

# Bayes Optimal Classifier

Renato Assunção

DCC-UFMG

2020

# Classificação em duas classes

- Vamos começar com a situação mais simples: duas classes
- Indivíduos são amostrados de uma certa população.
- Esta população é particionada em duas classes disjuntas:  $\text{pop}_1$  (denotada  $\pi_1$ ) e  $\text{pop}_2$  (denotada  $\pi_2$ )
- As duas classes representam uma partição da população:
  - Todo indivíduo pertence a uma das duas subpopulações.
  - Nenhum indivíduo pertence a duas classes ao mesmo tempo.

## Exemplos

- Risco de Crédito: Empresas tomadoras de crédito em um banco:  $\pi_1 \rightarrow$  créditos bons;  $\pi_2 \rightarrow$  créditos ruins
- Crânios em um sítio arqueológico:  $\pi_1 \rightarrow$  homens;  $\pi_2 \rightarrow$  mulheres
- Saúde: Pessoas com úlcera ( $\pi_1$ ) e pessoas sem úlcera ( $\pi_2$ )
- Saúde: Mulheres com ( $\pi_1$ ) ou sem ( $\pi_2$ ) câncer de mama
- Análise de textos de dois participantes do movimento de independência dos EUA:  $\pi_1$  : James Madison ou  $\pi_2$  : Alexander Hamilton.
- Duas espécies da flor Iris:  $\pi_1$ : Iris setosa;  $\pi_2$ : Iris virginica.
- Usuários de um website:  $\pi_1$ : clicam num certo anúncio e  $\pi_2$ , não clicam
- Alunos de um curso online:  $\pi_1$  : evadem e  $\pi_2$  completam o curso

## Features

- Indivíduos que pertencem a uma de duas sub-populações:  $\pi_1$  ou  $\pi_2$ .
- Em cada indivíduo, medimos um conjunto de  $p$  variáveis (ou features):

$$\mathbf{X} = (X_1, X_2, \dots, X_p)$$

- Com base nas medições em  $\mathbf{X}$ , queremos inferir se  $\mathbf{X} \in \pi_1$  ou se  $\mathbf{X} \in \pi_2$ .
- Queremos descobrir (ou aprender) uma regra matemática  $g(\mathbf{X})$  que prediga se o indivíduo pertence à classe  $\pi_1$  ou a  $\pi_2$ .
- Esta regra será usada para predizer a classe de novos itens para os quais sabemos  $\mathbf{X}$  mas não sabemos a sua classe.

- Para construir uma regra de classificação de novos itens, usamos uma amostra com as classes conhecidas (amostra rotulada com a classe):

Item	Classe ou População	Variáveis $X_1 X_2 \dots X_p$
1	$\pi_1$	$X_{1,1} X_{1,2} X_{1,3} \dots X_{1,p}$
2	$\pi_1$	$X_{2,1} X_{2,2} X_{2,3} \dots X_{2,p}$
$\vdots$	$\vdots$	$\vdots$
$m_1$	$\pi_1$	$X_{m_1,1} X_{m_1,2} X_{m_1,3} \dots X_{m_1,p}$
1	$\pi_2$	$X_{m_1+1,1} X_{m_1+1,2} X_{m_1+1,3} \dots X_{m_1+1,p}$
2	$\pi_2$	$X_{m_1+2,1} X_{m_1+2,2} X_{m_1+2,3} \dots X_{m_1+2,p}$
$\vdots$	$\vdots$	$\vdots$
$m_2$	$\pi_2$	$X_{m_1+m_2,1} X_{m_1+m_2,2} X_{m_1+m_2,3} \dots X_{m_1+m_2,p}$
Novo Item	?????	$X_1^* X_2^* X_3^* \dots X_p^*$

- Novo item: conhecemos  $\mathbf{X}$  mas não conhecemos a sua classe.
- $X_1^* X_2^* X_3^* \dots X_p^* \rightarrow$  valores conhecidos, efetivamente observados.
- ?????  $\rightarrow$  queremos inferir a classe do novo item

# Exemplos

Populações $\pi_1$ e $\pi_2$	Variáveis $X_1 \dots X_p$
Risco de Crédito: Empresas tomadoras de crédito em um banco $\pi_1 \rightarrow$ créditos bons $\pi_2 \rightarrow$ créditos ruins	- % do empréstimo frente ao faturamento anual da empresa - tempo como cliente - nº de empréstimos anteriores pagos a tempo - saldo mensal
Crânios em um sítio arqueológico $\pi_1 \rightarrow$ homens $\pi_2 \rightarrow$ mulheres	- Circunferência - Largura - Altura
Pessoas com úlcera ou sem úlcera	- Medidas de grau de ansiedade - Grau de perfeccionismo - Grau de sentimento de culpa - Grau de dependência
Textos de James Madison ou Alexander Hamilton	- Frequências de palavras distintas e comprimento das sentenças


# Exemplos

Populações $\pi_1$ e $\pi_2$	Variáveis $X_1 \dots X_p$
Duas espécies de flor	<ul style="list-style-type: none"><li>- Comprimento da pétala</li><li>- Largura da pétala</li><li>- Comprimento da sépala</li><li>- Largura da sépala</li></ul>
Usuários que clicam e não clicam em um anúncio	<ul style="list-style-type: none"><li>- Posição do anúncio na página</li><li>- Tamanho do anúncio</li><li>- Tem imagem?</li><li>- Número de palavras</li></ul>
Alunos que evadem e que completam um curso online	<ul style="list-style-type: none"><li>- Nota do exame de entrada no curso</li><li>- Medidas de motivação a partir de questionário na entrada</li><li>- Renda familiar</li><li>- Idade</li></ul>

Por que precisamos predizer a classe de um item novo?

- Classe pode ser conhecida apenas no futuro.
  - Ex.: Risco de crédito: No momento em que o crédito é solicitado, não sabemos se o crédito do Indivíduo é bom ou ruim.
- Informação sobre a classe não é conhecida com certeza.
  - Crânios arqueológicos danificados.
- Obter a classe pode implicar em destruir o item.
  - Ex.: Queremos classificar um paciente chegando ao pronto socorro com lesão na cabeça como UTI ou não-UTI, com base em algumas medidas rápidas. Esperar para saber com certeza se deve ir para UTI pode significar esperar demais.

- Cada uma das populações possui uma distribuição conjunta para as variáveis:
  - $\mathbf{X} = (X_1, X_2, \dots, X_p)$
  - População 1  
 $(\mathbf{X} | \in \pi_1) \sim f_1(\mathbf{x})$
  - População 2  
 $(\mathbf{X} | \in \pi_2) \sim f_2(\mathbf{x})$



Por exemplo:  $f_1(x) = N_p(\mu_1, \Sigma_1)$  e  $f_2(x) = N_p(\mu_2, \Sigma_2)$   
 $\qquad\qquad\qquad_{px1}^{pxp} \qquad\qquad\qquad_{px1}^{pxp}$   
 (mas poderia ser qualquer outra distribuição).

- Com base na amostra rotulada (classes conhecidas), podemos obter estimativas dos valores esperados  $\mu_1$  e  $\mu_2$  das distribuições  $f_1(x)$  e de  $f_2(x)$  simplesmente tomando a média aritmética de cada variável dentro de cada classe.


Item	Classe ou População	Variáveis $X_1 \ X_2 \ \dots \ X_p$
1	$\pi_1$	$X_{1,1} \ X_{1,2} \ X_{1,3} \ \dots \ X_{1,p}$
2	$\pi_1$	$X_{2,1} \ X_{2,2} \ X_{2,3} \ \dots \ X_{2,p}$
$\vdots$	$\vdots$	$\vdots$
$m_1$	$\pi_1$	$X_{m_1,1} \ X_{m_1,2} \ X_{m_1,3} \ \dots \ X_{m_1,p}$
Médias das $p$ vars		$\bar{x}_{11} \ \bar{x}_{12} \ \bar{x}_{13} \ \dots \rightarrow$ vetor $\bar{x}_1 = \hat{\mu}_1$
<hr/> <hr/>		
1	$\pi_2$	$X_{m_1+1,1} \ X_{m_1+1,2} \ X_{m_1+1,3} \ \dots \ X_{m_1+1,p}$
2	$\pi_2$	$X_{m_1+2,1} \ X_{m_1+2,2} \ X_{m_1+2,3} \ \dots \ X_{m_1+2,p}$
$\vdots$	$\vdots$	$\vdots$
$m_2$	$\pi_2$	$X_{m_1+m_2,1} \ X_{m_1+m_2,2} \ X_{m_1+m_2,3} \ \dots \ X_{m_1+m_2,p}$
Médias das $p$ vars		$\bar{x}_{21} \ \bar{x}_{22} \ \bar{x}_{23} \ \dots \rightarrow$ vetor $\bar{x}_2 = \hat{\mu}_2$

- Podemos também estimar as matrizes  $p \times p$  de covariância  $\Sigma_1$  e  $\Sigma_2$  com as amostras rotuladas.
- Por exemplo, para a classe 1, estimamos as  $p$  variâncias  $\sigma_{11}^2, \sigma_{1,2}^2, \dots, \sigma_{1,p}^2$  através das variâncias amostrais  $s_{11}^2, s_{1,2}^2, \dots, s_{1,p}^2$
- A covariância  $c_{12}$  entre a variável  $i$  e a variável  $j$  (da classe 1) é estimada por  $s_{1i}s_{1j}r_{1,ij}$  usando os desvios-padrão de cada variável e a correlação  $r_{1,ij}$


Item	Classe ou População	Variáveis $X_1 X_2 \dots X_p$
1	$\pi_1$	$X_{1,1} X_{1,2} X_{1,3} \dots X_{1,p}$
2	$\pi_1$	$X_{2,1} X_{2,2} X_{2,3} \dots X_{2,p}$
$\vdots$	$\vdots$	$\vdots$
$m_1$	$\pi_1$	$X_{m_1,1} X_{m_1,2} X_{m_1,3} \dots X_{m_1,p}$
Variância amostral das $p$ vars		$s_{11}^2, s_{1,2}^2, \dots, s_{1,p}^2$

- Novo item

$$X = (X_1, X_2) \text{ (Supondo apenas } p = 2 \text{ variáveis)}$$




- Olhar a distância do novo item  $X$  aos vetores  $\mu_1$  e  $\mu_2 \Rightarrow$  parece razoável alocar  $X$  à população 1, pois a distância entre  $X$  e  $\mu_1$  é menor que entre  $X$  e  $\mu_2$ .




- No entanto, **X** parece pertencer à população 2!
- Precisamos levar em conta as correlações.
- Precisamos olhar a distância estatística ou a distância de Mahalanobis do novo item **X** a cada um dos centros  $\mu_1$  e  $\mu_2$ .

# Distância Estatística



- Centro da nuvem representa o valor médio de cada variável, o perfil “médio” desta população estatística.


# Distância Estatística



- INTUITIVAMENTE, os pontos vermelhos estão ESTATISTICAMENTE mais distantes do centro da nuvem que os pontos azuis.

- Como criar uma medida de distância matemática que incorpore esta intuição?
- Distância de Mahalanobis: leva em conta as variâncias de cada variável.

# Distância de Mahalanobis



- Mahalanobis também leva em conta as correlações entre as variáveis.
- Pontos na elipse inclinada estão à mesma distância do centro da nuvem.
- As correlações entre as variáveis → inclinação da elipse.
- Obs: eixos das elipses são os componentes principais!!
- Para mais detalhes, ver capítulo 13 do meu livro em:  
<https://homepages.dcc.ufmg.br/~assuncao/EstatCC/FECD.pdf>

## Distância Euclidiana em duas dimensões

- Queremos a distância entre um ponto arbitrário  $\mathbf{x} = (x_1, x_2)$  e o ponto  $\boldsymbol{\mu} = (\mu_1, \mu_2)$  que representa os valores esperados das variáveis  $X_1$  e  $X_2$ .

$$\begin{aligned} d^2(\mathbf{x}, \boldsymbol{\mu}) &= (x_1 - \mu_1)^2 + (x_2 - \mu_2)^2 \\ &= (x_1 - \mu_1, x_2 - \mu_2) \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{pmatrix} x_1 - \mu_1 \\ x_2 - \mu_2 \end{pmatrix} \\ &= \begin{pmatrix} x_1 - \mu_1 \\ x_2 - \mu_2 \end{pmatrix}^t \mathbf{I} \begin{pmatrix} x_1 - \mu_1 \\ x_2 - \mu_2 \end{pmatrix} \\ &= (\mathbf{x} - \boldsymbol{\mu})^t \mathbf{I} (\mathbf{x} - \boldsymbol{\mu}) \end{aligned}$$

- Esta forma matricial é uma maneira complicada, um tanto pedante, de escrever a distância.
- Entretanto ela é uma representação muito útil: o caso genérico vai ficar MUITO simples nesta notação matricial.

# Distância Euclidiana em $p$ dimensões

- Queremos a distância entre um ponto arbitrário  $\mathbf{x} = (x_1, x_2, \dots, x_p) \in \mathbb{R}^p$  e o ponto  $\boldsymbol{\mu} = (\mu_1, \mu_2, \dots, \mu_p) \in \mathbb{R}^p$  que representa os valores esperados das variáveis  $X_1, X_2, \dots, X_p$ .
- Em  $p$  dimensões:

$$\begin{aligned} d^2(\mathbf{x}, \boldsymbol{\mu}) &= (x_1 - \mu_1)^2 + (x_2 - \mu_2)^2 + \dots + (x_p - \mu_p)^2 \\ &= (x_1 - \mu_1, x_2 - \mu_2, \dots, x_p - \mu_p) \begin{bmatrix} 1 & 0 & \dots & 0 & 0 \\ 0 & 1 & \dots & 0 & 0 \\ \vdots & & \ddots & & \\ 0 & 0 & \dots & 0 & 1 \end{bmatrix} \begin{pmatrix} x_1 - \mu_1 \\ x_2 - \mu_2 \\ \vdots \\ x_p - \mu_p \end{pmatrix} \\ &= (\mathbf{x} - \boldsymbol{\mu})^t \mathbf{I} (\mathbf{x} - \boldsymbol{\mu}) \end{aligned}$$

## Distância Euclidiana em $p$ dimensões


- A representação matricial com  $p$  dimensões é a mesma daquela com duas dimensões.
- A distância estatística (de Mahalanobis) substitui a matriz  $p \times p$  identidade  $\mathbf{I}$  na expressão acima por  $\boldsymbol{\Sigma}^{-1}$ , a inversa da matriz de covariância, também de dimensão  $p \times p$ .
- Para uma explicação intuitiva e bem detalhada, ver o capítulo 13 do meu livro em:  
<https://homepages.dcc.ufmg.br/~assuncao/EstatCC/FECD.pdf>

# Mahalanobis

- $\mathbb{E}(X) = \boldsymbol{\mu}_{px1}$  = vetor com os valores esperados de cada uma das  $p$  variáveis
- $\mathbb{V}(X) = \boldsymbol{\Sigma}_{pxp}$  = matriz de variâncias e covariâncias do vetor  $\mathbf{X}$

$$d_{\Sigma}^2(\mathbf{X}, \boldsymbol{\mu}) = (\mathbf{X} - \boldsymbol{\mu})^t \boldsymbol{\Sigma}^{-1} (\mathbf{X} - \boldsymbol{\mu})$$

$$d^2(X, \mu) = \boxed{(X - \mu)^t} \cdot \boxed{\Sigma^{-1}} \cdot \boxed{\begin{matrix} X \\ - \\ \mu \end{matrix}}$$




- $d_1^2 = d_{\Sigma_1}^2(\mathbf{X}, \mu_1)$   
 $= (\mathbf{X} - \mu_1)^t \Sigma_1^{-1} (\mathbf{X} - \mu_1)$
- $d_2^2 = d_{\Sigma_2}^2(\mathbf{X}, \mu_2)$   
 $= (\mathbf{X} - \mu_2)^t \Sigma_2^{-1} (\mathbf{X} - \mu_2)$


### Uma Regra de Classificação Inicial

- Aloque  $\mathbf{X}$  à população com a menor distância de Mahalanobis  $d^2$ .


- Isto é,
  - Se  $d_{\Sigma_1}^2(\mathbf{X}, \mu_1) < d_{\Sigma_2}^2(\mathbf{X}, \mu_2) \Rightarrow$  aloque  $\mathbf{X}$  à pop1;
  - Caso contrário, aloque  $\mathbf{X}$  à pop2.
- Espaço  $\mathbb{R}^p$  é particionado em duas regiões:
  - $R_1 = \{x \in \mathbb{R}^p \mid d_{\Sigma_1}^2(\mathbf{X}, \mu_1) < d_{\Sigma_2}^2(\mathbf{X}, \mu_2)\}$
  - $R_2 = \mathbb{R}^p - R_1 =$  pontos que serão alocados à pop2.




- Quais são essas duas regiões?
- A seguir uma visão intuitiva.
- Resultado mais rigoroso vem a seguir.



- Obtenha o perfil médio das duas populações.



- Consider the structure of correlation between the variables of each group (but for now, we will see the details of this)



$\Leftarrow$  as duas regiões.

- Outra maneira de ver a regra de classificação:

$$\begin{cases} \pi_1 = pop_1 \\ \pi_2 = pop_2 \end{cases}$$

- $f_1(\mathbf{x})$  = densidade do vetor  $\mathbf{X}$  se  $\in \pi_1$
- $f_2(\mathbf{x})$  = densidade do vetor  $\mathbf{X}$  se  $\in \pi_2$
- Vamos supor que, dentro de cada classe, os dados  $\mathbf{X}$  sigam uma distribuição gaussiana:

$$\mathbf{X} \sim \begin{cases} N(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1), & \text{se } \in \pi_1 \\ N(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2), & \text{se } \in \pi_2 \end{cases}$$

- No caso gaussiano, temos

$$f_1(\mathbf{x}) = \underbrace{\left[ \frac{1}{(2\pi)^{p/2} |\boldsymbol{\Sigma}_1|^{1/2}} \right]}_{c_1 = \text{constante em } \mathbf{x}} \exp \left( -\frac{1}{2} \underbrace{(\mathbf{x} - \boldsymbol{\mu}_1)^t \boldsymbol{\Sigma}_1^{-1} (\mathbf{x} - \boldsymbol{\mu}_1)}_{\text{distância de Mahalanobis}} \right)$$

$$f_2(\mathbf{x}) = \underbrace{\left[ \frac{1}{(2\pi)^{p/2} |\boldsymbol{\Sigma}_2|^{1/2}} \right]}_{c_2 = \text{constante em } \mathbf{x}} \exp \left( -\frac{1}{2} \underbrace{(\mathbf{x} - \boldsymbol{\mu}_2)^t \boldsymbol{\Sigma}_2^{-1} (\mathbf{x} - \boldsymbol{\mu}_2)}_{\text{distância de Mahalanobis}} \right)$$

- Tomando a razão das densidades no mesmo ponto  $\mathbf{x}$ :

$$\begin{aligned}\frac{f_1(\mathbf{x})}{f_2(\mathbf{x})} &= \frac{c_1 \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_1)^t \boldsymbol{\Sigma}_1^{-1}(\mathbf{x} - \boldsymbol{\mu}_1)\right)}{c_2 \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_2)^t \boldsymbol{\Sigma}_2^{-1}(\mathbf{x} - \boldsymbol{\mu}_2)\right)} \\ &= \exp\left(-\frac{1}{2}(d_{\boldsymbol{\Sigma}_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) - d_{\boldsymbol{\Sigma}_2}^2(\mathbf{x}, \boldsymbol{\mu}_2))\right)\end{aligned}$$

- Vamos escolher um threshold  $M \geq 1$ . Veja que:

$$\frac{f_1(\mathbf{x})}{f_2(\mathbf{x})} > M \iff \underbrace{d_{\boldsymbol{\Sigma}_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) < d_{\boldsymbol{\Sigma}_2}^2(\mathbf{x}, \boldsymbol{\mu}_2) + K}_{\text{condição para alocar a } \pi_1}$$

onde  $K = \log(c_1/(Mc_2))$ .

## Caso $\Sigma_1 = \Sigma_2$

- Se  $\Sigma_1 = \Sigma_2$ , temos  $c_1 = c_2$ . Além disso, tomando  $M = 1$ , a regra fica simplesmente

$$\frac{f_1(\mathbf{x})}{f_2(\mathbf{x})} > 1 \iff \underbrace{d_{\Sigma_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) < d_{\Sigma_2}^2(\mathbf{x}, \boldsymbol{\mu}_2)}_{\text{condição para alocar a } \pi_1}$$

- Isto é, no caso gaussiano com covariâncias iguais, o conjunto  $R_1$  dos pontos  $\mathbf{x} \in \mathbb{R}^p$  tais que  $f_1(\mathbf{x}) > f_2(\mathbf{x})$  é o mesmo conjunto de pontos em que  $d_{\Sigma_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) < d_{\Sigma_2}^2(\mathbf{x}, \boldsymbol{\mu}_2)$
- No caso geral, com  $M = 1$ , o conjunto  $R_1$  dos pontos e que  $f_1(\mathbf{x}) > f_2(\mathbf{x})$  é o mesmo que pedir a distância de Mahalanobis  $d_{\Sigma_1}^2(\mathbf{x}, \boldsymbol{\mu}_1)$  menor que a distância  $d_{\Sigma_2}^2(\mathbf{x}, \boldsymbol{\mu}_2)$  acrescida da constante  $\log(c_1/c_2)$ .

## Saindo do caso gaussiano

- Assim, no caso gaussiano, definir a região de classificação à  $\pi_1$  usando a razão de densidades é matematicamente equivalente a definir usando as distâncias de Mahalanobis.

$$\frac{f_1(\mathbf{x})}{f_2(\mathbf{x})} > 1 \iff \underbrace{d_{\Sigma_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) < d_{\Sigma_2}^2(\mathbf{x}, \boldsymbol{\mu}_2) + K}_{\text{condição para alocar a } \pi_1}$$

- E quando  $\mathbf{X}$  não seguir uma gaussiana?
- O que devemos usar para definir  $R_1$ ?
- Faz diferença?

## Caso não-gaussiano

- Conhecemos a densidade de  $\mathbf{X}$  em cada classe:  $f_1(\mathbf{x})$  e  $f_2(\mathbf{x})$ .
- **Método 1:** Imitando o que descobrimos no caso gaussiano, podemos escolher  $R_1$  como sendo o seguinte conjunto de pontos do  $\mathbb{R}^P$ :

$$R_1 = \{\mathbf{x} \in \mathbb{R}^P \text{ tais que } f_1(\mathbf{x}) > f_2(\mathbf{x})\}$$

- **Método 2:** Outra opção, quando as amostras forem grandes:
  - com as amostras rotuladas, obtemos boas aproximações para os vetores de valores esperados  $\mu_1$  e  $\mu_2$ .
  - Obtemos boas estimativas das matrizes  $p \times p$  de covariância  $\Sigma_1$  e  $\Sigma_2$ .
  - Para cada pontos  $\mathbf{x} \in \mathbb{R}^P$  podemos calcular as duas distâncias de Mahalanobis:  $d_{\Sigma_1}^2(\mathbf{x}, \mu_1)$  e  $d_{\Sigma_2}^2(\mathbf{x}, \mu_2)$ .
  - Calcule a constante  $K = \log(c_1/c_2)$  que envolve os determinantes de  $\Sigma_1$  e de  $\Sigma_2$ .
  - Escolhemos  $R_1$  como sendo o seguinte conjunto de pontos:

$$R_1 = \{\mathbf{x} \in \mathbb{R}^P \text{ tais que } d_{\Sigma_1}^2(\mathbf{x}, \mu_1) < d_{\Sigma_2}^2(\mathbf{x}, \mu_2) + K\}$$

## Caso não-gaussiano

- Os dois métodos coincidem no caso gaussiano, gerando a mesma região  $R_1$ , mas não no caso não-gaussiano.
- Qual dos dois métodos é o melhor no caso não-gaussiano?
- É melhor usar a razão de densidades ou a distância de Mahalanobis?
- Existiria um terceiro método (árvore de classificação, por exemplo) melhor que estes dois métodos?
- Talvez este terceiro método possa ser usado até no caso gaussiano também.
- Existirá um método imbatível, insuperável, o melhor de todos os possíveis e imagináveis, por mais criativos que sejamos?
- De forma surpreendente, podemos responder SIM a esta questão. E ainda saberemos que método ótimo é este.

# O caso geral para classificação

- Na verdade, o problema que vamos resolver é mais geral do que o que consideramos até agora.
- Uma situação mais geral:
  - Custo de classificação errada pode variar de acordo com a classe.
  - Uma das populações pode ser muito mais frequente do que a outra
  - A distribuição pode não ser gaussiana
- Exemplo de risco de crédito:
  - Cliente solicita empréstimo no banco
  - Queremos saber, no momento do empréstimo, se ele é um bom risco (pagará no prazo) ou um mau risco.
  - Nos baseamos em várias características (features) medidas no momento do empréstimo:
    - idade, sexo, tempo como cliente, saldo médio,
    - % do empréstimo em relação ao saldo,
    - já pegou empréstimo antes?

- Custo de classificação em uma matriz:


		classificado em $\pi_1$	classificado em $\pi_2$
População Verdadeira	$\pi_1$ Bom crédito	$\text{custo} = 0$	$c(2  \in \pi_1)$
	$\pi_2$ Mau crédito	$c(1  \in \pi_2)$	$\text{custo} = 0$

- $c(2| \in \pi_1) = \text{custo de classificar como mau crédito um bom pagador};$   
 $= \text{custo de perder um bom cliente};$   
 $= \text{perder o pequeno ganho a ser obtido por juros do empréstimo}.$
- $c(1| \in \pi_2) = \text{custo de classificar como bom crédito um mau pagador};$   
 $= \text{custo de perder todo \$\$ emprestado};$   
 $= \text{perder todo o valor emprestado}$
- Em geral, nesse problema  $c(1| \in \pi_2) >> c(2| \in \pi_1)$

- Um outro exemplo típico: um paciente entra no pronto-socorro com um traumatismo craniano causado por uma queda (comum entre idosos e crianças), um acidente com moto ou esportes ou uma agressão física.
- Não é uma situação rara: ocorrem 50 casos por 10 mil habitantes nos EUA por ano, com 2,5 milhões atendimentos em pronto-socorros, 282 mil internações hospitalares e 56 mil mortes.
- A decisão mais importante é se devemos levar o paciente imediatamente para a UTI ou se ele deve ficar sob observação.
- As primeiras horas após a lesão ocorrer são decisivas.

- Os custos de uma decisão errada são bem diferentes:
  - Levar para a UTI imediatamente mas sem necessidade gasta recursos do hospital que poderiam ser usados de outra forma.
  - Deixar sob observação um paciente que necessitava de tratamento intensivo pode significar sua morte.
- Os custos muito diferentes têm impacto numa regra de classificação: se quisermos minimizar o custo esperado de uma decisão ruim, devemos levar em conta esses custos muito diferentes.
- Como fazer isso?
- O segundo ponto que queremos considerar é o tamanho desbalanceado das duas populações

- No mercado de risco de crédito, maus pagadores são muito mais raros do que bons pagadores.



- E daí?
- Aonde você classificaria um novo item se  $d_{\Sigma_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) = d_{\Sigma_2}^2(\mathbf{x}, \boldsymbol{\mu}_2)$ ???

- Suponha que os custos de classificação incorreta sejam iguais:  
 $c(1| \in \pi_2) = c(2| \in \pi_1)$
- Se  $d_{\Sigma_1}^2(x, \mu_1) = d_{\Sigma_2}^2(x, \mu_2)$ , estamos dizendo que não existe evidência nas variáveis em  $x$  para saber se  $\in \pi_1$  ou se  $\in \pi_2$
- O ponto  $x$  está igualmente distante das duas populações.
- Resta uma informação *a priori*, que não está no novo caso  $x$ : é que, com alta probabilidade (0.99), o novo caso  $x$  vem de  $\pi_1$ .
- A chance de um novo caso qualquer vir de  $\pi_2$  é muito pequena (1% apenas). Então:
  - se os custos são os mesmos
  - se o novo caso está igualmente distante de  $\pi_1$  e  $\pi_2$
  - parece razoável usar a informação *adicional* de que existem muito mais casos em  $\pi_1$  do que em  $\pi_2$  e alojar em  $\pi_1$ .
- Como misturar custos e probabilidades *a priori* no caso geral?

- Um terceiro ponto a ser considerado:
- A distribuição dos dados pode não ser gaussiana.
- No caso gaussiano, como


$$f(\mathbf{x}) = c^{te} \cdot \exp \left( -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_1)^t \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}_1) \right),$$

comparar distâncias de Mahalanobis é equivalente a comparar duas densidades de probabilidades. Os dois métodos são, na verdade, um só. Mas não sabemos se existe outro melhor que este.


- Vamos considerar o caso de distribuições  $f_1(\mathbf{x})$  e  $f_2(\mathbf{x})$  arbitrárias. Não estaremos restritos a densidades gaussianas nem vamos nos limitar a olhar apenas as distâncias de Mahalanobis.
- E vamos descobrir a melhor regra de classificação: não existe nada melhor que este novo classificador.
- Ele é o *classificador ótimo de Bayes* (optimal Bayes classifier).

# Expected cost of misclassification (ECM)

Temos duas densidades,  $f_1(x)$  e  $f_2(x)$ , e uma regra de classificação:  
 $\mathbb{R}^p = R_1 \cup R_2$ .



- As duas densidades:  $f_1(x)$  e  $f_2(x)$ .
- $R_1$  e  $R_2$  são definidas por alguma regra de classificação (regra que não é necessariamente boa).



Veja que:

- (a) estabelecer uma partição de  $R_1 \cup R_2 = \mathbb{R}^p$ , com  
 $R_2 = \mathbb{R}^p - R_1$ , implica em criar uma regra de classificação:  
Regra: Se  $x \in R_1$ , aloque  $x$  a  $\pi_1$ . Else, aloque  $x$  a  $\pi_2$ .
- (b) estabelecer uma regra de classificação qualquer implica em  
criar uma partição de  $\mathbb{R}^p$ :

$$R_1 = \{x \in \mathbb{R}^p \mid \text{a regra aloca } x \text{ a } \pi_1\}$$

$$R_2 = \mathbb{R}^p - R_1$$


Assim, estabelecer uma regra de classificação baseada em  $x \in \mathbb{R}^p$  é  
equivalente a estabelecer uma partição  $R_1 \cup R_2 = \mathbb{R}^p$ .

- Veja que o classificador (ou regra de classificação) é uma função matemática, determinística.
- Por exemplo, seja  $\mathbf{x} = (x_1, x_2, x_3) = (\text{age}, \text{sex}, \text{income})$ .
- Suponha que  $\mathbf{x}_i = (37, \text{FEM}, 25) = \mathbf{x}_j$ , duas pessoas com os mesmos três atributos.
- O classificador não muda de valor (ou de classe) diante desses dois exemplos, a classe atribuída será para os dois exemplos.
- O classificador é uma função matemática

$$g(\mathbf{x}) = \begin{cases} \pi_1 & \text{if } \mathbf{x} \in R_1 \\ \pi_2 & \text{if } \mathbf{x} \in R_2 = \mathbb{R}^p - R_1 \end{cases}$$

- Dado um certo exemplo  $\mathbf{x}$ , a regra vai alocá-lo a uma das duas classes.
- Se tivermos outro exemplo  $\mathbf{x}^*$  cujas variáveis tenham os mesmos valores, a classe atribuída a  $\mathbf{x}^*$  será a mesma da classe atribuída a  $\mathbf{x}$ .


- Probabilidade condicional de classificar um objeto em  $\pi_2$  quando, de fato, ele é de  $\pi_1$  é:
  - $\mathbb{P}(\text{Class. em } \pi_2 | \in \pi_1) = \mathbb{P}(\mathbf{X} \in R_2 | \in \pi_1) = \int_{R_2} f_1(\mathbf{x}) d\mathbf{x}$



- Similarmente,
- probabilidade de classificar erradamente em  $\pi_1$  dado que ele é de  $\pi_2$ :
- $\mathbb{P}(\text{Class. em } \pi_1 | \in \pi_2) = \mathbb{P}(\mathbf{X} \in R_1 | \in \pi_2) = \int_{R_1} f_2(\mathbf{x}) d\mathbf{x}$
- A probabilidade desse segundo erro de classificação é o volume (integral) sob  $f_2(\mathbf{x})$  na região  $R_1$ .


## Caso 1-dim

- Vamos ver o caso em que  $p = 1$  (uma única variável)
- As densidades  $f_1(x)$  e  $f_2(x)$ , e  $R_1$  e  $R_2$ :



- As duas probabilidades de classificação incorreta:


$$\text{area} = P(\text{Class. em } \pi_1 | \in \pi_2) = \int_{R_1} f_2(x) dx$$



- Área em vermelho: probab de alocar a  $\pi_1$  um exemplo vindo de  $f_2(x)$  (e portanto, vindo de  $\pi_2$ ).
- Área em verde: probab de alocar a  $\pi_2$  um exemplo vindo de  $f_1(x)$  (e portanto, vindo de  $\pi_1$ ).

# Trade-off

$$\text{area} = P(\text{Class. em } \pi_1 | \in \pi_2) = \int_{R_1} f_2(x) dx$$




- Veja que quando procuramos diminuir  $\mathbb{P}(\text{Class. em } \pi_1 | \in \pi_2)$  estamos aumentando  $\mathbb{P}(\text{Class. em } \pi_2 | \in \pi_1)$ .
- Existe um trade-off entre essas probabilidades de classificação incorreta.
- Como escolher uma boa partição  $R_1$  e  $R_2$  do espaço  $\mathbb{R}^p$ ?
- Como os dois erros possuem custos diferentes, nós vamos minimizar o custo esperado de má classificação.


- Temos também as probabilidades a priori de que os objetos venham de  $\pi_1$  ou  $\pi_2$ :

$$p_1 = \mathbb{P}(\in \pi_1)$$

$$p_2 = \mathbb{P}(\in \pi_2) = 1 - \mathbb{P}(\in \pi_1) = 1 - p_1$$

- Quadro geral:





Incorre nesse custo com prob.

$$P(\pi_1)P(X \in R_1 | \pi_2)$$

TEXTO VERMELHO ERRADO: Deveria ser  $P(\pi_1)P(X \in R_2 | \in \pi_1)$ .

- Casos novos chegam: alguns nós clasificamos corretamente (com custo zero); outros, classificamos incorretamente (com custo  $> 0$ ).
- Podemos ter  $c(2| \in \pi_1) \neq c(1| \in \pi_2)$
- Nos casos em que erramos, às vezes caímos no custo mais elevado; às vezes, no custo menor.
- É impossível (nos casos realistas) ter uma regra baseada num vetor  $x$  que nunca erre.
- Queremos uma regra de classificação que, em geral (ou, em média) leve a um custo pequeno
- $\Rightarrow$  queremos um custo médio (ou esperado) pequeno.

# EMC: Expected misclassification cost

- Custo esperado (ou custo médio) de má-classificação:
- Custo é variável aleatória e possui três valores possíveis: 0,  $c(2| \in \pi_1)$  e  $c(1| \in \pi_2)$
- Estes custos aleatórios acontecem com certas probabilidades.
- Qual seu valor esperado?

$$\begin{aligned} EMC &= \mathbb{E}(\text{cost}) \\ &= 0 \times \mathbb{P}(\text{acertar}) + \text{cost}_1 \times \mathbb{P}(\text{erro 1}) + \text{cost}_2 \times \mathbb{P}(\text{erro 2}) \\ &= c(2| \in \pi_1)\mathbb{P}(\text{vir de } \pi_1 \text{ e errar}) + c(1| \in \pi_2)\mathbb{P}(\text{vir de } \pi_2 \text{ e errar}) \\ &= c(2| \in \pi_1)\mathbb{P}(\mathbf{X} \in R_2 | \in \pi_1)\mathbb{P}(\pi_1) + c(1| \in \pi_2)\mathbb{P}(\mathbf{X} \in R_1 | \in \pi_2)\mathbb{P}(\pi_2) \end{aligned}$$

- $EMC \rightarrow$  é custo esperado de má classificação. (expected misclassification cost).

- Queremos achar as regiões  $R_1$  e  $R_2$  que minimizam o EMC.
- Isto é equivalente a encontrar o classificador que torna o EMC o menor possível.
- Solução:

$$R_1 = \left\{ \mathbf{x} \in \mathbb{R}^p \text{ tais que } \underbrace{\frac{f_1(\mathbf{x})}{f_2(\mathbf{x})}}_{(1)} \geq \underbrace{\frac{c(1| \in \pi_2)}{c(2| \in \pi_1)}}_{(2)} \cdot \underbrace{\frac{p_2}{p_1}}_{(3)} \right\}$$

- (1): razão das densidades das duas classes
- (2): razão de custos
- (3): razão de probabilidades a priori

- Prova: Queremos  $R_1$  e  $R_2$  que minimizem EMC:

$$EMC = c(2| \in \pi_1) \mathbb{P}(\mathbf{X} \in R_2 | \in \pi_1) \mathbb{P}(\pi_1) + c(1| \in \pi_2) \mathbb{P}(\mathbf{X} \in R_1 | \in \pi_2) \mathbb{P}(\pi_2)$$

$\int_{R_2} f_1(\mathbf{x}) d\mathbf{x}$        $\int_{R_1} f_2(\mathbf{x}) d\mathbf{x}$

- Como  $R_1 \cup R_2 = \mathbb{R}^p$  então

$$1 = \int_{\mathbb{R}^p} f_1(\mathbf{x}) d\mathbf{x} = \int_{R_1} f_1(\mathbf{x}) d\mathbf{x} + \int_{R_2} f_1(\mathbf{x}) d\mathbf{x}.$$

- e podemos escrever a primeira integral em EMC (em azul) da seguinte forma:

$$\int_{R_2} f_1(\mathbf{x}) d\mathbf{x} = 1 - \int_{R_1} f_1(\mathbf{x}) d\mathbf{x}$$

- Vamos agora substituir a integral azul em EMC pela expressão em vermelho.

# Trabalhando EMC...

- Temos

$$EMC = c(2| \in \pi_1) \left( 1 - \int_{R_1} f_1(x) dx \right) \mathbb{P}(\pi_1) + c(1| \in \pi_2) \int_{R_1} f_2(x) dx \mathbb{P}(\pi_2)$$

- Agora, as duas integrais possuem a mesma região  $R_1$  de integração e portanto os dois integrandos podem ser colocados sob o mesmo sinal de integral. Isto implica que

$$EMC = c(2| \in \pi_1) \mathbb{P}(\pi_1) + \int_{R_1} (c(1| \in \pi_2) \mathbb{P}(\pi_2) f_2(x) - c(2| \in \pi_1) \mathbb{P}(\pi_1) f_1(x)) dx$$

- Queremos escolher  $R_1$  de forma que EMC seja mínimo.

$$EMC = c(2| \in \pi_1) \mathbb{P}(\pi_1) + \int_{R_1} \underbrace{(c(1| \in \pi_2) \mathbb{P}(\pi_2) f_2(x) - c(2| \in \pi_1) \mathbb{P}(\pi_1) f_1(x))}_{h(x)} dx$$

- O 1º termo não envolve  $R_1$ .
- Vamos olhar o 2º termo
- Escolher  $R_1$  é escolher a região em que vamos integrar (“somar”)  $h(x)$ .
- A expressão  $h(x)$  não envolve  $R_1$ .
- Para alguns  $x$ , teremos  $h(x) > 0$ ; para outros pontos  $x$ , teremos  $h(x) < 0$
- Para minimizar EMC, devemos tornar a integral o mais negativa possível.
- Conseguimos isto escolhendo  $R_1 = \{x \in \mathbb{R}^p \text{ tais que } h(x) \leq 0\}$ .
- Isso minimiza EMC!!

- ECM é minimizado se escolhermos

$$R_1 = \{x \in \mathbb{R}^p \text{ tais que } h(x) \leq 0\}$$

$$\begin{aligned} EMC &= c(2| \in \pi_1) \mathbb{P}(\pi_1) + \int_{R_1} \underbrace{(c(1| \in \pi_2) \mathbb{P}(\pi_2) f_2(x) - c(2| \in \pi_1) \mathbb{P}(\pi_1) f_1(x))}_{h(x)} dx \\ &= c(2| \in \pi_1) \mathbb{P}(\pi_1) + I \quad \text{onde } I = \int_{R_1} h(x) dx \end{aligned}$$

onde  $I = \int_{R_1} h(x) dx$ .

- Veja que  $h(x) \leq 0$  é o mesmo que

$$c(1| \in \pi_2) \mathbb{P}(\pi_2) f_2(x) - c(2| \in \pi_1) \mathbb{P}(\pi_1) f_1(x) \leq 0$$

- Passando o segundo termo para o outro lado da desigualdade e as posições, temos

$$c(2| \in \pi_1) \mathbb{P}(\pi_1) f_1(x) \geq c(1| \in \pi_2) \mathbb{P}(\pi_2) f_2(x)$$

ou ainda, após rearranjar os termos,

$$\frac{f_1(x)}{f_2(x)} \geq \frac{c(1| \in \pi_2)}{c(2| \in \pi_1)} \frac{\mathbb{P}(\pi_2)}{\mathbb{P}(\pi_1)}$$

- Para ficar em paz com esta afirmação, defina  
 $R_1 = \{x \in \mathbb{R}^P \text{ tais que } h(x) \leq 0\}$  e seja  $E_1$  o valor do ECM com esta regra de classificação .
- Se  $x \notin R_1$  então  $h(x) > 0$ .
- Seja  $R_1^* = A \cup R_1$  uma nova regra de classificação (com  $A \cap R_1 = \emptyset$ ) com ECM dado por  $E_1^*$
- Veremos que  $E_1 \leq E_1^*$ .

- Temos

$$\begin{aligned} E_1^* &= c(2| \in \pi_1) \mathbb{P}(\pi_1) + \int_{R_1^*} h(\mathbf{x}) \, d\mathbf{x} \\ &= c(2| \in \pi_1) \mathbb{P}(\pi_1) + \int_{R_1 \cup A} h(\mathbf{x}) \, d\mathbf{x} \\ &= c(2| \in \pi_1) \mathbb{P}(\pi_1) + \int_{R_1} h(\mathbf{x}) \, d\mathbf{x} + \underbrace{\int_A h(\mathbf{x}) \, d\mathbf{x}}_{>0} \\ &\geq c(2| \in \pi_1) \mathbb{P}(\pi_1) + \int_{R_1} h(\mathbf{x}) \, d\mathbf{x} = E_1 \end{aligned}$$

- Assim, aumentar a região  $R_1$  com qualquer outra região  $A$  nunca será capaz de fazer o ECM ser menor que aquele de  $R_1$ .
- Um argumento análogo, mostra que definir uma nova região para a classe 1 subtraindo uma área qualquer de  $R_1$  também nunca leva a um ECM menor (exercício).

## Resumo: Optimal Bayes Classifier

- Em cada caso, observamos o vetor aleatório  $\mathbf{X}$ .
- Existem duas populações:  $\pi_1$  e  $\pi_2$ .
- Um novo caso vem da pop  $\pi_1$  com probabilidade  $p_1$  e da pop  $\pi_2$  com probabilidade  $p_2 = 1 - p_1$ .
- As densidades de  $\mathbf{x}$ :  $f_1(\mathbf{x})$  e  $f_2(\mathbf{x})$ .
- Existem dois custos de classificação errada:  $c(2| \in \pi_1)$  e  $c(1| \in \pi_2)$
- Baseado em  $\mathbf{x}$ , queremos predizer a sua classe: 1 ou 2.
- Cada regra de classificação tem seu ECM = custo esperado de má-classificação (custo médio se classificarmos vários itens).
- Dentre todas as regras possíveis, aquela que torna mínimo o ECM é:  
aloque o caso a  $\pi_1$  caso

$$\frac{f_1(\mathbf{x})}{f_2(\mathbf{x})} \geq \frac{c(1| \in \pi_2)}{c(2| \in \pi_1)} \frac{\mathbb{P}(\pi_2)}{\mathbb{P}(\pi_1)}$$

## Resumo: Optimal Bayes Classifier

- Regra ótima de Bayes:

$$\frac{f_1(x)}{f_2(x)} \geq \underbrace{\frac{c(1| \in \pi_2)}{c(2| \in \pi_1)} \frac{\mathbb{P}(\pi_2)}{\mathbb{P}(\pi_1)}}_{\text{cte. em } x}$$

- A regra é bem intuitiva, gera um algoritmo muito simples.
- Recebemos um novo caso com atributos no vetor  $x$ .
- Qual sua classe? 1 ou 2?
- Calcule  $f_1(x)/f_2(x)$ , a razão de densidades no ponto  $x$  (aprox, é a razão das “probabilidades” de observar  $x$  em 1 ou 2).
- Se esta razão for “grande”, aloque a 1. Razoável, não?
- De fato, se  $f_1(x)/f_2(x) \approx 7$ , então a chance de observar  $x$  em 1 é aprox 7 vezes maior que a mesma chance em 2.
- Parece razoável alocar a 1. Mas...

## Resumo: Optimal Bayes Classifier



- Por quê não alocar a 1 simplesmente se tivermos  $f_1(x)/f_2(x) > 1$ ? Isto é, se  $f_1(x) > f_2(x)$ , devemos alocar a 1?
- Nem sempre.
- Queremos levar em conta os custos e diferentes frequências das classes na população total.
- Como fazer isto?
- Basta calcular: (a) a razão de custos, (b) a razão de probabilidades *a priori*, e multiplicá-las.
- Este valor não depende de  $x$ , é uma constante.
- A beleza não é porque a regra é muito simples. Qualquer um pode bolar uma regra simples.
- A beleza é que a regra é muito simples e é a *melhor possível e imaginável*. Nada pode ser melhor que ela (para reduzir o ECM).

## Exemplo uni-dimensional

- Imagine que  $\pi_1$  é uma classe rara:  $p_1 = 0.02$
- É muito pior errar quando o item é de  $\pi_1$ :  $c(2| \in \pi_1) = 40c(1| \in \pi_2)$ .
- A regra é então alocar a 1 toda vez que  $f_1(x)/f_2(x) \geq (1/40) \times (0.98/0.02) = 1.22$ .
- Ou seja, se  $f_1(x) \geq 1.22 f_2(x)$ , aloque a 1.
- Suponha que as duas densidades sejam como a seguir.
- Como encontrar a região de alocação a  $\pi_1$ ?

## Exemplo uni-dimensional

- Na esquerda, temos o plot de  $f_1(x)$  (preto) e  $f_2(x)$  (azul).
- Na direita, temos  $f_1(x)$  e  $1.22 \times f_2(x)$ .
- Aloque a 1 toda vez que a curva preta for maior que a curva azul neste plot da direita.



## Classificação ótima com duas gaussianas

- Densidade de uma  $N_p(\mu, \Sigma)$  no ponto  $\mathbf{x} \in \mathbb{R}^p$ :

$$\begin{aligned} f(\mathbf{x}) &= \underbrace{\left[ (2\pi)^{-p/2} |\Sigma|^{-1/2} \right]}_{\text{constante em } \mathbf{x}} \exp \left( -\frac{1}{2} \underbrace{(\mathbf{x} - \boldsymbol{\mu})^t \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu})}_{\text{Mahalanobis}} \right) \\ &= k \exp \left( -\frac{1}{2} d_{\Sigma}^2(\mathbf{x}, \boldsymbol{\mu}) \right) \end{aligned}$$

- Queremos a razão de duas densidades gaussianas,  $f_1(\mathbf{x}) \sim N_p(\boldsymbol{\mu}_1, \Sigma_1)$  e  $f_2(\mathbf{x}) \sim N_p(\boldsymbol{\mu}_2, \Sigma_2)$ , no mesmo ponto  $\mathbf{x}$ :

$$\begin{aligned} \frac{f_1(\mathbf{x})}{f_2(\mathbf{x})} &= \frac{k_1 \exp \left( -\frac{1}{2} d_{\Sigma_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) \right)}{k_2 \exp \left( -\frac{1}{2} d_{\Sigma_2}^2(\mathbf{x}, \boldsymbol{\mu}_2) \right)} \\ &= \frac{k_1}{k_2} \exp \left( -\frac{1}{2} (d_{\Sigma_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) - d_{\Sigma_2}^2(\mathbf{x}, \boldsymbol{\mu}_2)) \right) \end{aligned}$$

# Classificação ótima com duas gaussianas

- A regra ótima é: aloque a  $\pi_1$  se

$$\frac{f_1(\mathbf{x})}{f_2(\mathbf{x})} \geq \frac{c(1| \in \pi_2)}{c(2| \in \pi_1)} \frac{\mathbb{P}(\pi_2)}{\mathbb{P}(\pi_1)}$$

- Portanto, aloque a  $\pi_1$  se

$$\frac{k_1}{k_2} \exp\left(-\frac{1}{2}(d_{\Sigma_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) - d_{\Sigma_2}^2(\mathbf{x}, \boldsymbol{\mu}_2))\right) \geq \frac{c(1| \in \pi_2)}{c(2| \in \pi_1)} \frac{\mathbb{P}(\pi_2)}{\mathbb{P}(\pi_1)}$$

- Tomando logs dos dois lados e mudando de lado alguns termos, temos que alocar a  $\pi_1$  se:

$$d_{\Sigma_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) \leq d_{\Sigma_2}^2(\mathbf{x}, \boldsymbol{\mu}_2) + 2 \left[ \log\left(\frac{c(2| \in \pi_1)}{c(1| \in \pi_2)}\right) + \log\left(\frac{\mathbb{P}(\pi_1)}{\mathbb{P}(\pi_2)}\right) + \log\left(\frac{k_2}{k_1}\right) \right]$$

- Vamos entender um pouco melhor esta fórmula.

## Classificação ótima com duas gaussianas

- Repetindo, alocar a  $\pi_1$  se:

$$d_{\Sigma_1}^2(x, \mu_1) \leq d_{\Sigma_2}^2(x, \mu_2) + 2\log\left(\frac{c(2| \in \pi_1)}{c(1| \in \pi_2)}\right) + 2\log\left(\frac{\mathbb{P}(\pi_1)}{\mathbb{P}(\pi_2)}\right) + 2\log\left(\frac{k_2}{k_1}\right)$$

↑                   ↑                   ↑                   ↑                   ↑  
Mahalanobis    Mahalanobis    custos           prioris           covariâncias

- Ideia: aloque a  $\pi_1$  se a distância de Mahalanobis de  $x$  a  $\mu_1$  for menor que a distância de Mahalanobis a  $\mu_2$  mais ou menos “alguma coisa”.
- O “alguma coisa” leva em conta os custos, prioris e estruturas de covariância de cada população.
- Esta fórmula mostra a *melhor* maneira de levar estes aspectos em conta.
- Por exemplo, os custos devem ser analisados em função de sua diferença *relativa* e numa escala log.
- Por exemplo, não é a diferença  $c(2| \in \pi_1) - c(1| \in \pi_2)$  que nos interessa, mas sim  $c(2| \in \pi_1)/c(1| \in \pi_2)$ .

## Classificação ótima com duas gaussianas

- Repetindo, alocar a  $\pi_1$  se:

$$d_{\Sigma_1}^2(x, \mu_1) \leq d_{\Sigma_2}^2(x, \mu_2) + 2\log\left(\frac{c(2| \in \pi_1)}{c(1| \in \pi_2)}\right) + 2\log\left(\frac{\mathbb{P}(\pi_1)}{\mathbb{P}(\pi_2)}\right) + 2\log\left(\frac{k_2}{k_1}\right)$$

Mahalanobis      Mahalanobis      custos      prioris      covariancias

- O termo envolvendo os custos dos dois erros desaparece se eles forem iguais.
- Aquele envolvendo as probabilidades *a priori* também desaparece se  $\mathbb{P}(\pi_1) = \mathbb{P}(\pi_2)$ .
- Do mesmo modo, se  $\Sigma_1 = \Sigma_2$ , o último termo desaparece.
- Neste caso em que todos estes termos desaparecem, a regra ótima simplesmente compara as distâncias de Mahalanobis": alocar a  $\pi_1$  se

$$d_{\Sigma}^2(x, \mu_1) \leq d_{\Sigma}^2(x, \mu_2)$$

## Classificação ótima com duas gaussianas

- Vamos começar a introduzir os termos adicionais, um de cada vez, para entender seu efeito.
- Suponha que os custos sejam diferentes e que um deles é 100 vezes maior que o outro:  $c(2| \in \pi_1) = 100c(1| \in \pi_2)$ .
- Isto é, é 100 mais pior alocar um caso de  $\pi_1$  erradamente que alocar errado um caso de  $\pi_2$ .
- Deveríamos ser *menos propensos* então a alocar um caso a  $\pi_2$ .
- De fato, neste caso, a regra ótima é alocar  $x$  a  $\pi_1$  se

$$d_{\Sigma}^2(x, \mu_1) \leq d_{\Sigma}^2(x, \mu_2) + 2 \log(100)$$

- Agora ficou mais fácil alocar um caso a  $\pi_1$ . A distância de Mahalanobis a  $\pi_1$  nem precisa ser a menor delas agora.
- Lembre-se: esta é a regra ótima, a melhor possível.

## Classificação ótima com duas gaussianas

- Do mesmo modo, suponha que a classe 1 seja 100 vezes mais frequente que a classe 2:  $\mathbb{P}(\pi_1) = 100\mathbb{P}(\pi_2)$ .
- Isto é, quando um caso qualquer aparece, sem considerar o valor de  $x$ , sabemos que é 100 mais provável que ele seja de  $\pi_1$  do que de  $\pi_2$ .
- Novamente, deveríamos ser *menos propensos* então a alocar um caso a  $\pi_2$ .
- Como antes, a regra ótima é alocar  $x$  a  $\pi_1$  se

$$d_{\Sigma}^2(x, \mu_1) \leq d_{\Sigma}^2(x, \mu_2) + 2 \log(100)$$

## Classificação ótima com duas gaussianas

- Por último, para ver o efeito do terceiro termo, vamos imaginar que a variável  $x$  é uni-dimensional.
- Assim,  $\Sigma_1 = \sigma_1^2$  e  $\Sigma_2 = \sigma_2^2$ , as variâncias de  $X$  em cada população.
- Além disso, a distância de Mahalanobis reduz-se a  $d_{\Sigma}^2(x, \mu) = ((x - \mu)/\sigma)^2$ , o desvio padronizado.
- Suponha que uma das populações tenha variância muito maior que a outra:  $\sigma_2^2 = (10)^2 \sigma_1^2$ .
- Isto é, pontos de  $\pi_2$  espalham-se em torno de sua média  $\mu_2$  muito mais que pontos de  $\pi_1$  em torno de  $\mu_1$ .
- A regra ótima é alocar  $x$  a  $\pi_1$  se

$$\left(\frac{x - \mu_1}{\sigma_1}\right)^2 \leq \left(\frac{x - \mu_2}{\sigma_2}\right)^2 + \log(100)$$

- Assim, penalizamos a população com maior dispersão. Pense assim, se as duas distâncias padronizadas forem iguais, o melhor é alocar à  $\pi_1$ , a menos dispersa.

## Caso gaussiano com $\Sigma_1 = \Sigma_2$

- Alocar a  $\pi_1$  se:

$$d_{\Sigma_1}^2(x, \mu_1) - d_{\Sigma_2}^2(x, \mu_2) \leq 2 \log \left( \frac{c(2| \in \pi_1) \mathbb{P}(\pi_1)}{c(1| \in \pi_2) \mathbb{P}(\pi_2)} \right) + 2 \log \left( \frac{k_2}{k_1} \right)$$

- Se  $\Sigma_1 = \Sigma_2$ , os seus determinantes também são iguais e  $k_2 = k_1$ .
- Vamos denotar a constante (em  $x$ ) do lado esquerdo, envolvendo as probabilidades a priori e os custos de  $K$ :

$$K = \log \left( \frac{c(2| \in \pi_1) \mathbb{P}(\pi_1)}{c(1| \in \pi_2) \mathbb{P}(\pi_2)} \right)$$

- A regra ótima no caso gaussiano com covariâncias iguais é alocar a  $\pi_1$  se

$$d_{\Sigma_1}^2(x, \mu_1) - d_{\Sigma_2}^2(x, \mu_2) \leq 2K$$

## Caso gaussiano com $\Sigma_1 = \Sigma_2$

- Alocar a  $\pi_1$  se  $d_{\Sigma_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) - d_{\Sigma_2}^2(\mathbf{x}, \boldsymbol{\mu}_2) \leq 2K$
- Expandimos a expressão da distância:

$$\begin{aligned} d_{\Sigma_1}^2(\mathbf{x}, \boldsymbol{\mu}_1) &= (\mathbf{x} - \boldsymbol{\mu}_1)^t \boldsymbol{\Sigma}_1^{-1} (\mathbf{x} - \boldsymbol{\mu}_1) \\ &= \mathbf{x}^t \boldsymbol{\Sigma}_1^{-1} \mathbf{x} + \boldsymbol{\mu}_1^t \boldsymbol{\Sigma}_1^{-1} \boldsymbol{\mu}_1 - 2\mathbf{x}^t \boldsymbol{\Sigma}_1^{-1} \boldsymbol{\mu}_1 \end{aligned}$$

- Do mesmo modo, expandimos a outra distância. Cancelamos o termo  $\mathbf{x}^t \boldsymbol{\Sigma}_1^{-1} \mathbf{x}$  encontrando: aloque  $\mathbf{x}$  a  $\pi_1$  se

$$\begin{aligned} 0 &\leq \underbrace{\mathbf{x}^t \boldsymbol{\Sigma}_1^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)}_{p \times 1, \quad \beta} + \underbrace{(\boldsymbol{\mu}_2^t \boldsymbol{\Sigma}_2^{-1} \boldsymbol{\mu}_2 - \boldsymbol{\mu}_1^t \boldsymbol{\Sigma}_1^{-1} \boldsymbol{\mu}_1 - K)}_{1 \times 1, \quad \alpha} \\ &= \alpha + \boldsymbol{\beta}^t \mathbf{x} \end{aligned}$$

usando que  $\boldsymbol{\beta}^t \mathbf{x} = \mathbf{x}^t \boldsymbol{\beta}$ .

## Caso gaussiano com $\Sigma_1 = \Sigma_2$

- Vamos escrever  $\lambda(\mathbf{x}) = \alpha + \boldsymbol{\beta}^t \mathbf{x}$ .
- O conjunto de pontos  $\mathbf{x} \in \mathbb{R}^p$  tais que  $\lambda(\mathbf{x}) = 0$  constitui a fronteira de decisão (decision boundary).
- No caso em que  $\mathbf{x} \in \mathbb{R}^2$ , esta fronteira é uma linha reta.
- Se  $\mathbf{x} \in \mathbb{R}^3$ , a fronteira é um plano.
- Passar para o notebook python para ilustrar.

## Caso gaussiano com $\Sigma_1 \neq \Sigma_2$

- É o caso gaussiano com  $\Sigma_1 \neq \Sigma_2$ ?
- Manipulação matricial da regra ótima leva à conclusão de que a fronteira de decisão é uma parábola, e não mais uma reta.
- A fórmula geral do caso gaussiano, como já sabemos, alocar a  $\pi_1$  se:

$$d_{\Sigma_1}^2(x, \mu_1) - d_{\Sigma_2}^2(x, \mu_2) \leq 2 \log \left( \frac{c(2| \in \pi_1) \mathbb{P}(\pi_1)}{c(1| \in \pi_2) \mathbb{P}(\pi_2)} \right) + 2 \log \left( \frac{k_2}{k_1} \right)$$

- Expandindo as fórmulas quadráticas das distâncias, exatamente como fizemos antes, leva a uma expressão simples.

## Caso gaussiano com $\Sigma_1 \neq \Sigma_2$

- Alocar  $\mathbf{x}$  a  $\pi_1$  se:

$$\mathbf{x}^t \mathbf{A} \mathbf{x} - 2\beta^t \mathbf{x} + \alpha \leq 0$$

com  $\mathbf{A}$  sendo uma matriz  $p \times p$ ,  $\beta$  sendo um vetor coluna  $p \times 1$  e  $\alpha$  sendo um escalar (um número real). Mais especificamente,

$$\mathbf{A} = \Sigma_1^{-1} - \Sigma_2^{-1}$$

$$\beta = \Sigma_1^{-1} \mu_1 - \Sigma_2^{-1} \mu_2$$

- A constante  $\alpha$  é uma expressão um pouco mais longa:

$$\alpha = (\mu_1^t \Sigma_1^{-1} \mu_1 - \mu_2^t \Sigma_2^{-1} \mu_2) - 2 \log \left( \frac{c(2| \in \pi_1) \mathbb{P}(\pi_1)}{c(1| \in \pi_2) \mathbb{P}(\pi_2)} \right) - 2 \log \left( \frac{|\Sigma_2|}{|\Sigma_1|} \right)$$

## Caso gaussiano bi-dimensional, com $\Sigma_1 \neq \Sigma_2$

- No caso em que  $x \in \mathbb{R}^2$ , a fronteira ótima de Bayes é uma forma quadrática em  $x_1$  e  $x_2$ .
- Isto é, a fronteira de decisão  $\lambda(x) = 0$  (o conjunto de pontos que separa as duas classes) será uma expressão do seguinte tipo:

$$c_1x_1^2 + c_2x_2^2 + c_3x_1x_2 + c_4x_1 + c_5x_2 + c_6 = 0$$

onde as constantes  $c_j$  são determinadas pelos parâmetros das duas distribuições, pelos custos e pelas probabilidades a priori.

- A fronteira  $\lambda(x) = 0$  costuma ser uma curva que lembra o formato de uma parábola (mas não é exatamente uma parábola).
- Ver notebook python para exemplos.

# Pros e Cons of Optimal Bayes Classifier

- Precisa conhecer a densidades.
- Se não conhecer, precisa estimá-las e então terá erro de estimacao
- Em principio: estimar via kde (kernel). Entao, a dificuldade será encontrar a regiao em espacos multi-dimensionais.
- Eh otima apenas para ECM. Não optimiza para outras funções objetivo.
- Vantagens: otima; simples; intuitiva;