

ME731 - Métodos em Análise Multivariada – Análise discriminante I –

Prof. Carlos Trucíos
ctrucios@unicamp.br
ctruciosm.github.io

Instituto de Matemática, Estatística e Computação Científica,
Universidade Estadual de Campinas

Aula 21



Agenda I

- 1 Motivação
- 2 Análise Discriminante
- 3 Implementação I
- 4 Erro de classificação
- 5 Análise Discriminante Quadrática

Motivação

Motivação

Suponhas que estamos interessados em algum dos seguintes problemas:

- 1 Saber se devemos ou não dar linha de crédito a um determinado cliente.
- 2 Saber se, segundo um conjunto de características (sintomas) uma pessoa está doente ou não.
- 3 Saber se uma nota de 100 reais (ou obra de arte, produto, etc) é original ou não.

Motivação

Suponhas que estamos interessados em algum dos seguintes problemas:

- 1 Saber se devemos ou não dar linha de crédito a um determinado cliente.
- 2 Saber se, segundo um conjunto de características (sintomas) uma pessoa está doente ou não.
- 3 Saber se uma nota de 100 reais (ou obra de arte, produto, etc) é original ou não.

Como faria as análises?

Análise Discriminante

Análise Discriminante

- Faz parte do conjunto de técnicas dentro do escopo de “Aprendizagem supervisionado” (classificação supervisionada).
- Utilizando um conjunto de variáveis X , vamos a encontrar como discriminar (classificar) y .
- Utilizamos as regras de classificação para classificar novas observações das quais apenas conhecemos X mas não y .

Análise Discriminante

- Sejam P_1 e P_2 , 2 populações nas quais \mathbf{X} , o vetor aleatório p -dimensional, está definido.
- Sejam $f_1(x)$ e $f_2(x)$ as respectivas densidades de \mathbf{X} para cada uma das populações.

Análise Discriminante

- Sejam P_1 e P_2 , 2 populações nas quais \mathbf{X} , o vetor aleatório p -dimensional, está definido.
- Sejam $f_1(x)$ e $f_2(x)$ as respectivas densidades de \mathbf{X} para cada uma das populações.
- Estamos interessados em classificar uma nova observação \mathbf{x}_0 em alguma das populações (P_1 ou P_2).

Análise Discriminante

- Sejam P_1 e P_2 , 2 populações nas quais \mathbf{X} , o vetor aleatório p -dimensional, está definido.
- Sejam $f_1(x)$ e $f_2(x)$ as respectivas densidades de \mathbf{X} para cada uma das populações.
- Estamos interessados em classificar uma nova observação \mathbf{x}_0 em alguma das populações (P_1 ou P_2).
- Sejam π_1 e π_2 as probabilidade iniciais de que um elemento venha de alguma das populações (P_1 ou P_2).

Análise Discriminante

- Sejam P_1 e P_2 , 2 populações nas quais \mathbf{X} , o vetor aleatório p -dimensional, está definido.
- Sejam $f_1(x)$ e $f_2(x)$ as respectivas densidades de \mathbf{X} para cada uma das populações.
- Estamos interessados em classificar uma nova observação \mathbf{x}_0 em alguma das populações (P_1 ou P_2).
- Sejam π_1 e π_2 as probabilidade iniciais de que um elemento venha de alguma das populações (P_1 ou P_2).
- Uma vez observado \mathbf{x}_0 , podemos então calcular a probabilidade condicional de que pertença a P_1 ou P_2 .

Análise Discriminante

$$P(1|x_0) = \frac{P(x_0|1)\pi_1}{P(x_0|1)\pi_1 + P(x_0|2)\pi_2} = \frac{f_1(x_0)\pi_1}{f_1(x_0)\pi_1 + f_2(x_0)\pi_2}$$

Análise Discriminante

$$P(1|x_0) = \frac{P(x_0|1)\pi_1}{P(x_0|1)\pi_1 + P(x_0|2)\pi_2} = \frac{f_1(x_0)\pi_1}{f_1(x_0)\pi_1 + f_2(x_0)\pi_2}$$

$$P(2|x_0) = \frac{P(x_0|2)\pi_2}{P(x_0|1)\pi_1 + P(x_0|2)\pi_2} = \frac{f_2(x_0)\pi_2}{f_1(x_0)\pi_1 + f_2(x_0)\pi_2}$$

Análise Discriminante

$$P(1|x_0) = \frac{P(x_0|1)\pi_1}{P(x_0|1)\pi_1 + P(x_0|2)\pi_2} = \frac{f_1(x_0)\pi_1}{f_1(x_0)\pi_1 + f_2(x_0)\pi_2}$$

$$P(2|x_0) = \frac{P(x_0|2)\pi_2}{P(x_0|1)\pi_1 + P(x_0|2)\pi_2} = \frac{f_2(x_0)\pi_2}{f_1(x_0)\pi_1 + f_2(x_0)\pi_2}$$

Assim, atribuímos x_0 à população com a probabilidade condicional maior:

- Atribuímos x_0 a P_1 se $P(1|x_0) > P(2|x_0)$ ($\equiv \pi_1 f_1(x_0) > \pi_2 f_2(x_0)$).
- Atribuímos x_0 a P_2 se $P(2|x_0) > P(1|x_0)$ ($\equiv \pi_2 f_2(x_0) > \pi_1 f_1(x_0)$).

Análise Discriminante

$$P(1|x_0) = \frac{P(x_0|1)\pi_1}{P(x_0|1)\pi_1 + P(x_0|2)\pi_2} = \frac{f_1(x_0)\pi_1}{f_1(x_0)\pi_1 + f_2(x_0)\pi_2}$$

$$P(2|x_0) = \frac{P(x_0|2)\pi_2}{P(x_0|1)\pi_1 + P(x_0|2)\pi_2} = \frac{f_2(x_0)\pi_2}{f_1(x_0)\pi_1 + f_2(x_0)\pi_2}$$

Assim, atribuímos x_0 à população com a probabilidade condicional maior:

- Atribuímos x_0 a P_1 se $P(1|x_0) > P(2|x_0)$ ($\equiv \pi_1 f_1(x_0) > \pi_2 f_2(x_0)$).
- Atribuímos x_0 a P_2 se $P(2|x_0) > P(1|x_0)$ ($\equiv \pi_2 f_2(x_0) > \pi_1 f_1(x_0)$).

Se $\pi_1 = \pi_2$, então

- Atribuímos x_0 a P_1 se $f_1(x_0) > f_2(x_0)$.
- Atribuímos x_0 a P_2 se $f_2(x_0) > f_1(x_0)$.

Análise Discriminante

Em algumas situações, o custo por classificar em P_2 quando na verdade era P_1 (ou classificar em P_1 quando na verdade era P_2) pode não ser o mesmo. Por exemplo

Análise Discriminante

Em algumas situações, o custo por classificar em P_2 quando na verdade era P_1 (ou classificar em P_1 quando na verdade era P_2) pode não ser o mesmo. Por exemplo



- Suponha que a máquina classifica erroneamente uma nota de R\$. 10 como uma de R\$. 100 e dá o troco ao cliente.
- O custo do erro (para a empresa) é de R\$. 90. Já se acontecer o contrário, o cliente receberá o dinheiro de volta via SAC e o custo será apenas a taxa paga ao funcionário terceirizado do SAC (R\$ 5).

Análise Discriminante

Seja $C(i|j)$ o custo de atribuir uma observação ao grupo i quando na verdade pertence ao grupo j .

Análise Discriminante

Seja $C(i|j)$ o custo de atribuir uma observação ao grupo i quando na verdade pertence ao grupo j . Assim, temos que

	População Correta: P_1	População Correta: P_2
Classificação P_1	0	$C(1 2)$
Classificação P_2	$C(2 1)$	0

Análise Discriminante

Seja $C(i|j)$ o custo de atribuir uma observação ao grupo i quando na verdade pertence ao grupo j . Assim, temos que

	População Correta: P_1	População Correta: P_2
Classificação P_1	0	$C(1 2)$
Classificação P_2	$C(2 1)$	0

- No momento de classificar incluiremos esta informação.
- Então, estamos interessados em classificar de forma que minimizemos o custo esperado.

Análise Discriminante

- O custo esperado de classificar x_0 em P_2 é dado por

$$\mathbb{E}(\text{Custo de classificar em } P_2) = C(2|1)P(1|x_0) + 0P(2|x_0)$$

Análise Discriminante

- O custo esperado de classificar x_0 em P_2 é dado por

$$\mathbb{E}(\text{Custo de classificar em } P_2) = C(2|1)P(1|x_0) + 0P(2|x_0)$$

- O custo esperado de classificar x_0 em P_1 é dado por

$$\mathbb{E}(\text{Custo de classificar em } P_1) = C(1|2)P(2|x_0) + 0P(1|x_0)$$

Análise Discriminante

- O custo esperado de classificar x_0 em P_2 é dado por

$$\mathbb{E}(\text{Custo de classificar em } P_2) = C(2|1)P(1|x_0) + 0P(2|x_0)$$

- O custo esperado de classificar x_0 em P_1 é dado por

$$\mathbb{E}(\text{Custo de classificar em } P_1) = C(1|2)P(2|x_0) + 0P(1|x_0)$$

Assim, atribuímos x_0 a, por exemplo, P_2 se seu custo esperado é menor, *i.e*

$$C(2|1)P(1|x_0) < C(1|2)P(2|x_0),$$

$$\equiv C(2|1)\pi_1 f_1(x_0) < C(1|2)\pi_2 f_2(x_0) \equiv \frac{\pi_1 f_1(x_0)}{C(1|2)} < \frac{\pi_2 f_2(x_0)}{C(2|1)}$$

Análise Discriminante

Regra de decisão

$$x_0 \in P_2 \text{ se } \frac{\pi_1 f_1(x_0)}{C(1|2)} < \frac{\pi_2 f_2(x_0)}{C(2|1)}. \text{ Caso contrário, } x_0 \in P_1.$$

Análise Discriminante

Regra de decisão

$$x_0 \in P_2 \text{ se } \frac{\pi_1 f_1(x_0)}{C(1|2)} < \frac{\pi_2 f_2(x_0)}{C(2|1)}. \text{ Caso contrário, } x_0 \in P_1.$$

Assuma que f_1 e f_2 são as densidades da distribuição normal multivariada p -dimensional e que elas tem a mesma matriz de covariância.

Análise Discriminante

Regra de decisão

$$x_0 \in P_2 \text{ se } \frac{\pi_1 f_1(x_0)}{C(1|2)} < \frac{\pi_2 f_2(x_0)}{C(2|1)}. \text{ Caso contrário, } x_0 \in P_1.$$

Assuma que f_1 e f_2 são as densidades da distribuição normal multivariada p -dimensional e que elas tem a mesma matriz de covariância.

$$f_i(x) = \frac{1}{(2\pi)^{p/2} |\Sigma|^{1/2}} e^{-\frac{1}{2}(x-\mu_i)' \Sigma^{-1} (x-\mu_i)} \quad (1)$$

Análise Discriminante

Regra de decisão

$$x_0 \in P_2 \text{ se } \frac{\pi_1 f_1(x_0)}{C(1|2)} < \frac{\pi_2 f_2(x_0)}{C(2|1)}. \text{ Caso contrário, } x_0 \in P_1.$$

Assuma que f_1 e f_2 são as densidades da distribuição normal multivariada p -dimensional e que elas tem a mesma matriz de covariância.

$$f_i(x) = \frac{1}{(2\pi)^{p/2} |\Sigma|^{1/2}} e^{-\frac{1}{2}(x-\mu_i)'\Sigma^{-1}(x-\mu_i)} \quad (1)$$

Se substituirmos (1) na regra de decisão e aplicarmos logaritmo, temos que

Análise Discriminante

$$\frac{\pi_1 f_1(x_0)}{C(1|2)} < \frac{\pi_2 f_2(x_0)}{C(2|1)}$$

$$\log(f_1(x_0)) + \log(\pi_1/C(1|2)) < \log(f_2(x_0)) + \log(\pi_2/C(2|1))$$

$$-\frac{1}{2}(x_0 - \mu_1)' \Sigma^{-1} (x_0 - \mu_1) + \log\left(\frac{\pi_1}{C(1|2)}\right) < -\frac{1}{2}(x_0 - \mu_2)' \Sigma^{-1} (x_0 - \mu_2) + \log\left(\frac{\pi_2}{C(2|1)}\right)$$

Análise Discriminante

$$\frac{\pi_1 f_1(x_0)}{C(1|2)} < \frac{\pi_2 f_2(x_0)}{C(2|1)}$$

$$\log(f_1(x_0)) + \log(\pi_1/C(1|2)) < \log(f_2(x_0)) + \log(\pi_2/C(2|1))$$

$$-\frac{1}{2}(x_0 - \mu_1)' \Sigma^{-1} (x_0 - \mu_1) + \log\left(\frac{\pi_1}{C(1|2)}\right) < -\frac{1}{2}(x_0 - \mu_2)' \Sigma^{-1} (x_0 - \mu_2) + \log\left(\frac{\pi_2}{C(2|1)}\right)$$

Por definição, a distância de Mahalanobis ao quadrado entre x_0 e média da população i é $D_i^2 = (x_0 - \mu_i)' \Sigma^{-1} (x_0 - \mu_i)$

Análise Discriminante

$$\frac{\pi_1 f_1(x_0)}{C(1|2)} < \frac{\pi_2 f_2(x_0)}{C(2|1)}$$

$$\log(f_1(x_0)) + \log(\pi_1/C(1|2)) < \log(f_2(x_0)) + \log(\pi_2/C(2|1))$$

$$-\frac{1}{2}(x_0 - \mu_1)' \Sigma^{-1} (x_0 - \mu_1) + \log\left(\frac{\pi_1}{C(1|2)}\right) < -\frac{1}{2}(x_0 - \mu_2)' \Sigma^{-1} (x_0 - \mu_2) + \log\left(\frac{\pi_2}{C(2|1)}\right)$$

Por definição, a distância de Mahalanobis ao quadrado entre x_0 e média da população i é $D_i^2 = (x_0 - \mu_i)' \Sigma^{-1} (x_0 - \mu_i)$

$$-\frac{1}{2} \underbrace{(x_0 - \mu_1)' \Sigma^{-1} (x_0 - \mu_1)}_{D_1^2} + \log\left(\frac{\pi_1}{C(1|2)}\right) < -\frac{1}{2} \underbrace{(x_0 - \mu_2)' \Sigma^{-1} (x_0 - \mu_2)}_{D_2^2} + \log\left(\frac{\pi_2}{C(2|1)}\right)$$

Análise Discriminante

Classificamos x_0 em P_2 se

$$\frac{1}{2}D_2^2 - \log\left(\frac{\pi_2}{C(2|1)}\right) < \frac{1}{2}D_1^2 - \log\left(\frac{\pi_1}{C(1|2)}\right)$$

Análise Discriminante

Classificamos x_0 em P_2 se

$$\frac{1}{2}D_2^2 - \log\left(\frac{\pi_2}{C(2|1)}\right) < \frac{1}{2}D_1^2 - \log\left(\frac{\pi_1}{C(1|2)}\right)$$

Note que se $\pi_1 = \pi_2$ e $C(2|1) = C(1|2)$, então a regra se reduz a classificar x_0 em P_2 se

$$D_2^2 < D_1^2.$$

Análise Discriminante

$$D_2^2 < D_1^2$$

$$\begin{aligned} (x_0 - \mu_2)' \Sigma^{-1} (x_0 - \mu_2) &< (x_0 - \mu_1)' \Sigma^{-1} (x_0 - \mu_1) \\ -2\mu_2' \Sigma^{-1} x_0 + 2\mu_1' \Sigma^{-1} x_0 + \mu_2' \Sigma^{-1} \mu_2 - \mu_1' \Sigma^{-1} \mu_1 &< 0 \\ 2(\mu_1 - \mu_2)' \Sigma^{-1} x_0 - (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 + \mu_2) &< 0 \\ (\mu_1 - \mu_2)' \Sigma^{-1} x_0 - (\mu_1 - \mu_2)' \Sigma^{-1} \frac{(\mu_1 + \mu_2)}{2} &< 0 \\ \underbrace{(\mu_1 - \mu_2)' \Sigma^{-1}}_{\alpha'} \left[x_0 - \underbrace{\frac{(\mu_1 + \mu_2)}{2}}_{\mu} \right] &< 0 \end{aligned}$$

Análise Discriminante

$$D_2^2 < D_1^2$$

$$\begin{aligned} (x_0 - \mu_2)' \Sigma^{-1} (x_0 - \mu_2) &< (x_0 - \mu_1)' \Sigma^{-1} (x_0 - \mu_1) \\ -2\mu_2' \Sigma^{-1} x_0 + 2\mu_1 \Sigma^{-1} x_0 + \mu_2' \Sigma^{-1} \mu_2 - \mu_1' \Sigma^{-1} \mu_1 &< 0 \\ 2(\mu_1 - \mu_2)' \Sigma^{-1} x_0 - (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 + \mu_2) &< 0 \\ (\mu_1 - \mu_2)' \Sigma^{-1} x_0 - (\mu_1 - \mu_2)' \Sigma^{-1} \frac{(\mu_1 + \mu_2)}{2} &< 0 \\ \underbrace{(\mu_1 - \mu_2)' \Sigma^{-1}}_{\alpha'} \left[x_0 - \underbrace{\frac{(\mu_1 + \mu_2)}{2}}_{\mu} \right] &< 0 \end{aligned}$$

$x_0 \in P_2$ se $\alpha'(x_0 - \mu) < 0$ e $x_0 \in P_1$ se $\alpha'(x_0 - \mu) \geq 0$.

Análise Discriminante

Resumo

- $x_0 \in P_2$ se

$$\frac{f_1(x)\pi_1}{C(2|1)} < \frac{f_2(x)\pi_2}{C(1|2)}.$$

- Além do mais, sob normalidade e assumindo $\Sigma_1 = \Sigma_2$, $\pi_1 = \pi_2$ e $C(2|1) = C(1|2)$, $x_0 \in P_2$ se

$$D_2^2 < D_1^2 \quad \text{ou equivalentemente} \quad \underbrace{(\mu_1 - \mu_2)'}_{\alpha'} \Sigma^{-1} \left[x_0 - \underbrace{\frac{(\mu_1 + \mu_2)}{2}}_{\mu} \right] < 0$$

Implementação I

Implementação I

```
ad_me731 <- function(x, y, new_obs) {  
  mu_1 <- apply(x, 2, mean)  
  mu_2 <- apply(y, 2, mean)  
  n_1 <- nrow(x)  
  n_2 <- nrow(y)  
  S <- ((n_1 - 1)*cov(x) + (n_2 - 1)*cov(y))/(n_1 + n_2 - 2)  
  iS <- solve(S)  
  mu <- 0.5*(mu_1 + mu_2)  
  alpha <- iS %*% (mu_1 - mu_2)  
  ifelse(t(alpha) %*% (new_obs - mu) < 0, "P2", "P1")  
}
```

Implementação I

```
Sigma = matrix(c(1, 0.2, 0.2, 1), ncol = 2)
mu1 = c(1, 1)
mu2 = c(2.5, 2.5)
x = MASS::mvrnorm(100, mu1, Sigma)
y = MASS::mvrnorm(100, mu2, Sigma)
new_obs = MASS::mvrnorm(1000, mu1, Sigma)
classifica = c()
for (i in 1:1000) classifica[i] = ad_me731(x, y, new_obs[i, ])
table(classifica)
```

```
## classifica
## P1 P2
## 838 162
```

Implementação I

```
Sigma = matrix(c(0.5, 0.2, 0.2, 0.5), ncol = 2)
mu1 = c(1, 1)
mu2 = c(2.5, 2.5)
x = MASS::mvrnorm(100, mu1, Sigma)
y = MASS::mvrnorm(100, mu2, Sigma)
new_obs = MASS::mvrnorm(1000, mu1, Sigma)
classifica = c()
for (i in 1:1000) classifica[i] = ad_me731(x, y, new_obs[i, ])
table(classifica)
```

```
## classifica
## P1 P2
## 881 119
```

Implementação I

```
data <- data.frame(rbind(x, y))
data$Grupo <- c(rep("P1", nrow(x)), rep("P2", nrow(y)))
ad <- MASS::lda(Grupo ~ ., data)
classifica_lda <- predict(ad, data.frame(new_obs))$class
table(classifica_lda)
```

```
## classifica_lda
##   P1  P2
## 881 119
```

Implementação I

```
table(classifica, classifica_lda)
```

```
##           classifica_lda
## classifica  P1  P2
##           P1 881  0
##           P2  0 119
```

Implementação I

```
ad$prior    # Probabilidades iniciais (nossos Pis)
```

```
## P1 P2  
## 0.5 0.5
```

```
ad$means    # Vetores de médias
```

```
##           X1           X2  
## P1 0.9709064 1.008752  
## P2 2.5148020 2.415932
```

```
ad$scaling  # O que acham que é?
```

```
##           LD1  
## X1 0.8970200  
## X2 0.7408648
```

Erro de classificação

Erro de classificação

- No exemplo vimos que, mesmo todos os $x_0 \in P_1$, algumas vezes foi classificado como P_2 . Isto é um erro de classificação.

Erro de classificação

- No exemplo vimos que, mesmo todos os $x_0 \in P_1$, algumas vezes foi classificado como P_2 . Isto é um erro de classificação.

$$\mathbb{P}(\text{Classificar em } P_2 | X \in P_1) = \mathbb{P}(\alpha'(X - \mu) < 0 | X \in P_1)$$

Erro de classificação

- No exemplo vimos que, mesmo todos os $x_0 \in P_1$, algumas vezes foi classificado como P_2 . Isto é um erro de classificação.

$$\mathbb{P}(\text{Classificar em } P_2 | X \in P_1) = \mathbb{P}(\alpha'(X - \mu) < 0 | X \in P_1)$$

$$X \sim N(\mu_1, \Sigma)$$

$$X - \mu \sim N\left(\frac{\mu_1 - \mu_2}{2}, \Sigma\right)$$

$$\alpha'(X - \mu) \sim N\left(\underbrace{\alpha'\left(\frac{\mu_1 - \mu_2}{2}\right)}_{\frac{(\mu_1 - \mu_2)'\Sigma^{-1}(\mu_1 - \mu_2)}{2}}, \underbrace{\alpha'\Sigma\alpha}_{(\mu_1 - \mu_2)'\Sigma^{-1}(\mu_1 - \mu_2)} \right)$$

Erro de classificação

$$\alpha'(X - \mu) \sim N\left(\frac{(\mu_1 - \mu_2)'\Sigma^{-1}(\mu_1 - \mu_2)}{2}, (\mu_1 - \mu_2)'\Sigma^{-1}(\mu_1 - \mu_2)\right)$$

Erro de classificação

$$\alpha'(X - \mu) \sim N\left(\frac{(\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2)}{2}, (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2)\right)$$

Se denotarmos $\delta^2 = (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2)$, então

$$\alpha'(X - \mu) \sim N\left(\frac{\delta^2}{2}, \delta^2\right)$$

Erro de classificação

$$\alpha'(X - \mu) \sim N\left(\frac{(\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2)}{2}, (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2)\right)$$

Se denotarmos $\delta^2 = (\mu_1 - \mu_2)' \Sigma^{-1} (\mu_1 - \mu_2)$, então

$$\alpha'(X - \mu) \sim N\left(\frac{\delta^2}{2}, \delta^2\right)$$

Se $X \in P_1$:

$$\mathbb{P}(\alpha'(X - \mu) < 0) = \mathbb{P}\left(\underbrace{\frac{\alpha'(X - \mu) - \frac{\delta^2}{2}}{\delta}}_Z < -\frac{\frac{\delta^2}{2}}{\delta}\right) = \mathbb{P}\left(Z < -\frac{\delta}{2}\right)$$

Erro de classificação

Então, se temos n novas observações de P_1 , esperamos que $n \times P(Z < -\frac{\delta}{2})$ sejam incorretamente classificadas.

Erro de classificação

Então, se temos n novas observações de P_1 , esperamos que $n \times P(Z < -\frac{\delta}{2})$ sejam incorretamente classificadas.

No nosso caso:

```
n = 1000
delta = sqrt(t(mu1 - mu2) %*% solve(Sigma) %*% (mu1 - mu2))
c(pnorm(-delta/2), n * pnorm(-delta/2))

## [1]    0.1024469 102.4469469
```

Erro de classificação

- Como não conhecemos Σ , μ_1 nem μ_2 , na prática estimamos essa probabilidade de má classificação

```
mu_1 <- apply(x, 2, mean)
mu_2 <- apply(y, 2, mean)
n_1 <- nrow(x)
n_2 <- nrow(y)
S <- ((n_1 - 1)*cov(x) + (n_2 - 1)*cov(y))/(n_1 + n_2 - 2)
iS <- solve(S)
delta = sqrt(t(mu_1 - mu_2) %*% iS %*% (mu_1 - mu_2))
c(pnorm(-delta/2), n * pnorm(-delta/2))

## [1] 0.1124277 112.4277476
```

Erro de classificação

- Temos calculado $\mathbb{P}(\text{Classificar em } P_2 | X \in P_1)$ no caso em que $P_1 \sim N(\mu_1, \Sigma)$, $P_2 \sim N(\mu_2, \Sigma)$, $\pi_1 = \pi_2$, $C(2|1) = C(1|2)$.

Erro de classificação

- Temos calculado $\mathbb{P}(\text{Classificar em } P_2 | X \in P_1)$ no caso em que $P_1 \sim N(\mu_1, \Sigma)$, $P_2 \sim N(\mu_2, \Sigma)$, $\pi_1 = \pi_2$, $C(2|1) = C(1|2)$.
- Podemos também calcular $\mathbb{P}(\text{Classificar em } P_1 | X \in P_2)$

Erro de classificação

- Temos calculado $\mathbb{P}(\text{Classificar em } P_2 | X \in P_1)$ no caso em que $P_1 \sim N(\mu_1, \Sigma)$, $P_2 \sim N(\mu_2, \Sigma)$, $\pi_1 = \pi_2$, $C(2|1) = C(1|2)$.
- Podemos também calcular $\mathbb{P}(\text{Classificar em } P_1 | X \in P_2)$
- Calcular as probabilidades para diversos outros modelos não sempre é fácil.

Erro de classificação

- Temos calculado $\mathbb{P}(\text{Classificar em } P_2 | X \in P_1)$ no caso em que $P_1 \sim N(\mu_1, \Sigma)$, $P_2 \sim N(\mu_2, \Sigma)$, $\pi_1 = \pi_2$, $C(2|1) = C(1|2)$.
- Podemos também calcular $\mathbb{P}(\text{Classificar em } P_1 | X \in P_2)$
- Calcular as probabilidades para diversos outros modelos não sempre é fácil.
- Outra opção é estimar essas probabilidades é utilizando dados de *treinamento* e *teste* ou através de *validação cruzada* (alguns utilizam re-substituição mas este método é muito otimista).

Erro de classificação

- Temos calculado $\mathbb{P}(\text{Classificar em } P_2 | X \in P_1)$ no caso em que $P_1 \sim N(\mu_1, \Sigma)$, $P_2 \sim N(\mu_2, \Sigma)$, $\pi_1 = \pi_2$, $C(2|1) = C(1|2)$.
- Podemos também calcular $\mathbb{P}(\text{Classificar em } P_1 | X \in P_2)$
- Calcular as probabilidades para diversos outros modelos não sempre é fácil.
- Outra opção é estimar essas probabilidades é utilizando dados de *treinamento* e *teste* ou através de *validação cruzada* (alguns utilizam re-substituição mas este método é muito otimista).
- Ambos os métodos permitem “pular” o cálculo dessas probabilidades todas de forma analítica ao custo de um maior esforço computacional.

Análise Discriminante Quadrática

Análise Discriminante Quadrática

- Análise Discriminante Linear assume que a matriz de covariância Σ é a mesma para ambos os grupos.

Análise Discriminante Quadrática

- Análise Discriminante Linear assume que a matriz de covariância Σ é a mesma para ambos os grupos.
- O que acontece se $\Sigma_1 \neq \Sigma_2$?

Análise Discriminante Quadrática

- Análise Discriminante Linear assume que a matriz de covariância Σ é a mesma para ambos os grupos.
- O que acontece se $\Sigma_1 \neq \Sigma_2$? ADL perde performance.

Análise Discriminante Quadrática

- Análise Discriminante Linear assume que a matriz de covariância Σ é a mesma para ambos os grupos.
- O que acontece se $\Sigma_1 \neq \Sigma_2$? ADL perde performance.
- Uma alternativa é desenvolver todas as contas considerando $\Sigma_1 \neq \Sigma_2$. Neste caso, $x_0 \in P_2$ se

$$\begin{aligned}
 & -\frac{1}{2}x_0'(\Sigma_1^{-1} - \Sigma_2^{-1})x_0 + (\mu_1'\Sigma_1^{-1} - \mu_2'\Sigma_2^{-1})x_0 - \frac{1}{2}\log\left(\frac{|\Sigma_1|}{|\Sigma_2|}\right) \\
 & + \frac{1}{2}(\mu_1'\Sigma_1^{-1}\mu_1 - \mu_2'\Sigma_2^{-1}\mu_2) - \log\left[\frac{C(1|2)\pi_2}{C(2|1)\pi_1}\right]
 \end{aligned}$$

Referências

Referências

- Härdle, W. K., & Simar, L. (2019). Applied Multivariate Statistical Analysis. Fifth Edition. Springer Nature. Capítulo 14.
- Mardia, K. V., Kent, J. T., & Bibby, J. M. (1979). Multivariate Analysis. Academic Press. Capítulo 11.
- Peña, D. (2002). Análisis de Datos Multivariantes. Mc Graw Hill. Capítulo 13.