análise Discriminante

- Análise de Agrupamentos
 - √ Dividir os elementos da amostra (ou população) em grupos, de maneira que:
 - Elementos de um grupo são similares entre si
 - Elementos de grupos diferentes sejam heterogêneos em relação a essas características

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

11

- Análise discriminante:
 - √ Classificação de elementos de amostra (população)
 - Grupos são pré-definidos
 - √ Procedimento:
 - Regra de classificação

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

12

Discriminação e Classificação para Duas Populações

Objetivo

1. Separar duas classes de objetos
 2. Atribuir um novo objeto a uma das duas classes
- Classes:
 - √ π_1 e π_2
 - Objetos:
 - √ São separados ordinariamente ou classificados com base em medidas de p variáveis aleatórias associadas

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

14

Conceitos

- **Classes:**
 - √ π_1 e π_2
- **Objetos:**
 - √ São separados ordinariamente ou classificados com base em medidas de p variáveis aleatórias associadas

$$\mathbf{X}' = [X_1, X_2, \dots, X_p].$$
- **Hipótese:**
 - √ Os valores observados de \mathbf{X} diferem em alguma quantidade de uma classe a outra

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

15

- **Populações das duas classes:**
 - √ Podem ser descritas por suas funções de densidade $[f_1(\mathbf{x})$ e $f_2(\mathbf{x})]$
 - √ Pode-se falar em atribuir:
 - Observações a populações ou
 - Objetos a classes

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

16

Exemplos

Populações π_1 e π_2	Variáveis \mathbf{X}
Risco de crédito alto/baixo	Renda, Idade, nº de cartões de crédito, tamanho família
Duas espécies de flor	Comprimento e largura de pétalas e sépalas, diâmetro do pólen, etc.
Masculino e feminino	Medidas antropológicas tais como: circunferência e volume de crânios antigos
Seleção a curso de pós-graduação	Histórico escolar, curriculum vitae, cartas de referência, experiência profissional

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

17

- **Outros Exemplos:**
 - √ **Agricultura:**
 - Identificar áreas de maior potencial para plantação de determinadas sementes
 - √ **Marketing:**
 - Identificar mercados potenciais e não potenciais para determinados produtos e serviços
 - √ **Esporte:**
 - Identificação de atletas promissores para cada modalidade
 - √ **Estudos de criminalidade:**
 - Identificação de regiões que necessitam de política de segurança diferenciada

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

18

Regras de Alocação e Classificação

- Em geral, são desenvolvidas de amostras de treinamento:
 - √ Examinadas diferenças das medidas características de objetos selecionados
 - √ O conjunto de todos os resultados amostrais possíveis são dividido em duas regiões (R_1 e R_2)
 - Se uma nova observação pertencer à região R_1 ela é alocada à população π_1 .
 - Se uma nova observação pertencer à região R_2 ela é alocada à população π_2 .

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

19

Problema da Classificação

- Como saber se algumas observações pertencem a uma particular população?
 - √ Incerteza na classificação

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

20

Paradoxo da Classificação

- Conhecimento incompleto de desempenho futuro:
 - √ Classificação de candidato como capaz de concluir ou não um mestrado
- Informação perfeita exige destruição objeto:
 - √ Classificação de itens como bons ou defeituosos
- Informação cara ou indisponível:
 - √ Problemas médicos que podem ser identificados conclusivamente apenas com cirurgia cara

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

21

Erros de Classificação

- Caso médico:
 - √ Em geral, deseja-se diagnosticar um mal a partir de sintomas externos facilmente observáveis
- Erro de classificação:
 - √ Pode não ser clara a distinção entre as características medidas das duas populações.

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

22

Exemplo

- Discriminação de proprietários e não-proprietários de cortador de grama

√ X_1 : renda

√ X_2 : tamanho do lote




Semana da Estatística/UFJF - 2016

Discriminação e Classificação

23

- Proprietários e não proprietários: Renda e tamanho lote



- Proprietários tendem a ter rendas e lotes maiores

- Renda aparenta discriminar melhor que tamanho do lote

- Há uma certa sobreposição entre os dois grupos

√ Erros de classificação

Ideia:
Criar regra que minimize a chance de erros de classificação

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

24

Crítérios para Classificação

- Bom procedimento de classificação:

√ Poucos erros de classificação

- Regra ótima deveria considerar estas probabilidades a priori

√ Pode ser que uma classe (ou população) tenha uma verossimilhança de ocorrência maior que outra

√ Uma das classes é relativamente maior que a outra

√ Ex.:

– Há muito mais empresas solventes que insolventes

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

25

- Outro aspecto a considerar:

√ Custo associado ao erro de classificação

√ Ex.:

– Classificar um objeto π_1 como π_2 é mais sério que classificar um objeto π_2 como π_1 .

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

26

Caso de Classificação de Duas Populações Normais Multivariadas

Classificação em Duas Populações

- Supondo disponíveis:
 - √ Conjunto de observações independentes de duas populações π_1 e π_2
 - √ Distribuições de probabilidades do vetor X , associadas às populações π_1 e π_2 .
- Regra de classificação que minimize a chance de se classificar incorretamente elemento amostral:
 - √ Princípio da máxima verossimilhança

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

29

Exemplo

- Processo de seleção de alunos:
 - √ Fase 1: todos fazem várias provas
 - √ Fase 2: apenas aprovados na fase 1
- Populações:
 - √ População 1:
 - Alunos que passaram na 1ª. Fase, mas reprovados na 2ª
 - √ População 2:
 - Alunos aprovados em ambas as fases

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

30

Exemplo

- Objetivo:
 - √ A partir dos dados, construir uma regra de classificação que permita identificar, dentre os aprovados na 1ª. Fase, quais provavelmente serão aprovados na 2ª Fase
- Considere apenas a variável aleatória nota na prova de Matemática dos candidatos na fase 1

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

31

Exemplo

- Considere apenas a variável aleatória nota na prova de Matemática dos candidatos na fase 1
- Suponha que X tenha uma distribuição normal
 - √ População 1: média μ_1 .
 - √ População 2: média μ_2
 - √ Ambas populações como o mesmo desvio padrão σ .

Semana da Estatística/UFJF - 2016 32
Discriminação e Classificação

Exemplo


- Razão de verossimilhança entre as 2 populações

$$\lambda(x) = \frac{f_1(x)}{f_2(x)} = \frac{\frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu_1}{\sigma}\right)^2\right\}}{\frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu_2}{\sigma}\right)^2\right\}}$$


$$= \exp\left\{-\frac{1}{2}\left[\left(\frac{x-\mu_1}{\sigma}\right)^2 - \left(\frac{x-\mu_2}{\sigma}\right)^2\right]\right\}$$
- Para uma nota fixa x:
 - √ $\lambda(x) > 1$: razoável classificar candidato em π_1 (não aprovado da Fase 2)
 - √ $\lambda(x) < 1$: provável aprovado Fase 2 (π_2)
 - √ $\lambda(x) = 1$: candidato poderia ser classificado em π_2 ou π_2
 - Obter informações adicionais sobre o candidato

Semana da Estatística/UFJF - 2016 33
Discriminação e Classificação


- Classificação de 2 populações normais, com mesma variabilidade




Valores de X
Gráfico a: nenhuma intersecção



Valores de X
Gráfico b: pouca intersecção



Valores de X
Gráfico c: intersecção moderada



Valores de X
Gráfico d: grande intersecção

Fonte: Mingoti

Semana da Estatística/UFJF - 2016 34
Discriminação e Classificação

Qualidade da discriminação depende do grau de intersecção

- √ (a): número de classificações incorretas é 0
- √ (b): pequeno número de erros de classificação
- √ (c) e (d): número de erros de classificação tende a aumentar
- √ Intersecção pode chegar a valores que inviabiliza o uso da função discriminante como regra de classificação

Função Discriminante

$$\lambda(x) = \exp\left\{-\frac{1}{2}\left[\left(\frac{x-\mu_1}{\sigma}\right)^2 - \left(\frac{x-\mu_2}{\sigma}\right)^2\right]\right\}$$

$$-2 \ln(\lambda(x)) = \left(\frac{x-\mu_1}{\sigma}\right)^2 - \left(\frac{x-\mu_2}{\sigma}\right)^2$$

$$= \frac{1}{\sigma^2} [(x-\mu_1)^2 - (x-\mu_2)^2]$$

- √ Relacionada com a diferença das distância euclidiana ponderadas ao quadrado
- √ $\lambda(x) > 1 \rightarrow -2 \ln(\lambda(x)) < 0$: x está mais próximo de μ_1 .
- √ $\lambda(x) < 1 \rightarrow -2 \ln(\lambda(x)) > 0$: x está mais próximo de μ_2 .

Semana da Estatística/UFJF - 2016 35
Discriminação e Classificação

• Regra de classificação:

- √ Se $-2\ln(\lambda(x)) < 0$, classifique o elemento amostral em π_1
- √ Se $-2\ln(\lambda(x)) > 0$, classifique o elemento amostral em π_2 .
- √ Se $-2\ln(\lambda(x)) = 0$, o elemento amostral poderá ser classificado tanto em π_1 como π_2 .

Populações com Variâncias Diferentes

• Função discriminante:

$$\lambda(x) = \frac{f_1(x)}{f_2(x)} = \frac{\frac{1}{\sqrt{2\pi}\sigma_1} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu_1}{\sigma_1}\right)^2\right\}}{\frac{1}{\sqrt{2\pi}\sigma_2} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu_2}{\sigma_2}\right)^2\right\}}$$

$$= \frac{\sigma_2}{\sigma_1} \exp\left\{-\frac{1}{2}\left[\left(\frac{x-\mu_1}{\sigma_1}\right)^2 - \left(\frac{x-\mu_2}{\sigma_2}\right)^2\right]\right\}$$

√ e, considerando $-2 \ln(\lambda(x))$:

$$-2 \ln(\lambda(x)) = -2 \ln\left(\frac{\sigma_2}{\sigma_1}\right) + \left[\left(\frac{x-\mu_1}{\sigma_1}\right)^2 - \left(\frac{x-\mu_2}{\sigma_2}\right)^2\right].$$

• Com mesma regra de classificação

Populações Multivariadas – Caso $\Sigma_1 \neq \Sigma_2$

- Populações normais multivariadas, com vetor de médios μ_i e matriz de covariâncias Σ_i , $i = 1, 2$.
- Função discriminante:

$$-2 \ln(\lambda(x)) = -2 \ln \left\{ \frac{(2\pi)^{\frac{p}{2}} |\Sigma_1|^{-\frac{1}{2}} \left[\exp\left\{-\frac{1}{2}(x-\mu_1)'\Sigma_1^{-1}(x-\mu_1)\right\} \right]}{(2\pi)^{\frac{p}{2}} |\Sigma_2|^{-\frac{1}{2}} \left[\exp\left\{-\frac{1}{2}(x-\mu_2)'\Sigma_2^{-1}(x-\mu_2)\right\} \right]} \right\}$$

$$= [(x-\mu_1)'\Sigma_1^{-1}(x-\mu_1) - (x-\mu_2)'\Sigma_2^{-1}(x-\mu_2)] + [\ln |\Sigma_1| - \ln |\Sigma_2|]$$

√ para um vetor de observações: $\mathbf{x}' = (x_1, x_2, \dots, x_p)$.

- Com mesma regra de classificação

• Função discriminante quadrática

$$[(x-\mu_1)'\Sigma_1^{-1}(x-\mu_1) - (x-\mu_2)'\Sigma_2^{-1}(x-\mu_2)] + [\ln |\Sigma_1| - \ln |\Sigma_2|]$$

√ Depende das distâncias de Mahalanobis do vetor \mathbf{x} aos vetores de médias μ_1 e μ_2

√ Fator de correção relacionando as variâncias generalizadas das duas populações

- Quando $\Sigma_1 = \Sigma_2 = \Sigma$

$$-2 \ln(\lambda(\mathbf{x})) = [(\mathbf{x} - \boldsymbol{\mu}_1)' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}_1) - (\mathbf{x} - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}_2)]$$

√ Pode ser reescrita como

$$-2 \ln(\lambda(\mathbf{x})) = -2 \left[(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} \mathbf{x} - \frac{1}{2} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2) \right].$$

Função Discriminante de Fisher

$$f_d(\mathbf{x}) = \ln(\lambda(\mathbf{x})) = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} \mathbf{x} - \frac{1}{2} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2).$$

- Regra de classificação:

√ \mathbf{x} é classificado à π_1 se $f_d(\mathbf{x}) > 0$ ou seja, se

$$(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} \mathbf{x} > \frac{1}{2} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2).$$

√ \mathbf{x} é classificado à π_2 se $f_d(\mathbf{x}) < 0$ ou seja, se

$$(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} \mathbf{x} < \frac{1}{2} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2).$$

- A função discriminante de Fisher tem a forma

$$(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} \mathbf{x} = \mathbf{b}' \mathbf{x} = b_1 X_1 + b_2 X_2 + \dots + b_p X_p.$$


√ Dependendo do valor numérico desta combinação, o elemento amostral é classificado em uma ou outra população

- Constante de delimitação da região de classificação

$$\frac{1}{2} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2) = \mathbf{b}' \frac{(\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2)}{2}.$$

√ Combinação linear dos vetores de médias das populações

- Discriminação de duas populações normais:



√ Os valores observados das combinações lineares $\mathbf{b}' \mathbf{X}$ na população π_1 são os mais separados possíveis daqueles observados da população π_2 .

Padronização

- O vetor **b** é único $b' = (\mu_1 - \mu_2)' \Sigma^{-1}$.
 - √ Exceto para multiplicações de todos seus componentes pela mesma constante c.
- É recomendável que os componentes do vetor **b** sejam padronizados ou normalizados, como em:
$$b^* = \frac{b}{\sqrt{b'b}}$$
 - √ Componentes de **b*** estarão no intervalo [-1, 1]
 - √ É possível comparar os loadings de f_{dn}

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

48

- Mesclar com Scaling – Johnson, pág. 589/590

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

49

Custos

- Regra de discriminação pelo princípio da máxima verossimilhança minimiza as probabilidades de erros de classificações
 - √ Máxima separação entre as combinações lineares
- Não leva em consideração possíveis diferenças entre os custos associados aos erros de classificação

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

51

Mistura de Duas Normais Multivariadas

- Suponha:
 - √ 2 populações normais p-variadas com vetor de médias μ_i , $i = 1, 2$
 - √ Probabilidades de mistura p_j , $j=1, 2$
 - Probabilidade de que uma observação escolhida ao acaso pertença à π_j , $j=1, 2$.
 - √ Função de densidade de π_j . $f(x|\pi_j) = f(x|(\mu_j, \Sigma))$.

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

53

√ Dada uma observação \mathbf{x} , qual a melhor maneira de distinguir de qual das duas populações ela foi amostrada?
 $f(\mathbf{x} \text{ amostrada de } \pi_j) = p_j f(\mathbf{x} | (\boldsymbol{\mu}_j, \boldsymbol{\Sigma}))$.

√ Densidade de \mathbf{x} oriunda de uma população não especificada:
 $f(\mathbf{x}) = p_1 f(\mathbf{x} | (\boldsymbol{\mu}_1, \boldsymbol{\Sigma})) + p_2 f(\mathbf{x} | (\boldsymbol{\mu}_2, \boldsymbol{\Sigma}))$.

√ Densidade posterior de \mathbf{x} de amostras da população j para uma dada observação \mathbf{x}
 $f(\pi_j | \mathbf{x}) = \frac{p_j f(\mathbf{x} | (\boldsymbol{\mu}_j, \boldsymbol{\Sigma}))}{p_1 f(\mathbf{x} | (\boldsymbol{\mu}_1, \boldsymbol{\Sigma})) + p_2 f(\mathbf{x} | (\boldsymbol{\mu}_2, \boldsymbol{\Sigma}))}$.

Expressão básica para estimar a população da qual a observação \mathbf{x} foi amostrada

Semana da Estatística/UFJF - 2016 Discriminação e Classificação 55

- Função discriminante de Fisher:


$$f_d(\mathbf{x}) = \ln \left(\frac{p_1}{p_2} \right) - \underbrace{\frac{1}{2}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 + \boldsymbol{\mu}_2)}_{\text{constante}} + (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} \mathbf{x}$$
- Limite entre as populações π_1 e π_2 .
 $f_d(\mathbf{x}) = \text{constante} + (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} \mathbf{x} = 0$

Semana da Estatística/UFJF - 2016 Discriminação e Classificação 57

Exemplo

- Mistura de normais bivariadas com mesma estrutura de variabilidade:

$$\boldsymbol{\Sigma} = \begin{bmatrix} 1 & -0,4 \\ -0,4 & 1,2 \end{bmatrix}$$
- √ π_1 : $p_1 = 0,6$ e $\boldsymbol{\mu}_1 = (-1, -1)'$.
- √ π_2 : $p_2 = 0,4$ e $\boldsymbol{\mu}_2 = (1, 1)'$.



Semana da Estatística/UFJF - 2016 Discriminação e Classificação 58

- Função discriminante:

$$(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}^{-1} \mathbf{x} = [-1 -1 \quad -1 -1] \begin{bmatrix} 1 & -0,4 \\ -0,4 & 1,2 \end{bmatrix}^{-1} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

$$= [-3,0769 \quad -2,6923] \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

$$= -3,0769x_1 - 2,6923x_2$$
- Constante de delimitação:

$$\text{cte} = \ln \left(\frac{0,6}{0,4} \right) - \frac{1}{2} \left([-1 -1 \quad -1 -1] \begin{bmatrix} 1 & -0,4 \\ -0,4 & 1,2 \end{bmatrix}^{-1} \begin{bmatrix} -1 + 1 \\ -1 + 1 \end{bmatrix} \right)$$


$$= 0,40546$$
- Fronteira

$$-3,0769x_1 - 2,6923x_2 = 0,40546$$

$$x_2 = 0,1506 - 1,1428x_1$$

Semana da Estatística/UFJF - 2016 Discriminação e Classificação 59

- Fronteira entre as duas populações



√ Linha divisória discriminando as duas populações

Estimação da Regra de Classificação

- Na prática, μ_1 , μ_2 , Σ_1 e Σ_2 não são conhecidos
- Caso 1: $\Sigma_1 = \Sigma_2 = \Sigma$

√ Σ é estimada por S : $S_{pol} = \frac{(n_1 - 1)S_1 + (n_2 - 1)S_2}{n_1 + n_2 - 2}.$

√ Função discriminante de Fisher estimada por:

$$\hat{f}_d(\mathbf{x}) = (\bar{\mathbf{x}}_1 - \bar{\mathbf{x}}_2)' S_{pol}^{-1} \mathbf{x} - \frac{1}{2} (\bar{\mathbf{x}}_1 - \bar{\mathbf{x}}_2)' S_{pol}^{-1} (\bar{\mathbf{x}}_1 + \bar{\mathbf{x}}_2).$$

- Caso 2: $\Sigma_1 \neq \Sigma_2.$

√ Função discriminante quadrática estimada por:

$$-2 \ln(\hat{\lambda}(\mathbf{x})) = [(\mathbf{x} - \bar{\mathbf{x}}_1)' S_1^{-1} (\mathbf{x} - \bar{\mathbf{x}}_1) - (\mathbf{x} - \bar{\mathbf{x}}_2)' S_2^{-1} (\mathbf{x} - \bar{\mathbf{x}}_2)] + [\ln |S_1| - \ln |S_2|]$$

√ Considera os sistemas de variabilidade das duas populações separadamente.

Estrutura de Variabilidades das Populações

- Testes de hipóteses para decidir se as matrizes Σ_1 e Σ_2 são iguais ou diferentes
- Alternativa prática:
 - √ Ajuste aos dados dos dois modelos: linear de Fisher e quadrático
 - √ Escolhe-se o modelo que resultar em menores proporções de erros de classificação
 - √ Caso os resultados sejam semelhantes, opta-se pelo modelo linear
 - Matriz de covariâncias estimada com mais observações

Exemplo

- Detecção de portadoras de hemofilia A
 - √ Grupo 1: mulheres que não têm o gene da hemofilia
 - Grupo normal ($n_1 = 30$)
 - √ Grupo 2: mulheres portadoras do gene da hemofilia
 - Filhas de hemofílicos, mães com mais de um filho hemofílico e outros parentes hemofílicos ($n_2 = 45$)
- √ Variáveis:
 - V_1 : grupos
 - V_2 : log(atividade AHF)
 - V_3 : log(antígeno AHF)

Semana da Estatística/UFJF - 2016 66
Discriminação e Classificação

- Análise descritiva do conjunto de dados:

anticorpo

antigeno

```

> t(centroide)
      [,1]      [,2]
V2 -0.13487000 -0.307946667
V3 -0.07785667 -0.005991111

> sigma.pol
      V2      V3
V2 0.02263709 0.0154313
V3 0.01543130 0.0216058
    
```

Semana da Estatística/UFJF - 2016 67
Discriminação e Classificação

- *Contour plot* por grupo

- √ Curvas contendo 50% e 95% de probabilidade para normais bvariadas centradas em \bar{x}_1 e \bar{x}_2 .
- √ Normal bvariada aparenta se ajustar bem aos dados

Semana da Estatística/UFJF - 2016 68
Discriminação e Classificação

- Função discriminante de Fisher

```

>> ajuste.ad = lda(dados, grupo)
> ajuste.ad
Call:
lda(dados, grupo)


Prior probabilities of groups:
 1  2
0.4 0.6

Group means:
      V2      V3
1 -0.13487000 -0.077856667
2 -0.3079467 -0.005991111

Coefficients of linear discriminants:
      LD1
V2 -9.032787
V3  8.006605
    
```

Semana da Estatística/UFJF - 2016 70
Discriminação e Classificação


- Gráfico da função discriminante



Semana da Estatística/UFJF - 2016

Discriminação e Classificação

71





Semana da Estatística/UFJF - 2016

Discriminação e Classificação

72

- Grupos ajustados



Semana da Estatística/UFJF - 2016

Discriminação e Classificação

73

- Predição:

✓ Mulher com $V1 = -0,210$ e $V2 = -0,044$

```
> predict(ajuste.ad, newdata = c(-0.210, -0.044))$class
[1] 2
Levels: 1 2
```

✓ Mulher pode ser portadora de hemofilia

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

75

Avaliação das Funções de Classificação

Erros de Classificação

- Erros a serem avaliados:
 - √ Erro 1: Elemento amostral pertence a π_1 , mas é classificado em π_2 .
 - √ Erro 2: Elemento amostral pertence a π_2 , mas é classificado em π_1 .
- Notação:
 - √ $P(\text{Erro 1}) = p(2|1)$
 - √ $P(\text{Erro 2}) = p(1|2)$
- Quanto menores essas probabilidades, melhor será a função de discriminação

Semana da Estatística/UFJF - 2016 Discriminação e Classificação 80

Procedimentos de Estimação dos Erros de Classificação

1. Método da Ressubstituição:
 - √ Calculado o escore de cada elemento amostral
 - √ Calculada a frequência das classificações corretas e incorretas
 - √ Estimação da regra de classificação e dos erros de classificação com os mesmos elementos

Semana da Estatística/UFJF - 2016 Discriminação e Classificação 81

- Tabela de frequência de classificação:

		Classificação		Total
		π_1	π_2	
Origem	π_1	n_{11}	n_{12}	n_1
	π_2	n_{21}	n_{22}	n_2

- √ Estimativa das probabilidades de erros de classificação:

$$\hat{p}(2|1) = \frac{n_{12}}{n_1}$$

$$\hat{p}(1|2) = \frac{n_{21}}{n_2}$$

Semana da Estatística/UFJF - 2016 Discriminação e Classificação 82

Comentários

- Também denominado de estimação do erro aparente de classificação (APER)
- Procedimento consistente, mas viciado
 - √ Vício tende a zero para n_1 e n_2 grandes
 - √ Tende a subestimar os verdadeiros valores de $p(1|2)$ e $p(2|1)$ para elementos que não pertencem à amostra conjunta $n = n_1 + n_2$.
 - √ Pode servir como etapa inicial de avaliação
 - Valores elevados indica a necessidade de reformulação da regra de discriminação

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

83

2. Método de colocação de elementos à parte para classificação (Hold-out validation)

- √ Amostra conjunta é repartida em duas partes
 - Amostra de treinamento: construção da regra de discriminação
 - Amostra de validação: para estimação dos erros de classificação
- √ São selecionados aleatoriamente os elementos amostrais que constituirão cada amostra
- √ Estimação dos erros de classificação da maneira descrita no método de ressubstituição

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

84

Comentários

- Procedimento não é enviesado
- Recomendável:
 - √ Separar de 25% a 50% dos elementos originais para a amostra de validação
- Desvantagem:
 - √ Redução do tamanho da amostra original para estimação da regra de discriminação
 - √ Não pode ser empregado em amostras pequenas
- Para amostras grandes, é melhor que o método 1

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

85

3. Método de validação cruzada (Método de Lachenbruch)

- √ Retira-se um elemento amostral da amostra conjunta e constrói-se a função de discriminação
- √ Utiliza-se a regra de discriminação para classificar o elemento que ficou à parte
- √ Elemento amostral é retornado à amostra e retira-se elemento amostral diferente do anterior, repetindo-se o procedimento.
- Estimação dos erros de classificação:

$$\hat{p}(2|1) = \frac{n_{12}}{n_1}$$
$$\hat{p}(1|2) = \frac{n_{21}}{n_2}$$

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

86

Comentários

- Estimativas são aproximadamente não viciadas
 √ Melhores que o método da ressubstituição para populações normais e não-normais

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

87

Estimação da Probabilidade Global de Acerto

- Estimação da probabilidade global de acerto da função discriminante:

$$\hat{p}(\text{acerto}) = \frac{n_{11} + n_{22}}{n_1 + n_2}.$$

- √ Recomendável estimar as probabilidades de ocorrência dos erros de classificação tipo 1 e 2
 - Possível função discriminante com alta probabilidade de acerto global, mas apresentando alta probabilidade de algum dos erros parciais.

Semana da Estatística/UFJF - 2016


Discriminação e Classificação

88

Exemplo

- Conjunto de dados: Hemofilia

Gráfico da partição



```
> ajuste.ad <- lda(dados, grupo)
> predicao <- predict(ajuste.ad, dados)
> GrupoPrevisto <- predicao$class
> contagem <- table(grupo, GrupoPrevisto)
> diag(prop.table(contagem, 1))
      1      2
0.8666667 0.8444444
> sum(diag(prop.table(contagem)))
[1] 0.85333336058
```

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

92

Construção da Regra de Discriminação: Caso de Várias Populações

Regra de Discriminação para Várias Populações

- Classificar unidades amostrais em $g > 2$ populações
 $\checkmark f_i(x)$: função de densidade π_i , $i = 1, 2, \dots, g$.
- Objetivo:
 \checkmark Construir regra de classificação que minimize as probabilidades de erros de classificação

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

95

Procedimento

- Para um vetor de observações x :
 \checkmark Calcula-se o valor de $f_i(x)$, para cada i .
 \checkmark Classifica-se o elemento amostral na população k correspondente ao maior valor $f_i(x)$.
- No caso de população normal multivariada, corresponde a classificar na população k , tal que:

$$d_k^Q(x) = \max\{d_1^Q(x), d_2^Q(x), \dots, d_g^Q(x)\}$$

- \checkmark Sendo d_i^Q : escore quadrático de discriminação

$$d_i^Q = -\frac{1}{2} \ln(|\Sigma_i|) - \frac{1}{2} (x - \mu_i)' \Sigma_i^{-1} (x - \mu_i)$$

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

96

- Na prática, os escores quadrático de discriminação são estimados por:

$$\hat{d}_i^Q = -\frac{1}{2} \ln(|S_i|) - \frac{1}{2} (x - \bar{x}_i)' S_i^{-1} (x - \bar{x}_i)$$

- Se $\Sigma_1 = \Sigma_2 = \dots = \Sigma_g = \Sigma$, usa-se S_{pol} para estimar \hat{d}_i^Q :

$$S_{pol} = \frac{1}{\sum_{i=1}^g n_i - g} \sum_{i=1}^g (n_i - 1) S_i$$

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

97

Erro de Classificação

- Elemento amostral pertence a π_j , mas a regra de discriminação o classifica em π_k , $j, k = 1, 2, \dots, g$, $j \neq k$.

- Erros estimados por:

$$\hat{p}(k|j) = \frac{n_{jk}}{n_j}$$

- $\checkmark n_{jk}$: número de elementos de π_j classificados em π_k .

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

99

Exemplo


- Cultivares de Vinho: 178 tipos de vinhos
 - √ Class: cultivares de vinho
 - √ Variáveis:
 - Alcohol
 - Malic
 - Ash
 - Alcal
 - Mg
 - Phenol
 - Flav:
 - Nonf
 - Proan
 - Color
 - Hue
 - Abs
 - Proline:

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

102

- Matrix scatter plot:



- Há variáveis que diferem entre os grupos

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

103

- Médias das variáveis por grupo

```
> round(t(aggregate(vinho, list(vinho$Class),
  mean)[,2:14]),2)
      [,1] [,2] [,3]
Class  1.00  2.00  3.00
Alcohol 13.74 12.28 13.15
Malic   2.01  1.93  3.33
Ash     2.46  2.24  2.44
Alcal   17.04 20.24 21.42
Mg      106.34 94.55 99.31
Phenol  2.84  2.26  1.68
Flav    2.98  2.08  0.78
Nonf    0.29  0.36  0.45
Proan   1.90  1.63  1.15
Color   5.53  3.09  7.40
Hue     1.06  1.06  0.68
Abs     3.16  2.79  1.68
```


- Abordagem marginal é intuitiva para identificar médias dos grupos
 - √ Falha em identificar características para discriminar os indivíduos
 - √ Abordagem univariada não considera correlação entre variáveis
- Pode haver combinação de variáveis que fornecem nível mais alto de discriminação

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

104

- Parallel coordinate plot




- Há alguma sobreposição entre grupos

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

105



• Análise discriminante

```

ajuste.ld <- lda(Class~., data = vinho)
ajuste.ld
lda(Class ~ ., data = vinho)
Prior probabilities of groups:
 1      2      3
0.3314607 0.3988764 0.2696629

Group means:
  Alcohol  Malic  Ash  Alcal  Mg  Phenol
1 13.74475 2.010678 2.455593 17.03729 106.3390 2.840169
2  9.823729 0.290000
3 12.27873 1.932676 2.244789 20.23803  94.5493 2.258873
2.0808451 0.363662
3 13.15375 3.333750 2.437083 21.41667  99.3125 1.678750
0.7814583 0.447500

Proan  Color  Hue  Abs  Proline
1 1.899322 5.528305 1.0620339 3.157797 1115.7119
2 1.630282 3.086620 1.0562817 2.785352  519.5070
3 1.153542 7.396250 0.6827083 1.683542  629.8958
    
```

Coefficients of linear discriminants:

	LD1	LD2
Alcohol	-0.403399781	0.8717930699
Malic	0.165254596	0.3053797325
Ash	-0.369075256	2.3458497486
Alcal	0.154797889	-0.1463807654
Mg	-0.002163496	-0.0004627565
Phenol	0.618052068	-0.0322128171
Flav	-1.661191235	-0.4919980543
Nonf	-1.495818440	-1.6309537953
Proan	0.134092628	-0.3070875776
Color	0.355055710	0.2532306865
Hue	-0.818036073	-1.5156344987
Abs	-1.157559376	0.0511839665
Proline	-0.002691206	0.0028529846


Proportion of trace:

	LD1	LD2
	0.6875	0.3125

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

107



Função de Discriminação Logística

Regressão Logística

- Método de regressão para distinguir entre dois grupos diferentes
- Critério de classificação:
 - √ Baseado na probabilidade de indivíduo pertencer a grupo
- Resposta:
 - √ Binária
 - √ Condicionada a vetor de variáveis explicativas \mathbf{x} .
- i -ésima observação: (y_i, \mathbf{x}_i)

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

117

Modelo Logístico

$$\ln \left(\frac{P\{Y = 0|\mathbf{x}\}}{P\{Y = 1|\mathbf{x}\}} \right) = \beta' \mathbf{x}.$$

√ log da chance é função linear das variáveis explicativas

- Probabilidade da resposta

$$P\{Y = 0|\mathbf{x}\} = \frac{\exp\{\beta' \mathbf{x}\}}{1 + \exp\{\beta' \mathbf{x}\}}.$$

√ β pode ser estimado por máxima verossimilhança

√ Interpretação de β :

- Alteração no log da chance para cada variação de uma unidade na variável explicativa

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

118

Generalização do Modelo

- √ Mais de dois grupos
- Abordagem mais comum:
 - √ Selecionar uma categoria como referência , comparando com todos os outros grupos

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

119

- Generalização do modelo para 3 grupos:

$$\ln \left(\frac{P\{\text{Grupo} = 1|\mathbf{x}\}}{P\{\text{Grupo} = 2|\mathbf{x}\}} \right) = \beta'_1 \mathbf{x}.$$

$$\ln \left(\frac{P\{\text{Grupo} = 3|\mathbf{x}\}}{P\{\text{Grupo} = 2|\mathbf{x}\}} \right) = \beta'_3 \mathbf{x}.$$

√ Probabilidades são comparadas separadamente com a da categoria de referência (Grupo = 2), através de seus coeficientes

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

120

Exemplo

- Cultivares de vinho
- Ajuste de modelo logístico multinomial
 - √ Covariáveis:
 - Alcohol, Ash, Alcal, Abs, proline
 - Julga-se que elas conduzirão a um bom ajuste
 - √ Categoria de referência: 2

```
> vinho$grupo <- as.factor(vinho$class)
> vinho$class <- relevel(vinho$grupo, ref = 2)
# define categoria de referencia
```

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

121

• Modelo:

√ $rClass \sim Alcohol + Ash + Alcal + Abs + Proline$:

```
> ajuste.logit <- multinom(rClass ~ Alcohol + Ash + Alcal + Abs + Proline,
+ data = vinho, maxit = 200)
> print(aj.lg <- summary(ajuste.logit), digits = 4)
Call:
multinom(formula = rClass ~ Alcohol + Ash + Alcal + Abs + Proline,
data = vinho, maxit = 200)

Coefficients:
(Intercept) Alcohol Ash Alcal Abs Proline
1 -124.00 6.213 22.849 -3.3478 10.354 0.029388
3 -46.46 2.927 6.192 0.3032 -7.483 0.005955

Std. Errors:
(Intercept) Alcohol Ash Alcal Abs Proline
1 0.1139 1.6304 0.1403 1.0161 0.2612 0.032351
3 0.3558 0.4539 2.8564 0.2566 1.8766 0.003968

Residual Deviance: 26.65138
AIC: 50.65138
```

√ Coeficientes:

- Alteração no log da chance, quando a cada unidade de variação explicativa

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

122

• Teste de significância dos coeficientes:

√ Estatística t e p-valor:

```
> rzaoc.t <- aj.lg$coefficients / aj.lg$standard.errors
> # p-valores da t com q1 = Sedf
> print(2 * (1 - pt(abs(rzaoc.t), df = aj.lg$seof)), digits = 4)
(Intercept) Alcohol Ash Alcal Abs Proline
1 0 2.482e-03 0.00000 0.006404 4.308e-14 0.3816
3 0 3.169e-05 0.05101 0.260270 1.802e-03 0.1592
```

√ Distribuição multinomial ajustada a cada observação

```
> head(aj.lg$fitted.values)
      2      1      3
1 6.405531e-18 1.0000000 2.109756e-21
2 3.942623e-16 1.0000000 1.247350e-20
3 3.273230e-11 1.0000000 2.887328e-12
4 1.979074e-20 1.0000000 8.690855e-21
5 4.198875e-03 0.9944199 1.381191e-03
6 1.013497e-18 1.0000000 9.108334e-18
```

- Cada linha soma 1

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

123

Outros Métodos de Discriminação

Métodos de Discriminação

- Método do vizinho mais próximo
- Classification and Regression Trees – CART
- Support Vector Machine – SVM
- Método dos núcleos estimadores
- Redes neurais artificiais

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

126

Método do Vizinho mais Próximo

- *Nearest neighbor discriminant analysis*
 - √ Não é um método paramétrico
 - Não depende da suposição de normalidade multivariada
- Procedimento de discriminação:
 - √ Encontra-se vizinho mais próximo
 - (distância de Mahalanobis)
 - √ Classifica-se a observação na população do vizinho
- Variação:
 - √ Método dos k vizinhos mais próximos

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

128

Árvores de Regressão e Classificação

- CART(Classification and Regression Trees)
 - √ Trata simultaneamente variáveis contínuas e não contínuas
- Procedimento de classificação:
 - √ Baseado em informações das distribuições isoladas de cada variável
 - √ Resulta numa árvore com vários nós

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

130

Support Vector Machine

- Grupo de algoritmos de classificação, incluem ampla variedade de modelos paramétricos e não paramétricos
 - √ Modelos lineares e métodos de regressão
 - √ Técnicas de suavização por núcleo
- Estimativa de probabilidade de classificação:
 - √ Validação cruzada ou por amostras de treinamento

Semana da Estatística/UFJF - 2016

Discriminação e Classificação

132

Referências

Bibliografia Recomendada

- JOHNSON, R. A.; WINCHERN, D. W. *Applied Multivariate Statistical Analysis*. Prentice Hall, 2007
- MINGOTI, D.C. *Análise de Dados através de Métodos de Estatística Multivariada*. Ed. UFMG, 2005.
- ZELTERMAN, D. *Applied Multivariate Statistics with R*. Springer, 2015.