

Introdução a Métodos Estatísticos para a Bioinformática

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

IBI 5086 – Bioinformática - IME/USP
2º Sem/2023

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, Coordenadas Principais, Análise de Correspondência, **Análise Discriminante e Classificação**, Análise de Agrupamento, Correlação Canônica, Modelos MANOVA
 - 3. Simulação de Monte Carlo, Intervalos de Confiança Bootstrap

Análise Multivariada → Redução de Dimensionalidade

Unidades Amostras	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 de **p** variáveis, obter **m** novas variáveis ($m < p$)
 (são combinações lineares das **p** variáveis e atendem a critérios de otimalidade)

$Y_{n \times p}$ **p** vetores das respostas para **n** indivíduos \Rightarrow Vetores de **Escore**s 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: $Y_{n \times p} \Rightarrow S_{p \times p}, R_{p \times p}$
- ✓ 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 $Y_{n \times (p+1)} \Rightarrow \mathcal{R}^{p \times p} \Rightarrow$ MANOVA
Regressão logística!

Análise supervisionada


- Análise de Agrupamento: (das n observações)
- Análise de Correlação Canônica: $Y_{n \times (p+q)} \Rightarrow S_{(p+q) \times (p+q)}$

Análises não supervisionadas

Redução de Dimensionalidade

Dados “Iris” do R : Medidas do comprimento e largura da pétala e sépala de 50 flores de íris de três espécies (setosa, versicolor e virginica).

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



Representação dos dados Iris de acordo com os escores dos dois primeiros Componentes Principais (Cp1 e CP2). Indicação das três espécies de flores.

Esta análise discriminou as três espécies?
A construção destes componentes levou em conta a estratificação dos dados?

Análise Discriminante

Análise Clássica



$$n > p$$

P Variáveis quantitativas

Observações independentes

e agrupadas ($G=2$ ou + grupos)

Técnicas de Redução de Dimensionalidade

Análise Discriminante

Análises Não-Supervisionadas

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

$Y_{n \times p}$

Reduzir dimensionalidade dos dados, de “p” para “m”, $m \leq \text{mínimo}(n,p)$

$S_{p \times p}$

CP

$D_{n \times n}$

CoP



Análise Supervisionada de Redução de dimensionalidade

Análise Discriminante:

$Y_{n \times p}$;

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

$g = 1, 2, \dots, G$

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

- **Dados Estratificados (G grupos):** Trataremos de situações com $G=2$ e $G>2$
 - \Rightarrow Solução de Fisher
 - Solução Probabilística (Regra Discriminante de Bayes)

População Estratificada

τ_1	τ_2	...	τ_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 “m” Variáveis Discriminantes das “p” variáveis
 - Redução de dimensionalidade: $\mathbb{R}^p \rightarrow \mathbb{R}^m$; $m \leq \min[n, p, (G-1)]$
 - Classificação de “novas” observações (predição de grupos)

Análise Discriminante - Motivação

Exemplo: Dados do desempenho de atletas.

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

Dados						
	V0	Gene	V1_1	V1_2	V2_1	V2_2
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

Indicação de Grupos Genotípicos:
(dados desbalanceados)

1	2	3	Total
17	50	28	95

Vetor centróide

V0	V1_1	V1_2	V2_1	V2_2
75.97	261.79	337.58	25.48	29.13

Matriz de Covariância (superior) e Correlação (inferior)

	V0	V1_1	V1_2	V2_1	V2_2
V0	155.24	317.53	303.47	20.80	19.37
V1_1	0.40	4032.93	3815.02	70.70	59.41
V1_2	0.36	0.88	4640.35	71.05	65.73
V2_1	0.41	0.27	0.26	16.40	17.10
V2_2	0.35	0.21	0.22	0.95	19.85

Como as observações
estão distribuídas de
acordo com os 3
Grupos genotípicos?

É possível predizer o
grupo genotípico em
função dessas 5
variáveis?

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 prever os grupos de Sobreviventes e Não-Sobreviventes?

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 - Motivação

Dados “Iris” do R: Medidas do comprimento e largura da pétala e sépala de 50 flores de íris de três espécies (setosa, versicolor e virginica).


E os dados Iris, podem ser melhor representados com o objetivo de discriminar as espécies?

Uma flor com as dimensões (4.5, 2.7, 5.0, 0.8) para as variáveis avaliadas, provavelmente pertence a qual espécie?



	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



Considerando a dispersão das variáveis:


Sepal.Width x Petal.Width

Petal.Length x Petal.Width

Qual seria uma “**direção ótima**” para discriminar as espécies?

Análise Discriminante

Dados Iris – G=3
Pepal.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 (uma reta, um terceiro eixo, além de x e y)
que defina uma função discriminante linear de separação dos
grupos!

Análise Discriminante

Dados Iris – G=3
Petal.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?

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

↑ 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 estratificadas em dois grupos, tal que:

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

O grupo ao qual a observação pertence é conhecido.

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

Matrizes de covariâncias homogêneas

Para G=2: A proposta de Fisher é obter combinações lineares, $l' Y_i$, das “p” variáveis que maximizem a distância entre os centróides (projetados) dos grupos:

$$Y_i = (Y_{1i}, Y_{2i}, \dots, Y_{pi}) \rightarrow X_i = l' Y_i = (l_1 Y_{1i} + l_2 Y_{2i} + \dots + l_p Y_{pi})$$

$$l = (l_1, l_2, \dots, l_p)'; \quad \max_l \frac{(l' \mu_1 - l' \mu_2)^2}{l' \Sigma l}$$

Função Discriminante Linear de Fisher

Formulação de Fisher – Caso de 2 Populações

Para G=2: Proposta de Fisher é obter combinações lineares, $l' Y_i$, das “p” variáveis que maximizem a distância entre os centróides (projetados) dos grupos:

$$Y_i = (Y_{1i}, Y_{2i}, \dots, Y_{pi}) \rightarrow X_i = l' Y_i = (l_1 Y_{1i} + l_2 Y_{2i} + \dots + l_p Y_{pi})$$

$$l = (l_1, l_2, \dots, l_p)'; \quad \max_l \frac{(l' \mu_1 - l' \mu_2)^2}{l' \Sigma l}$$

$l' Y_i$ Função discriminante
Como obter o vetor de cargas l ?

Solução ao problema de otimização:

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

$$l = (l_1, l_2, \dots, l_p)'$$

Cargas (das variáveis)

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

$$X = (X_1, X_2, \dots, X_n)'$$

Escore (dos indivíduos)

Função Discriminante Linear de Fisher

Estimação

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

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

Função Discriminante calculada para dados amostrais:

$$\begin{array}{ccc} \hat{\mu}_1, & \hat{\mu}_2, & \hat{\Sigma} \\ \downarrow & \downarrow & \downarrow \\ \bar{Y}_1 & \bar{Y}_2 & S_c \end{array}$$

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

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 aos grupos


Regra de Classificação de Observações: Alocar novas observações a um dos Grupos

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

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

Função Discriminante Linear de Fisher

Critério



Dados hipotéticos:

$$p=2, G=2$$

$$l'Y_i$$

A função discriminante é uma direção na qual os dados serão projetados e os grupos estarão o mais “distante” possível (na comparação entre as medias, em unidades de variância), o que facilitará a predição de uma nova observação.


$$l'Y_i$$

$$l = (l_1, l_2, \dots, l_p) \text{ Cargas}$$

$$Y_0 = (Y_{01}, Y_{02}, \dots, Y_{0p}) \rightarrow X_0 = l'Y_0 \text{ Escores}$$

$$X_0 = l'Y_0 \begin{cases} X_0 \geq c \Rightarrow Y_0 \in \tau_1 \\ X_0 < c \Rightarrow Y_0 \in \tau_2 \end{cases}$$

Regra de Classificação



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

Redução de dimensionalidade: O número máximo de funções discriminantes (de Fisher) que podemos obter é mínimo $(n, p, G-1)$!

Dados Iris, **G=2 (Setosa x Virginica) n=100**

✓ **p=2**: Sepal.Length
Sepal.Width

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



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 S1: S.setosa

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

Matriz de Covariância S2: S.virginica

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

Matriz de Covariância Comum: 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[1:50] x Virginica[101:150])** p=2, n=100

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

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

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) n=100

✓ p=2: Petal.Length
Petal.Width

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



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[1:50] x Virginica[101:150]) p=2

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

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

	X_i
1	-33.36452
2	-33.36452
3	-31.39010
4	-35.33893
5	-33.36452
6	-45.01044
7	-36.22585
8	-35.33893
9	-33.36452
10	-32.47760
11	-35.33893
12	-37.31335
13	-30.50318
14	-24.57993
15	-29.41568
16	-41.06161
17	-37.11277
18	-36.22585
19	-42.14910
20	-38.20027
21	-39.28777
22	-41.06161
23	-25.46685
24	-47.87178
25	-43.23660

	X_i
26	-37.31335
27	-43.03602
28	-35.33893
29	-33.36452
30	-37.31335
31	-37.31335
32	-41.06161
33	-32.47760
34	-33.36452
35	-35.33893
36	-29.41568
37	-31.39010
38	-30.50318
39	-31.39010
40	-35.33893
41	-34.25143
42	-34.25143
43	-31.39010
44	-48.75870
45	-48.95927
46	-36.22585
47	-37.31335
48	-33.36452
49	-35.33893
50	-33.36452

	X_i
101	-189.99845
102	-155.06068
103	-176.57869
104	-162.07143
105	-177.46561
106	-190.39961
107	-137.49150
108	-175.89235
109	-166.02026
110	-191.97287
111	-157.92202
112	-159.00951
113	-168.68102
114	-155.94760
115	-169.36736
116	-170.45486
117	-160.09701
118	-195.23536
119	-202.04554
120	-141.64091
121	-178.35253
122	-153.97318
123	-189.51269
124	-148.25051
125	-172.62986

	X_i
126	-169.96910
127	-146.27609
128	-148.25051
129	-170.65544
130	-160.29759
131	-174.80485
132	-183.58944
133	-173.51677
134	-143.61533
135	-150.62608
136	-186.25020
137	-179.23945
138	-160.09701
139	-146.27609
140	-166.70660
141	-179.23945
142	-166.50603
143	-155.06068
144	-182.30136
145	-184.07520
146	-168.48044
147	-153.08626
148	-159.89643
149	-172.42928
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

$LD1 \leq 0$ Setosa
 > 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 Discriminante - Exemplo

Grupo	Hemofílicos -		Grupo	Hemofílicos +	
	log(AHF ativ)	log(AHF antig)		log(AHF ativ)	log(AHF antig)
1	-0,0056	-0,1657	2	-0,3478	0,1151
1	-0,1698	-0,1585	2	-0,3618	-0,2008
1	-0,3496	-0,1879	2	-0,3618	-0,086
1	-0,0894	0,0064	2	-0,4986	-0,2984
1	2
1	-0,2228	-0,171	2	-0,1744	0,1892
1	-0,0997	-0,0733	2	-0,4055	-0,2418
1	-0,1972	-0,0607	2	-0,2444	0,1614
1	-0,0867	-0,056	2	-0,4784	0,0282


(Johnson and Wichern, 1992, Tabela 11.8)

Objetivo: Obter uma função discriminante para grupos de mulheres que carregam ou não genes da hemofilia com base na atividade da proteína AHF e de seu antígeno.

Com base na função discriminante classifique uma mulher com medidas de AHF iguais a: (-0,11 -0,037)

Análise Discriminante

Exemplo: Dados dos grupos de pacientes Hemofílicos (carregadores do gene) e não Hemofílicos (Normais) .



$$\bar{Y}_1 = \begin{pmatrix} -0.0065 \\ -0.0390 \end{pmatrix} \quad \bar{Y}_2 = \begin{pmatrix} -0.2483 \\ 0.0262 \end{pmatrix}$$

$$S_c^{-1} = \begin{pmatrix} 131.158 & -90.423 \\ -90.423 & 108.147 \end{pmatrix}$$

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

$$X = l'Y = 37.61Y_1 - 28.92Y_2$$

$X_i \geq m \Rightarrow \text{Normais}$

$X_i < m \Rightarrow \text{Hemof.}$

$$\bar{X} = \begin{pmatrix} \bar{X}_1 \\ \bar{X}_2 \end{pmatrix} = \begin{pmatrix} l' \bar{Y}_1 \\ l' \bar{Y}_2 \end{pmatrix} = \begin{pmatrix} 0.88 \\ -10.10 \end{pmatrix} \Rightarrow m = \frac{1}{2} (\bar{X}_1 + \bar{X}_2) = -4.61$$

Análise de Componentes Principais (Único grupo)

Análise Discriminante G=2 (ou mais grupos)

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

$$S = V \Lambda V'$$

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

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

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


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

$$\max_{l; X=l'Y} \frac{(\bar{X}_1 - \bar{X}_2)^2}{l' S_c l}$$

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

escore

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



$$S_T = S_B + S_W$$



Dados estratificados (em grupos): a variabilidade total (S_T) é decomposta nos efeitos Entre (S_B) e Dentro (S_W) dos grupos

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?



“p” pode ser maior que 2!

Análise Discriminante

Método de Fisher para Muitas Populações

- Re-escrevendo o Critério para Duas Populações:

$$\frac{(\mu_{X1} - \mu_{X2})^2}{\sigma_X^2} = \frac{\sum_{g=1}^2 (\mu_{Xg} - \bar{\mu}_X)^2}{\sigma_X^2} = \frac{l' \sum_{g=1}^2 (\mu_g - \bar{\mu})(\mu_g - \bar{\mu})' l}{l' \Sigma l}$$

Maximizar a variabilidade
Entre grupos (numerador)
relativamente à
variabilidade Dentro dos
grupos (Σ)

- 
- Critério para Muitas Populações (estender o somatório para g grupos):

$$\frac{\sum_{g=1}^G (\mu_{Xg} - \bar{\mu}_X)^2}{\sigma_X^2} = \frac{\sum_{g=1}^G (l' \mu_g - l' \bar{\mu})^2}{\sigma_X^2} = \frac{l' \sum_{g=1}^G (\mu_g - \bar{\mu})(\mu_g - \bar{\mu})' l}{l' \Sigma l} = \frac{l' B l}{l' \Sigma l}$$

Funções Discriminantes de Fisher

Solução de Fisher para Muitas Populações

Para G populações: $\mu_1, \mu_2, \dots, \mu_G$
 $\Sigma_1 = \Sigma_2 = \dots = \Sigma_G = \Sigma$

Centróides diferentes
Matrizes de covariância homogêneas

$Y_i \in \mathcal{R}^p \rightarrow X_i = l' Y_i;$ Funções discriminantes

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

**B: Matriz de covariância
ENTRE grupos**

**Σ : Matriz de covariância
DENTRO de grupos**

Neste caso, 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 $L' \Sigma L = I_m$

Funções Discriminantes de Fisher

Método de Fisher para Muitas Populações

■ Dados Amostrais:

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 Produtos Cruzados 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 $Y_o (\in \mathbb{R}^p)$ à população τ_k à qual o valor da função discriminante X_o ($\in \mathbb{R}^m$) está mais “**próxima**” de seu centróide.



Distância Euclidiana Padronizada

Tabela de ANOVA

Já vimos!

→
MANOVA

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_G = \mu \in \mathbb{R} \quad \times \quad H_1 : \exists \text{ pelo menos uma diferença}$$

F.V.	g l	SQ	QM	F	valor-p
ENTRE	G-1	$\sum_g n_g (\bar{y}_g - \bar{y})^2$	SQEntre/(G-1)	QME/QMD	← Efeito de Grupo
DENTRO	n-G	$\sum_{g,i} (y_{ig} - \bar{y}_g)^2$	SQDentro/(n-G)		← Resíduo
TOTAL	n-1	$\sum_{g,i} (y_{ig} - \bar{y})^2$			

$$F = \frac{QMEntre}{QMDentro} \sim F (G-1 , n-G)$$

$$\text{Sob: } Y_{ig} \stackrel{iid}{\sim} N_1(\mu_g; \sigma^2)$$

normalidade
homocedasticidade
independência

Tabela de MANOVA

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_G = \mu$$

Comparar Populações considerando “p” variáveis!


F.V.	g.l.	Matriz de SQPC
Trat	G-1	$B_{p \times p} = \sum_{g=1}^G n_g (\bar{y}_g - \bar{y})(\bar{y}_g - \bar{y})'$ <p>Matriz de Soma de Quadrados e produtos cruzados ENTRE Grupos</p>
Resíduo	n-G	$S_{W \, p \times p} = \sum_{g=1}^G \sum_{i=1}^{n_g} (y_{ig} - \bar{y}_g)(y_{ig} - \bar{y}_g)'$ <p>Matriz de Soma de Quadrados e produtos cruzados DENTRO de Grupos (comum)</p> <p>$\Rightarrow \text{Sc} = \text{Sw}/(\text{n-G})$</p>
TOTAL	n-1	$T = \sum_{g=1}^G n_g (\bar{Y}_g - \bar{Y})(\bar{Y}_g - \bar{Y})'$

$$\Lambda^* = \frac{|S_c|}{|B + S_c|} = |I + S_c^{-1}B|^{-1}$$

Estatística lambda de Wilks para testar H_0 (sob normalidade multivariada, independência e homocedasticidade)

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 a discriminação dos grupos?

Função Discriminante de Fisher


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

Entendendo a direção discriminante

A direção discriminante é obtida dos autovetores da matriz $S_c^{-1} B$

que equivale a:

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



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 $Y_0 (\in \mathcal{R}^p)$ à população τ_k em que o valor da função discriminante $X_0 (\in \mathcal{R}^m)$ 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} V+	n_{1M} F-	n_1
$\tau_2 -$	n_{2M} F+	n_{2c} 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		
	τ_1 +	τ_2 -	
τ_1 +	n_{1c} V+	n_{1M} F-	n_1
τ_2 -	n_{2M} F+	n_{2c} V-	n_2

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

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

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 = $2 \frac{\text{Precisão} * \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}}$

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

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

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

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

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 (já vimos)

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

MANOVA

Uma Aplicação

MANOVA: Delineamento Completamente Aleatorizado com Um Único Fator

	T6	T12	T18	Trat
1	1.48	2.81	3.56	1
2	1.04	2.07	2.81	2
3	1.48	2.52	3.41	1
4	1.04	1.93	2.89	2
5	1.80	2.15	3.20	1
6	1.50	2.70	3.75	2
...				
23	1.80	2.15	3.90	1
24	1.20	2.25	3.30	2
25	1.78	2.96	4.00	3
26	1.48	2.81	3.85	4
27	1.33	2.52	3.84	3
28	1.03	2.07	2.96	4
29	1.65	3.00	3.98	3
30	1.50	2.85	3.75	4
...				
45	1.65	3.00	4.05	3
46	1.20	2.70	3.90	4
47	1.35	2.55	3.67	3
48	1.20	2.70	3.60	4

Considere os seguintes dados de um Delineamento Completamente Aleatorizado com 1 Fator Tratamento em 4 níveis (Trat=1, Trat=2, Trat=3 e Trat=4)

p=3 variáveis (medidas repetidas de O2): T6, T12 e T18

$$Y_{48 \times (3+1)}$$

3 variáveis resposta quantitativas e 1 categórica (identificando grupo)

MANOVA.RM do R

Centróides

	T6	T12	T18
Total (n=48)	1.497500	2.558333	3.664375

Trat	T6	T12	T18
1 (n=9)	1.618333	2.434167	3.526667
2 (n=9)	1.321667	2.430000	3.425000
3 (n=9)	1.655833	2.799167	4.029167
4 (n=9)	1.394167	2.570000	3.676667

Matrizes de Covariância

	T6	T12	T18	Trat
1	1.48	2.81	3.56	1
2	1.04	2.07	2.81	2
3	1.48	2.52	3.41	1
4	1.04	1.93	2.89	2
5	1.80	2.15	3.20	1
6	1.50	2.70	3.75	2
...				
23	1.80	2.15	3.90	1
24	1.20	2.25	3.30	2
25	1.78	2.96	4.00	3
26	1.48	2.81	3.85	4
27	1.33	2.52	3.84	3
28	1.03	2.07	2.96	4
29	1.65	3.00	3.98	3
30	1.50	2.85	3.75	4
...				
45	1.65	3.00	4.05	3
46	1.20	2.70	3.90	4
47	1.35	2.55	3.67	3
48	1.20	2.70	3.60	4

```

Trat=1      T6      T12      T18
T6          0.02   -0.02   0.00
T12        -0.02    0.09   0.00
T18         0.00    0.00   0.08
  
```

```

Trat=2      T6      T12      T18
T6          0.04    0.04   0.04
T12         0.04    0.07   0.06
T18         0.04    0.06   0.11
  
```

```

Trat=3      T6      T12      T18
T6          0.04    0.01   0.05
T12         0.01    0.11   0.01
T18         0.05    0.01   0.07
  
```

```

Trat=4      T6      T12      T18
T6          0.05    0.02   0.06
T12         0.02    0.06   0.05
T18         0.06    0.05   0.12
  
```

```

Sc          T6      T12      T18
T6          0.04    0.01   0.03
T12         0.01    0.08   0.03
T18         0.03    0.03   0.09
  
```

Teste M de Box: teste de homocedasticidade multivariado (testa a homogeneidade das matrizes de covariância)

Chi-Sq=34.61, df = 18, p-value = 0.01058

$\alpha=1\% \Rightarrow$ Não há evidência para a rejeição da hipótese de Homocedasticidade

Atenção à decomposição
imposta à Matriz de Covariância

$$\mathbf{T} = \mathbf{B} + \mathbf{S}_w$$

Tabela de MANOVA:

FV	no.gl	SQPC			
Trat	4-1	SSB	T6	T12	T18
		T6	0.98	0.53	0.98
		T12	0.53	1.08	1.63
		T18	0.98	1.63	2.51
Resíduo	48-4	SSW	T6	T12	T18
		T6	1.67	0.55	1.53
		T12	0.55	3.66	1.24
		T18	1.53	1.24	4.15
Total	48-1	SST	T6	T12	T18
		T6	2.65	1.08	2.51
		T12	1.08	4.74	2.87
		T18	2.51	2.87	6.67

Fonte de
Variação
ENTRE
grupos

Fonte de
Variação
DENTRO
de grupos

	T6	T12	T18	Trat
1	1.48	2.81	3.56	1
2	1.04	2.07	2.81	2
3	1.48	2.52	3.41	1
4	1.04	1.93	2.89	2
5	1.80	2.15	3.20	1
6	1.50	2.70	3.75	2
...				
23	1.80	2.15	3.90	1
24	1.20	2.25	3.30	2
25	1.78	2.96	4.00	3
26	1.48	2.81	3.85	4
27	1.33	2.52	3.84	3
28	1.03	2.07	2.96	4
29	1.65	3.00	3.98	3
30	1.50	2.85	3.75	4
...				
45	1.65	3.00	4.05	3
46	1.20	2.70	3.90	4
47	1.35	2.55	3.67	3
48	1.20	2.70	3.60	4

$$H_0: \mu_g = \mu_{3 \times 1}, \quad g = 1, \dots, 4$$

	Estat.	approxF	numDf	denDf	Pr(>F)	
Pillai	0.7651	5.0206	9	132	8.062e-06	***
Wilks	0.3807	5.5401	9	102.37	3.354e-06	***
Hotel.-Lawley	1.2444	5.6229	9	122	1.742e-06	***
Roy	0.7004	10.273	3	44	3.013e-05	***

Concl.?

Contribuição das
variáveis para a
discriminação dos Trats!

Decomposição Espectral de $Sc^{-1}B$:

Autovalores [,1] [,2] [,3]
 0.7004284 0.5425676 0.001408624

Atovetores
 [,1] [,2] [,3]
 T6 0.01632176 0.94481561 -0.08938875
 T12 -0.20483386 -0.07142574 -0.50725864
 T18 -0.40074216 -0.30089017 0.36425094

Modelo estrutural e distribucional adotado:

$$Y_{ig \ 3 \times 1} = \mu_g + e_{ig}; \quad e_{ig} \sim N_3(\mu_g; \Sigma)$$

$$= \mu + \tau_g + e_{ig}; \quad \sum_{g=1}^4 \tau_g = 0$$

Parametrização
de desvios

$$= \begin{cases} \mu_1 + e_{i1} \\ \mu_1 + \tau_g + e_{ig}; \quad g = 2, 3, 4 \end{cases}$$

Parametrização
casela de referência

Estimativas:


	T6	T12	T18
(Intercept)	1.6183333	2.434166667	3.5266667
Trat=2	-0.2966667	-0.004166667	-0.1016667
Trat=3	0.0375000	0.365000000	0.5025000
Trat=4	-0.2241667	0.135833333	0.1500000

→ $\hat{\mu}_1$

→ $\hat{\tau}_g; \quad g = 2, 3, 4$

Comparações Múltiplas

Intervalos de Confiança de Bonferroni (correção por variável)



		Li	Ls	Conclusão
T6	[2-1]	-0.52	-0.08	$\mu_{21} < \mu_{11}$
	[3-1]	-0.18	0.26	$\mu_{31} = \mu_{11}$
	[4-1]	-0.44	0.00	$\mu_{41} = \mu_{11}$
	[3-2]	0.11	0.55	$\mu_{31} > \mu_{21}$
	[4-2]	-0.15	0.29	$\mu_{41} = \mu_{21}$
	[4-3]	-0.48	-0.04	$\mu_{41} < \mu_{31}$
T12	[2-1]	-0.33	0.32	$\mu_{22} = \mu_{12}$
	[3-1]	0.04	0.69	$\mu_{32} > \mu_{12}$
	[4-1]	-0.19	0.46	$\mu_{42} = \mu_{12}$
	[3-2]	0.04	0.69	$\mu_{32} > \mu_{22}$
	[4-2]	-0.19	0.47	$\mu_{42} = \mu_{22}$
	[4-3]	-0.55	0.10	$\mu_{42} = \mu_{32}$
T18	[2-1]	-0.45	0.24	$\mu_{23} = \mu_{13}$
	[3-1]	0.16	0.85	$\mu_{33} > \mu_{13}$
	[4-1]	-0.20	0.50	$\mu_{43} = \mu_{13}$
	[3-2]	0.26	0.95	$\mu_{33} > \mu_{23}$
	[4-2]	-0.09	0.60	$\mu_{43} = \mu_{23}$
	[4-3]	-0.70	-0.01	$\mu_{43} < \mu_{33}$

$$ICB(\mu_{gj} - \mu_{hj}) \text{ a } (1-\alpha)100\% = (\bar{Y}_{gj} - \bar{Y}_{hj}) \pm t_{n-G}(\alpha/2K) \sqrt{V(\bar{Y}_{gj} - \bar{Y}_{hj})} \left(\frac{1}{n_g} + \frac{1}{n_h} \right) \frac{E_{jj}}{n-G}$$