

# Support Vector Machines

## Mineração de Dados

Ronaldo C. Prati<sup>1</sup>


---

<sup>1</sup>Universidade Federal do ABC (UFABC), [ronaldo.prati@ufabc.edu.br](mailto:ronaldo.prati@ufabc.edu.br)

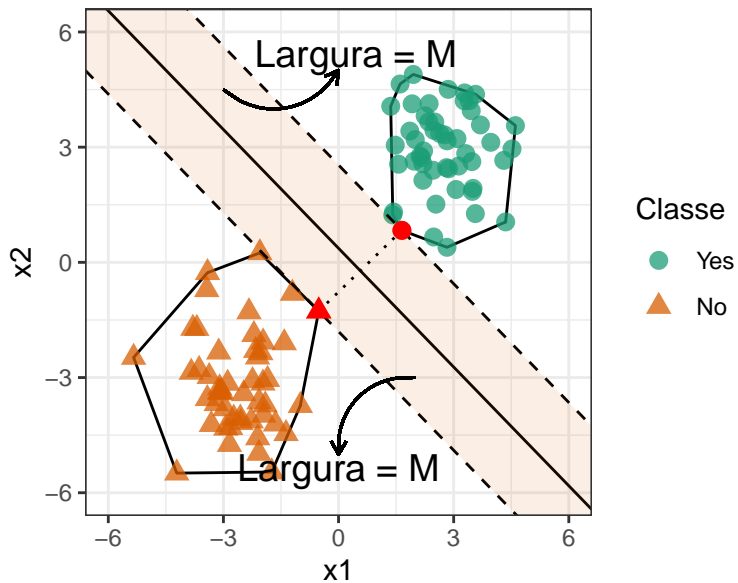
# SVM's

- ▶ Máquinas de vetores de suporte são uma outra família de algoritmos de aprendizado de máquina supervisionado
  - ▶ Na forma mais simples, é um classificador linear
  - ▶ Busca maximizar a margem de separação entre as classes
  - ▶ O uso de funções *kernel* pode estender para classificadores não lineares

## Classificadores Lineares



# SVM



## Função de custo (Regressão Logística)

Seja  $z = b_0 + b_1x_1 + b_2x_2 + \cdots + b_mx_m = b_0 + \mathbf{b}^T\mathbf{x}$  a reta que define a fronteira de decisão da regressão logística

A função de custo é:

$$Custo(y, \hat{y}) = \begin{cases} -\log\left(\frac{1}{1+e^z}\right), & \text{se } y = 1 \\ -\log\left(1 - \frac{1}{1+e^z}\right), & \text{se } y = 0 \end{cases}$$


## Função de custo (SVM)

Nas SMVs, função de custo é:


$$Custo(y, \hat{y}) = \begin{cases} \max(0, 1 - z), & \text{se } y = 1 \\ \max(0, 1 + z), & \text{se } y = 0 \end{cases}$$

# Comparando os custos

$y = 1$



$y = 0$



## Comparando os custos

- ▶ Na regressão logística queremos:
  - ▶ se  $y = 1$ ,  $\hat{y} \approx 1$  e  $z > 0$
  - ▶ se  $y = 0$ ,  $\hat{y} \approx 0$  e  $z < 0$
- ▶ SVM também é conhecida como **classificador de margem larga**, queremos:
  - ▶ se  $y = 1$ ,  $z \geq 1$  (não apenas  $> 0$ )
  - ▶ se  $y = 0$ ,  $z \leq -1$  (não apenas  $< 0$ )



## Minimizando o custo

Para encontrar o hiperplano, queremos que

$$\sum_{i=1}^n y \times \text{custo}(y, \hat{y}) + (1 - y) \times \text{custo}(y, \hat{y})$$

seja próximo a zero. Isso é equivalente a


$$\min_{\mathbf{b}} \sum_{j=1}^m b_j$$

sujeito a:


$$\mathbf{b}^T \mathbf{x} \geq 1 \text{ se } y = 1, \mathbf{b}^T \mathbf{x} \leq 1 \text{ se } y = 0$$

## Maximização da margem

- ▶  $\mathbf{b}$  é ortogonal a  $\mathbf{b}\mathbf{x}$  (geometria analítica)
- ▶ é possível mostrar que  $\min_{\mathbf{b}} \sum_{j=1}^m b_j$  corresponde a maximizar a margem





# Outliers



- ▶ Para lidar com possível outliers, podemos usar o conceito de margem “*soft*”
- ▶ De maneira simplista, corresponde a admitir uma pequena violação na margem, de maneira que alguns exemplos possam estar dentro dela
- ▶ É um hiperparâmetro do algoritmo

C

 $C = 0$  $C = \infty$ 


# Kernel

- ▶ O **kernel** é útil quando queremos computar uma fronteira de decisão não linear
- ▶ A ideia consiste em calcular um novo espaço de atributos
- ▶ Kernels são uma outra maneira de fazer isso


# Kernel

- O *kernel gaussiano* usa uma função de similaridade baseada na função gaussiana.


**Espaço Original**



**Espaço de entrada aumentado**



**Fronteira de decisão não linear**



# SVM com kernel gaussiano

- ▶ Parâmetro  $C$  da SVM
  - ▶  $C$  grande leva a uma hipótese com baixo bias/alta variância: overfitting
  - ▶  $C$  pequeno leva a uma hipótese com alto bias/baixa variância: underfitting
- ▶ Parâmetro  $\sigma^2$  do Kernel Gaussiano
  - ▶  $\sigma^2$  grande - os atributos variam mais suavemente - alto bias, baixa variância
  - ▶  $\sigma^2$  pequeno - os atributos variam mais abruptamente - baixo bias, alta variância



## Outros Kernels

- ▶ Linear (não usar kernel)
- ▶ Polinomial (parecido com a ideia de usar polinômios de maior grau)
- ▶ String
- ▶  $\chi^2$
- ▶ Intersecção de histograma

Cada um tem um conjunto próprio de parâmetros

# Fronteira de decisão

