

Introdução a Métodos Estatísticos para a Bioinformática

Profa. Júlia Maria Pavan Soler
pavan@ime.usp.br

IBI 5086 – Bioinformática - IME/USP
2º Sem/2020

Programa

- Álgebra linear básica: cálculo matricial, determinantes, sistemas lineares, produto interno, norma, ortogonalidade, autovalores e autovetores
 - ✓ Estrutura de Dados: variáveis (resposta, explicativa), unidades amostrais e experimentais
-
- ✓ 1.1. Comparação de 2 ou mais grupos: Testes Clássicos (teste t, Wilcoxon, ANOVA), Testes de Aleatorização, Comparações Múltiplas, Efeitos Genéticos
 - ✓ 1.2. Análise de Tabelas de Contingência: Testes Qui-Quadrado, Regressão Logística.
- 
- 2. **Análise Multivariada de Dados**: Componentes Principais, Análise Discriminante e Classificação, Correlação Canônica, modelos MANOVA
 - 3. Simulação de Monte Carlo, Intervalos de Confiança Bootstrap

Redução de Dimensionalidade em \mathbb{R}^p

Unidades Amostrais	Variáveis					
	1	2	...	j	...	p
1	Y_{11}	Y_{12}		Y_{1j}		Y_{1p}
2	Y_{21}	Y_{22}		Y_{2j}		Y_{2p}
...
i	Y_{i1}	Y_{i2}		Y_{ij}		Y_{ip}
...
n	Y_{n1}	Y_{n2}		Y_{nj}		Y_{np}

$$Y_{n \times p}; \quad n > p \quad \mathbb{R}^p \rightarrow \mathbb{R}^m, m < p$$

Redução de Dimensionalidade \Rightarrow obter m vetores ($m < p$) que são combinações lineares das p variáveis originais e atendem a critérios de otimalidade

$Y_{n \times p}$ p vetores das respostas para n indivíduos \Rightarrow Vetores de **Escores** para os n indivíduos (CP)
 Vetores de **Cargas** (pesos) às p variáveis

Técnicas Multivariadas de Redução de Dimensionalidade

Como obter vetores reducionistas de dados?

Depende:

- Estrutura dos Dados
- Objetivo da análise

✓ Análise de Componentes Principais: $Y_{n \times p} \Rightarrow \mathcal{R}^{p \times p}$

✓ Escalonamento Multidimensional: $Y_{n \times p} \Rightarrow D^{n \times n}$

✓ Análise de Correspondência: $Y_{n \times p} \Rightarrow [0,1]^{I \times J}$

Análises não supervisionadas

▪ Análise Discriminante $Y_{n \times (p+1)} \Rightarrow \mathcal{R}^{p \times p} \Rightarrow \text{MANOVA}$

Análise supervisionada

▪ Análise de Agrupamento: $Y_{n \times p} \Rightarrow D^{n \times n}$

▪ Análise de Correlação Canônica: $Y_{n \times (p+q)} \Rightarrow \mathcal{R}^{p \times q} (\mathcal{R}^{p \times p}, \mathcal{R}^{q \times q})$

Análise Multivariada - Estatísticas Descritivas

Projeto ACTN3 e Força (dados de atletas)

n = 95 p= (5+1)


	Massa	ACTN3	Pré.Força	Pós.Força	Pré.ÁreaVL	Pós.ÁreaVL
1	73.0	1	210	260	27.133	31.398
2	78.0	1	260	320	23.841	26.950
3	70.0	3	220	320	23.755	28.937
...						
94	95.0	2	175	260	25.120	28.605
95	71.0	2	220	330	25.452	29.029

Vetor centróide

Massa	Pré.Força	Pós.Força	Pré.ÁreaVL	Pós.ÁreaVL
75.97	261.79	337.58	25.48	29.13


Matriz de Covariância (superior) e Correlação (inferior)

	Massa	Pré.Força	Pós.Força	Pré.ÁreaVL	Pós.ÁreaVL
Massa	155.24	317.53	303.47	20.80	19.37
Pré.Força	0.40	4032.93	3815.02	70.70	59.41
Pós.Força	0.36	0.88	4640.35	71.05	65.73
Pré.ÁreaVL	0.41	0.27	0.26	16.40	17.10
Pós.ÁreaVL	0.35	0.21	0.22	0.95	19.85




Análise Multivariada – Observações Atípicas

Box-plot bivariado: observações atípicas (p=2)



Distância de Manhattan (p=5)



$$\chi^2(p=5, 90\%) = 9.24$$

Escore Z (Atletas atípicos)

	dm2	Massa	Pré.Força	Pós.Força	Pré.ÁreaVL	Pós.ÁreaVL
82	10.42	2.17	2.81	2.24	2.01	1.80
76	13.25	-0.14	-0.82	0.48	2.08	1.95
51	14.06	0.73	0.76	0.77	0.41	1.48
29	14.16	0.32	-0.03	0.48	-1.03	0.07
34	15.06	3.45	1.07	1.50	2.11	1.60
71	24.54	4.26	0.44	1.36	2.07	2.08

Análise Multivariada – Observações e Variáveis

Projeto ACTN3 e Força

Atletas

1	2	3	4	5	6	7	8	9	10
11	12	13	14	15	16	17	18	19	20
21	22	23	24	25	26	27	28	29	30
31	32	33	34	35	36	37	38	39	40
41	42	43	44	45	46	47	48	49	50
51	52	53	54	55	56	57	58	59	60
61	62	63	64	65	66	67	68	69	70
71	72	73	74	75	76	77	78	79	80
81	82	83	84	85	86	87	88	89	90
91	92	93	94	95					

Variáveis

Massa	Pré.Força	Pós.Força	Pré.AreaVL	Pós.AreaVL
				

Componentes Principais – Coordenadas Principais

Projeto ACTN3 e Força: Análise dos Dados originais (S)

Autovalores (importância dos CP):


	PC1	PC2	PC3	PC4	PC5
Standard deviation	90.4980	22.61788	11.56229	5.36349	0.9289
Proportion of Variance	0.9239	0.05771	0.01508	0.00325	0.0001
Cumulative Proportion	0.9239	0.98158	0.99666	0.99990	1.0000

Autovetores (cargas)

	PC1	PC2	PC3	PC4	PC5
Massa	0.05	0.07	0.97	-0.20	0.01
Pré.Força	0.68	0.73	-0.09	0.00	0.01
Pós.Força	0.73	-0.68	0.01	-0.01	0.00
Pré.ÁreaVL	0.01	0.01	0.14	0.64	-0.75
Pós.ÁreaVL	0.01	0.00	0.14	0.74	0.66

Biplot: representação simultânea dos atletas e das variáveis

As variáveis de Força são as que mais contribuem para a redução de dimensionalidade.



Componentes Principais – Coordenadas Principais

Projeto ACTN3 e Força: Análise dos Dados Normalizados (R)

Autovalores (importância dos CP):


	PC1	PC2	PC3	PC4	PC5
Standard deviation	1.6524	1.1983	0.8173	0.34393	0.21785
Proportion of Variance	0.5461	0.2872	0.1336	0.02366	0.00949
Cumulative Proportion	0.5461	0.8333	0.9668	0.99051	1.00000

Autovetores (cargas)

	PC1	PC2	PC3	PC4	PC5
Massa	0.40	0.02	0.91	-0.05	0.04
Pré.Força	0.45	0.51	-0.18	0.70	0.12
Pós.Força	0.44	0.51	-0.25	-0.69	-0.09
Pré.ÁreaVL	0.48	-0.47	-0.16	0.11	-0.71
Pós.ÁreaVL	0.46	-0.51	-0.22	-0.10	0.69

Biplot: representação dos atletas e das variáveis

Todas as variáveis contribuem para a redução de dimensionalidade




Análise de Correspondência

Representação gráfica das variáveis em uma tabela de contingência


Projeto ACTN3 e Força

Biplot – S Categorização das Variáveis



Distribuição dos atletas

	XX	RX	RR
P11	1	9	9
P12	7	14	4
P21	3	13	8
P22	6	14	7




X-squared=53.04, df=6, p-value=1.151e-09

Análise de Correspondência

Representação gráfica das variáveis em uma tabela de contingência


Projeto ACTN3 e Força

Biplot – R Categorização



Distribuição dos atletas

	XX	RX	RR
P11	6	14	8
P12	4	11	8
P21	3	10	9
P22	4	15	3



X-squared=4.86, df=6, p-value=0.5616

Análise Discriminante

Análise Clássica



$$n > p$$

Observações iid **agrupadas**
(respostas quantitativas)

Técnicas de Redução de Dimensionalidade

Análise Discriminante

Análises Não-Supervisionadas

- ✓ Componentes Principais
- ✓ Coordenadas Principais
- ✓ An. de Correspondência

$$Y_{n \times p}; \quad Y_{i_{p \times 1}} \stackrel{iid}{\sim} (\mu; \Sigma); \quad i = 1, \dots, n$$

$$\mathbb{R}^p \rightarrow \mathbb{R}^m; \quad m < \min(n, p); \quad n > p$$

Análise Discriminante: $Y_{n \times p}; \quad n = \sum_{g=1}^G n_g; \quad Y_{g i_{p \times 1}} \stackrel{iid}{\sim} (\mu_g; \Sigma_g), \quad g = 1, 2, \dots, G$

$$\mathbb{R}^p \rightarrow \mathbb{R}^m; \quad m < p$$

Análise Supervisionada

- Populações Estratificadas (**G grupos**): $G=2$ e $G>2$

⇒ Solução de Fisher

- Solução Probabilística (Regra Discriminante de Bayes)

População Estratificada

τ_1
 τ_2
...
 τ_G

$\Rightarrow Y_i | \tau_g = (Y_{i1}, Y_{i2}, \dots, Y_{ip})' \in \mathfrak{R}^p; \quad g = 1, \dots, G$

$E(Y_i | \tau_1) = \mu_{1(p \times 1)}$
 $E(Y_i | \tau_2) = \mu_{2(p \times 1)}$
...
 $E(Y_i | \tau_G) = \mu_{G(p \times 1)}$

$Cov(Y_i | \tau_1) = \Sigma_{1(p \times p)}$
 $Cov(Y_i | \tau_2) = \Sigma_{2(p \times p)}$
...
 $Cov(Y_i | \tau_G) = \Sigma_{G(p \times p)}$

↓
 n_1

↓
 n_2

↓
 n_G

Amostra

Grupos	Unidades amostrais	Variáveis					
		1	2	...	j	...	p
1	1	Y_{11}	Y_{12}	...	Y_{1j}	...	Y_{1p}
	2	Y_{21}	Y_{22}	...	Y_{2j}	...	Y_{2p}
...
...	i	Y_{i1}	Y_{i2}	...	Y_{ij}	...	Y_{ip}
G
	n	Y_{n1}	Y_{n2}	...	Y_{nj}	...	Y_{np}

Matriz de Dados

$$Y_{n \times p} = \begin{pmatrix} Y_1 \\ \dots \\ Y_G \end{pmatrix}$$

$$Y_{g(n_g \times p)}$$

$$n = \sum_{g=1}^G n_g$$

Objetivos da ANÁLISE DISCRIMINANTE

- Obter Funções Discriminantes das “p” variáveis
 - Redução de dimensionalidade: $\mathfrak{R}^p \rightarrow \mathfrak{R}^m; \quad m \leq \min[n, p, (G-1)]$
 - Classificação de “novas” observações (predição de grupos)

Análise Discriminante - Motivação

Projeto ACTN3 e Força (dados de atletas)

$n = 95$ $p = (5+1)$

	Massa	ACTN3	Pré.Força	Pós.Força	Pré.ÁreaVL	Pós.ÁreaVL
1	73.0	1	210	260	27.133	31.398
2	78.0	1	260	320	23.841	26.950
3	70.0	3	220	320	23.755	28.937
...						
94	95.0	2	175	260	25.120	28.605
95	71.0	2	220	330	25.452	29.029

Atletas agrupados segundo
o genótipo em ACTN3

Obter uma função das variáveis que melhor faça a predição dos Grupos \Rightarrow seleção de variáveis mais discriminatórias.

Análise Discriminante - Motivação

1. Medidas biométricas (mm) de Pardais fêmea

(Manly, 2005; Hermon Bumps, 1898).

Pardal	Sobrev.	X1	X2	X3	X4	X5
1	S	156	245	31.6	18.5	20.5
...	...					
21	S	159	236	31.5	18.0	21.5
22	N	155	240	31.4	18.0	20.7
...	...					
49	N	164	248	32.3	18.8	20.9

Como as características corporais dos pardais pode ser usada para predizer os grupos de Sobreviventes e Não-Sobreviventes?

Análise Discriminante - Motivação

Dados "Iris" do R (Fisher, RA, 1936. The use of multiple measurements in taxonomic problems. *Annals of Eugenics* 7, Part II: 179–188)

Medidas do comprimento e largura da pétala e sépala de 50 flores de íris de cada uma de três espécies (setosa, versicolor e virginica).

$$Y_{150 \times 4} = \begin{pmatrix} Y_{G=1 \ 50 \times 4} \\ Y_{G=2 \ 50 \times 4} \\ Y_{G=3 \ 50 \times 4} \end{pmatrix}$$



	Sepal.Length	Sepal.Width	Petal.Length	Petal.Width	Species
1	5.1	3.5	1.4	0.2	setosa
2	4.9	3.0	1.4	0.2	setosa
3	4.7	3.2	1.3	0.2	setosa
...					
50	5.0	3.3	1.4	0.2	setosa
51	7.0	3.2	4.7	1.4	versicolor
...					
100	5.7	2.8	4.1	1.3	versicolor
101	6.3	3.3	6.0	2.5	virginica
102	5.8	2.7	5.1	1.9	virginica
...					
150	5.9	3.0	5.1	1.8	virginica

Análise Discriminante - Motivação

⇒ Dados do Transcriptoma: A expressão de “genes” pode ser usada para prever (caracterizar) diferentes tecidos tumorais (cancer)?

Irizarry, R.A. and Love, M.I.
Data Analysis for the Life Sciences, 2015.


$$Y_{189 \times 22.215} = \begin{pmatrix} Y_1' \\ \dots \\ Y_{189}' \end{pmatrix} = (Y_{(1)}, \dots, Y_{(22.215)})$$

```
library(devtools)
install_github("genomicsclass/tissuesGeneExpression")

library(tissuesGeneExpression)
data(tissuesGeneExpression)
dim(e) ## e contains the expression data
## [1] 22215 189
p=22.215

table(tissue) ##tissue[i] tells us what tissue is represented by e[,i]
## tissue
## cerebellum colon endometrium hippocampus kidney liver placenta
## 38 34 15 31 39 26 6
n=189
```

Análise Discriminante



Considerando a dispersão das variáveis:


Sepal.Width x Petal.Width

Petal.Length x Petal.Width

Qual seria uma direção “ótima” (função linear) para a discriminação das espécies?

Análise Discriminante

Dados Iris – G=3
Petal.Length x Petal.Width



Dados Iris – G=3
Sepal.Width x Petal.Width





Gráfico de dispersão das observações (em \mathbb{R}^2).


Indique uma direção (terceiro eixo, $l'Y$) que defina uma função discriminante linear de separação dos grupos!

Análise Discriminante

Dados Iris – G=3
Pepal.Length x Petal.Width



Dados Iris – G=3
Sepal.Width x Petal.Width



Indicação de um terceiro eixo, $l'Y$ (em preto), que define uma função discriminante linear de separação entre os grupos.

Como obter essa direção discriminante?

$$Y_i \in \mathcal{R}^p; \quad Y_i = (Y_{i1}, Y_{i2}, \dots, Y_{ip}) \quad \rightarrow \quad X = l' Y_i = l_1 Y_{i1} + l_2 Y_{i2} + \dots + l_p Y_{ip}$$

↑ obter Cargas e os correspondentes Escores

Função Discriminante Linear de Fisher

Formulação de Fisher – Caso de 2 Populações

Considere uma População constituída por observações multivariadas (**quantitativas**) e estratificada em dois subgrupos, tal que:

$$Y_{n \times p} = \begin{bmatrix} Y_{1(n_1 \times p)} \\ Y_{2(n_2 \times p)} \end{bmatrix} \Rightarrow \begin{cases} Y_i \in \mathfrak{R}^p; & E(Y_i | \tau_1) = \mu_{1(p \times 1)} & Cov(Y_i | \tau_1) = \Sigma_{1(p \times p)} \\ & E(Y_i | \tau_2) = \mu_{2(p \times 1)} & Cov(Y_i | \tau_2) = \Sigma_{2(p \times p)} \end{cases}$$

O grupo ao qual a observação pertence é conhecido.

Suposição $\Rightarrow \Sigma_1 = \Sigma_2 = \Sigma$

Matrizes de covariâncias homogêneas

Para G=2: Proposta de Fisher é obter combinações lineares das “p” variáveis que maximizem a distância entre os centróides dos grupos na função discriminante :

$$Y_i \in \mathfrak{R}^p \rightarrow X = l' Y_i; \quad l = \arg \max_{l; l'Y} \frac{(\mu_{X1} - \mu_{X2})^2}{\sigma_X^2} = \arg \max_l \frac{(l' \mu_1 - l' \mu_2)^2}{l' \Sigma l}$$

Solução ao problema de otimização:



$l_{p \times 1} = \Sigma^{-1} (\mu_1 - \mu_2);$

Cargas

$X_i = l' Y_i = (\mu_1 - \mu_2)' \Sigma^{-1} Y_i$

Escores

Função Discriminante Linear de Fisher

Estimação

Suposição: Obs. independentes,
Matriz de covariâncias
homogêneas, prioris iguais.

$$Y_{n \times p} = \begin{bmatrix} Y_{1(n_1 \times p)} \\ Y_{2(n_2 \times p)} \end{bmatrix} \Rightarrow Y_i \in \mathfrak{R}^p \rightarrow X_i = l' Y_i = (\mu_1 - \mu_2)' \Sigma^{-1} Y_i$$

Para dados amostrais: Adotar estimadores “apropriados” de $\hat{\mu}_1, \hat{\mu}_2, \hat{\Sigma}$

\downarrow \downarrow \downarrow
 \bar{Y}_1 \bar{Y}_2 S_c

$$X_i = l' Y_i = (\bar{Y}_1 - \bar{Y}_2)' S_c^{-1} Y_i$$

Função discriminante

$$S_{c_{p \times p}} = \frac{(n_1 - 1) S_1 + (n_2 - 1) S_2}{n_1 + n_2 - 2}$$

Matriz de covariância comum

Regra de Classificação Amostral: Alocação de uma nova observação aos Grupos


$$Y_0 = (Y_{01}, Y_{02}, \dots, Y_{0p})? \rightarrow X_0 = l' Y_0 \begin{cases} X_0 \geq c \Rightarrow Y_0 \in \tau_1 \\ X_0 < c \Rightarrow Y_0 \in \tau_2 \end{cases} \quad c?$$


$$c = \bar{X} = \frac{1}{2} (\bar{X}_1 + \bar{X}_2) = \frac{1}{2} (l' \bar{Y}_1 + l' \bar{Y}_2) = \frac{1}{2} l' (\bar{Y}_1 + \bar{Y}_2) = \frac{1}{2} (\bar{Y}_1 - \bar{Y}_2)' S_c^{-1} (\bar{Y}_1 + \bar{Y}_2)$$

Função Discriminante Linear de Fisher

Critério

Dados hipotéticos: $p=2$, $G=2$





Obter a Função Discriminante Linear de Fisher nos seguintes casos:

G=2: Setosa x Virginica


✓ p=2: Sepal.Length
Sepal.Width

✓ p=2: Petal.Length
Petal.Width

✓ p=4: Sepal.Length
Sepal.Width
Petal.Length
Petal.Width

Dados Iris, $G=2$ (Setosa x Virginica) $p=2$

$$X_i = l'Y_i = (\bar{Y}_1 - \bar{Y}_2)' S_c^{-1} Y_i$$



Cargas da Função discriminante

	Sepal.Length	Sepal.Width
l'	-10.23536	11.64024

Centróides por grupo

	Sepal.Length	Sepal.Width
setosa	5.006	3.428
virginica	6.588	2.974
Dif	-1.582	0.454

Matriz de Covariância: S.setosa

	Sepal.Length	Sepal.Width
Sepal.Length	0.12424898	0.09921633
Sepal.Width	0.09921633	0.14368980

Matriz de Covariância: S.virginica

	Sepal.Length	Sepal.Width
Sepal.Length	0.40434286	0.09376327
Sepal.Width	0.09376327	0.10400408

Matriz de Covariância: S.pooled

	Sepal.Length	Sepal.Width
Sepal.Length	0.2642959	0.0964898
Sepal.Width	0.0964898	0.1238469

$$c = -22.07399$$

Dados Iris, $G=2$ (Setosa x Virginica) $p=2$, $n=150$

$$X_i = l'Y_i = (\bar{Y}_1 - \bar{Y}_2)' S_c^{-1} Y_i$$

$$X_i = -10.23536 * Sepal.Length_i + 11.640 * Sepal.Width_i \begin{cases} \geq -22.07399 \Rightarrow \text{Setosa} \\ < -22.07399 \Rightarrow \text{Virginica} \end{cases}$$

X_i		X_i		X_i		X_i	
1	-11.459508	26	-16.256091	101	-26.069989	126	-36.445839
2	-15.232555	27	-11.599996	102	-27.936452	127	-30.866573
3	-10.857435	28	-12.483044	103	-37.750350	128	-27.514989
4	-10.997923	29	-13.647068	104	-30.726085	129	-32.913645
5	-9.271948	30	-10.857435	105	-31.609133	130	-38.773886
6	-9.874021	31	-13.044995	106	-42.868031	131	-43.149006
7	-7.505851	32	-15.694140	107	-21.052674	132	-36.626448
8	-11.599996	33	-5.498901	108	-40.961446	133	-32.913645
9	-11.278898	34	-7.405485	109	-39.476325	134	-31.890109
10	-14.068531	35	-14.068531	110	-31.789743	135	-32.171084
11	-12.202069	36	-13.928043	111	-29.281086	136	-43.891567
12	-9.552923	37	-15.553652	112	-34.077669	137	-24.905966
13	-14.209019	38	-8.248412	113	-34.679742	138	-29.421573
14	-9.091338	39	-10.114874	114	-29.240964	139	-26.491453
15	-12.804141	40	-12.623532	115	-26.772428	140	-34.539254
16	-7.124510	41	-10.435972	116	-28.257549	141	-32.492182
17	-9.874021	42	-19.286577	117	-31.609133	142	-34.539254
18	-11.459508	43	-7.786826	118	-34.579376	143	-27.936452
19	-14.108653	44	-10.435972	119	-48.547663	144	-32.351694
20	-7.967436	45	-7.967436	120	-35.803644	145	-30.164134
21	-15.694140	46	-14.209019	121	-33.375230	146	-33.656206
22	-9.131460	47	-7.967436	122	-24.725356	147	-35.382180
23	-5.177803	48	-9.833899	123	-46.219615	148	-31.609133
24	-13.787556	49	-11.178532	124	-33.054133	149	-23.882429
25	-9.552923	50	-12.764019	125	-30.164134	150	-25.467916


Matriz de classificação
(ou confusão)

	Predito	
	setosa	virginica
setosa	50	0
virginica	1	49

% de classificação
correta: 100 Setosa
98 Virginica

Dados Iris, $G=2$ (Setosa x Virginica) $p=2$, $n=150$

$$X_i = l'Y_i = (\bar{Y}_1 - \bar{Y}_2)' S_c^{-1} Y_i$$



Centróides por grupos

	Petal.Length	Petal.Width
setosa	1.462	0.246
virginica	5.552	2.026
Dif	-4.090	-1.78

S.setosa

	Petal.Length	Petal.Width
Petal.Length	0.030159184	0.006069388
Petal.Width	0.006069388	0.011106122

S.virginica

	Petal.Length	Petal.Width
Petal.Length	0.30458776	0.04882449
Petal.Width	0.04882449	0.07543265

S.pooled

	Petal.Length	Petal.Width
Petal.Length	0.16737347	0.02744694
Petal.Width	0.02744694	0.04326939

Cargas da Função discriminante

	Petal.Length	Petal.Width
l'	-19.74417	-28.61337

$$c = -101.7476$$

Dados Iris, $G=2$ (Setosa x Virginica) $p=2$

$$X_i = l'Y_i = (\bar{Y}_1 - \bar{Y}_2)' S_c^{-1} Y_i$$

$$X_i = -19.74417 * Petal.Length_i - 28.6133711.640 * Petal.Width_i \begin{cases} \geq -101.7476 \Rightarrow \text{Setosa} \\ < -101.7476 \Rightarrow \text{Virginica} \end{cases}$$

1	-33.36452	26	-37.31335	101	-189.99845	126	-169.96910
2	-33.36452	27	-43.03602	102	-155.06068	127	-146.27609
3	-31.39010	28	-35.33893	103	-176.57869	128	-148.25051
4	-35.33893	29	-33.36452	104	-162.07143	129	-170.65544
5	-33.36452	30	-37.31335	105	-177.46561	130	-160.29759
6	-45.01044	31	-37.31335	106	-190.39961	131	-174.80485
7	-36.22585	32	-41.06161	107	-137.49150	132	-183.58944
8	-35.33893	33	-32.47760	108	-175.89235	133	-173.51677
9	-33.36452	34	-33.36452	109	-166.02026	134	-143.61533
10	-32.47760	35	-35.33893	110	-191.97287	135	-150.62608
11	-35.33893	36	-29.41568	111	-157.92202	136	-186.25020
12	-37.31335	37	-31.39010	112	-159.00951	137	-179.23945
13	-30.50318	38	-30.50318	113	-168.68102	138	-160.09701
14	-24.57993	39	-31.39010	114	-155.94760	139	-146.27609
15	-29.41568	40	-35.33893	115	-169.36736	140	-166.70660
16	-41.06161	41	-34.25143	116	-170.45486	141	-179.23945
17	-37.11277	42	-34.25143	117	-160.09701	142	-166.50603
18	-36.22585	43	-31.39010	118	-195.23536	143	-155.06068
19	-42.14910	44	-48.75870	119	-202.04554	144	-182.30136
20	-38.20027	45	-48.95927	120	-141.64091	145	-184.07520
21	-39.28777	46	-36.22585	121	-178.35253	146	-168.48044
22	-41.06161	47	-37.31335	122	-153.97318	147	-153.08626
23	-25.46685	48	-33.36452	123	-189.51269	148	-159.89643
24	-47.87178	49	-35.33893	124	-148.25051	149	-172.42928
25	-43.23660	50	-33.36452	125	-172.62986	150	-152.19934

Matriz de classificação
(ou confusão)

	Predito	
	setosa	virginica
setosa	50	0
virginica	0	50

100% de
classificação
correta!

Dados Iris, G=2 (Setosa x Virginica) p=4

Centróide dos grupos:

	Sepal.L	Sepal.W	Petal.L	Petal.W
setosa	5.006	3.428	1.462	0.246
virginica	6.588	2.974	5.552	2.026

S. comum

0.264	0.096	0.160	0.030
0.096	0.124	0.042	0.028
0.160	0.042	0.167	0.027
0.030	0.028	0.027	0.043

Cargas do discriminante linear



	LD1
Sepal.L	-1.1338828
Sepal.W	-0.8603685
Petal.L	2.6138926
Petal.W	2.6310427

LD1 ≤ 0 Setosa
 LD1 > 0 Virginica

100% de classificação correta em ambos os grupos!

Escore da função discriminante

	LD1
1	-7.437061
2	-6.780101
3	-6.986787
4	-6.264583
5	-7.409710
6	-6.810997
...	
47	-7.172393
48	-6.612009
49	-7.574522
50	-7.151599
101	9.449657
102	6.601690
103	7.486855
104	6.906517
105	8.168899
106	8.749638
107	5.699715
108	7.602359
...	
148	6.074355
149	7.382464
150	5.967087



Análise de Componentes Principais (Único grupo)

Análise Discriminante G=2 (ou mais grupos)

$$Y_{n \times p} \Rightarrow Z_{n \times m}$$

$$\Sigma = V \Lambda V'$$

$$\Sigma V_j = \lambda_j V_j$$

$$Z_{ji} = V_j' Y_i \quad \text{escore}$$

$$V_j = a; \max_{\|a\|=1} \frac{a' \Sigma a}{a' a}$$

$$\hat{\Sigma} = \frac{1}{n-1} S_T$$

$$= \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})(Y_i - \bar{Y})'$$

$$Z_{n \times m} = Y_{n \times p} V_{p \times m}$$

$$Y_{n \times p}; n = \sum_{g=1}^G n_g; Y_{i \times p} \Rightarrow X_i = l' Y_i$$

$$\max_{l; X=l'Y} \frac{(\mu_{X_1} - \mu_{X_2})^2}{\sigma_X^2};$$


$$\frac{l'(\mu_1 - \mu_2)(\mu_1 - \mu_2)' l}{l' \Sigma l} \leq (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2)$$

$$X_i = l' Y_i = (\bar{Y}_1 - \bar{Y}_2)' S_c^{-1} Y_i$$

escore ↑

$$S_T = S_B + S_W$$

$$S_c = \frac{1}{n-G} S_W$$





Funções Discriminantes de Fisher

Solução de Fisher: $G=2 \rightarrow G>2$

Número de funções discriminantes: $m \leq \min(n, p, G-1)$

Como obter as
funções
discriminantes?



Funções Discriminantes de Fisher

Solução de Fisher para Muitas Populações

$$Y_{n \times p} = \begin{bmatrix} Y_{1(n_1 \times p)} \\ \dots \\ Y_{G(n_G \times p)} \end{bmatrix} \Rightarrow \begin{cases} Y_i \in \mathbb{R}^p; & E(Y_i | \tau_1) = \mu_{1(p \times 1)} \quad \dots \quad E(Y_i | \tau_G) = \mu_{G(p \times 1)} \\ \text{Cov}(Y_i | \tau_g) = \Sigma_g = \Sigma_{(p \times p)}, & g = 1, 2, \dots, G \end{cases}$$

Matriz de covariância homogênea

$$Y_i \in \mathbb{R}^p \rightarrow X_i = l' Y_i;$$

B: Matriz de covariância ENTRE grupos

$$l = \arg \max_{l; X=l'Y} \frac{\sum_{g=1}^G (\mu_{X_g} - \bar{\mu}_X)^2}{\sigma_X^2} \Rightarrow \frac{\sum_{g=1}^G (l' \mu_g - l' \bar{\mu})^2}{\sigma_X^2} = \frac{l' \sum_{g=1}^G (\mu_g - \bar{\mu})(\mu_g - \bar{\mu})' l}{l' \Sigma l} = \frac{l' B l}{l' \Sigma l}$$

\Sigma: Matriz de covariância DENTRO de grupos

As funções discriminantes, $L_{p \times m} = (l_1, \dots, l_m)$, são obtidas a partir dos autovetores da matriz $\Sigma^{-1} B$, restritos a $L' \Sigma L = I$.

$$\Sigma^{-1/2} B \Sigma^{-1/2} = P \Lambda P'; \quad L = \Sigma^{-1/2} P; \quad m \leq \min(n, p, G-1)$$

Matriz simétrica

Funções Discriminantes de Fisher

Método de Fisher para Muitas Populações

- Dados Amostrais: maximizar a função em termos de estimadores apropriados

$$\frac{l' B l}{l' \Sigma l} \Rightarrow \hat{l} = \arg \max_l \frac{l' \hat{B} l}{l' \hat{\Sigma} l} \Rightarrow \hat{L}_{p \times m} = (\hat{l}_1, \dots, \hat{l}_m)$$

Matriz de “Soma de Quadrados e Produtos Cruzados Entre grupos” (SQPC da MANOVA):

$$\hat{B}_{p \times p} = S_B = \sum_{g=1}^G n_g (\bar{Y}_g - \bar{Y})(\bar{Y}_g - \bar{Y})'$$

Matriz de “Quadrado Médio e Produto Cruzado Dentro de grupos” (QMPC da MANOVA):

$$\hat{\Sigma} = S_{c_{p \times p}} = \frac{(n_1 - 1)S_1 + \dots + (n_G - 1)S_G}{n_1 + \dots + n_G - G} = \frac{1}{n - G} \sum_{g=1}^G \sum_{i=1}^{n_g} (Y_{gi} - \bar{Y}_g)(Y_{gi} - \bar{Y}_g)' = \frac{1}{n - G} S_W$$

- Regra de Classificação Amostral:


Alocar a observação Y_0 ($\in \mathbb{R}^p$) à população τ_k em que o valor da função discriminante X_0 ($\in \mathbb{R}^m$) está mais “próxima” de seu centróide



Distância Euclidiana Padronizada

Funções Discriminantes de Fisher

Populações Estratificadas em Muitos Grupos ($G > 2$)



$$m \leq \min(n, p, G - 1)$$

Como realizar a redução dos dados ($p=2$, $G=15$)? Uma única dimensão ($X=l'Y$) é suficiente para uma boa discriminação dos grupos?


Função Discriminante de Fisher

Populações Estratificadas em Muitos Grupos ($G > 2$)

Entendendo a direção discriminante

$$\max_l \frac{l' \hat{B} l}{l' \hat{\Sigma} l}$$

$$m \leq \min(n, p, G - 1)$$



A direção discriminante ótima é aquela que maximiza B (eixo de variação ENTRE grupos) relativamente a Σ (eixo de variação DENTRO de grupos).

Alocar a observação $Y_0 (\in \mathbb{R}^p)$ à população τ_k em que o valor da função discriminante $X_0 (\in \mathbb{R}^m)$ está mais “próxima” de seu centróide

Dados Iris: G=3 e p=4

Probabilidades a priori dos grupos

setosa	versicolor	virginica
0.3333333	0.3333333	0.3333333

Centróides dos grupos

	Sepal.L	Sepal.W	Petal.L	Petal.W
setosa	5.006	3.428	1.462	0.246
versicolor	5.936	2.770	4.260	1.326
virginica	6.588	2.974	5.552	2.026

Cargas das Funções discriminantes

	LD1	LD2
Sepal.L	0.8293776	0.02410215
Sepal.W	1.5344731	2.16452123
Petal.L	-2.2012117	-0.93192121
Petal.W	-2.8104603	2.83918785

Redução de dimensionalidade em
Análise discriminante: $m = \min(n, p, G-1) = 2$

Centróide do espaço discriminante


		LD1	LD2
1	setosa	7.607600	0.2151330
2	versicolor	-1.825049	-0.7278996
3	virginica	-5.782550	0.5127666

X_0 é classificada no grupo ao qual possui menor distância (Euclidiana Padronizada) ao centróide

Matriz de Classificação

	setosa	versicolor	virginica
setosa	50	0	0
versicolor	0	48	2
virginica	0	1	49

	setosa	versicolor	virginica
1.00	0.96	0.98	



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): os mesmos dados são usados para Treinamento e Teste do algoritmo



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}	$\bar{Y}_{1p \times 1}$	$S_{1p \times p}$
	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}	$\bar{Y}_{2p \times 1}$	$S_{2p \times p}$
	2	Y_{221}	Y_{222}	...	Y_{22j}	...	Y_{22p}		
		
	n_2	Y_{2n21}	Y_{2n22}	...	Y_{2n2j}	...	Y_{2n2p}		

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

Na AD a normalização das variáveis é usada com a finalidade de facilitar a interpretação das cargas das variáveis na função discriminante e no cálculo de “c”. O comando “lda” do R adota a “normalização” das variáveis para calcular as funções discriminantes, mas o “linda” 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

Análise Discriminante

✓ Regra Discriminante Linear de Fisher

▪ Métodos Probabilísticos de Análise Discriminante:

Regra de Classificação de Bayes

Regressão Logística

▪ MANOVA: estimar as matrizes de covariância ENTRE (S_B) e DENTRO (S_W) de grupos sob diferentes modelos (ajuste por covariáveis)