

# CEiNE.

Centro de Investigación en  
Inteligencia de Negocios



**Support Vector Machines**  
**Ricardo Muñoz**



INGENIERIA INDUSTRIAL  
UNIVERSIDAD DE CHILE



**fcfm**

FACULTAD DE CIENCIAS  
FÍSICAS Y MATEMÁTICAS  
UNIVERSIDAD DE CHILE

# Contenido

- 1. Introducción
- 2. Caso Separable
- 3. Caso No-Separable
- 4. Extensiones



# Ejemplo introductorio

## Caso Retención de Clientes: “detección de fuga”.

- Dada ciertas características del cliente (edad, ingreso, crédito, saldo promedio, comportamiento en general) (atributos)
- Determinar si el cliente cerrará su cuenta corriente en los próximos meses.

*Aprender de información de otros clientes, generar alguna “Regla” y aplicar esta regla a casos nuevos.*

# Teoría de Aprendizaje Estadístico

## Minimización del riesgo empírico

Queremos encontrar una función  $f$  que minimice:


$$R_{\text{emp}}[f] = \frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2$$

Donde  $y$  es el valor conocido del objeto  $x$ ,  $f(x)$  es la función de inducción y  $n$  es el número de objetos

# Motivación SVM

Caso particular de dos conjuntos linealmente disjuntos en  $\mathbb{R}^2$

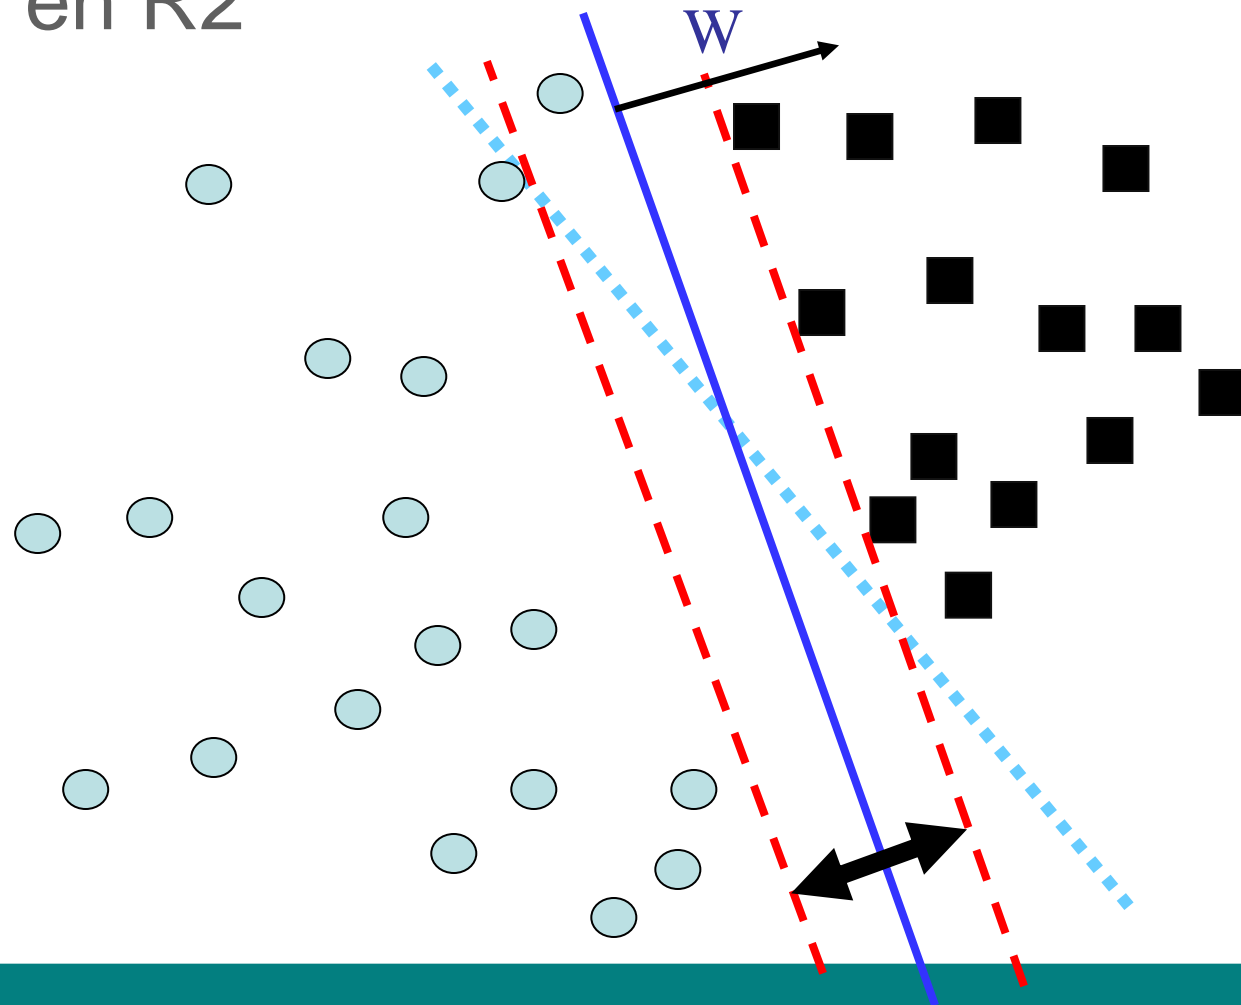
■ : No cierra  
○ : Cierra



# Motivación SVM

Caso particular de dos conjuntos linealmente disjuntos en  $\mathbb{R}^2$

- : No cierra
- : Cierra

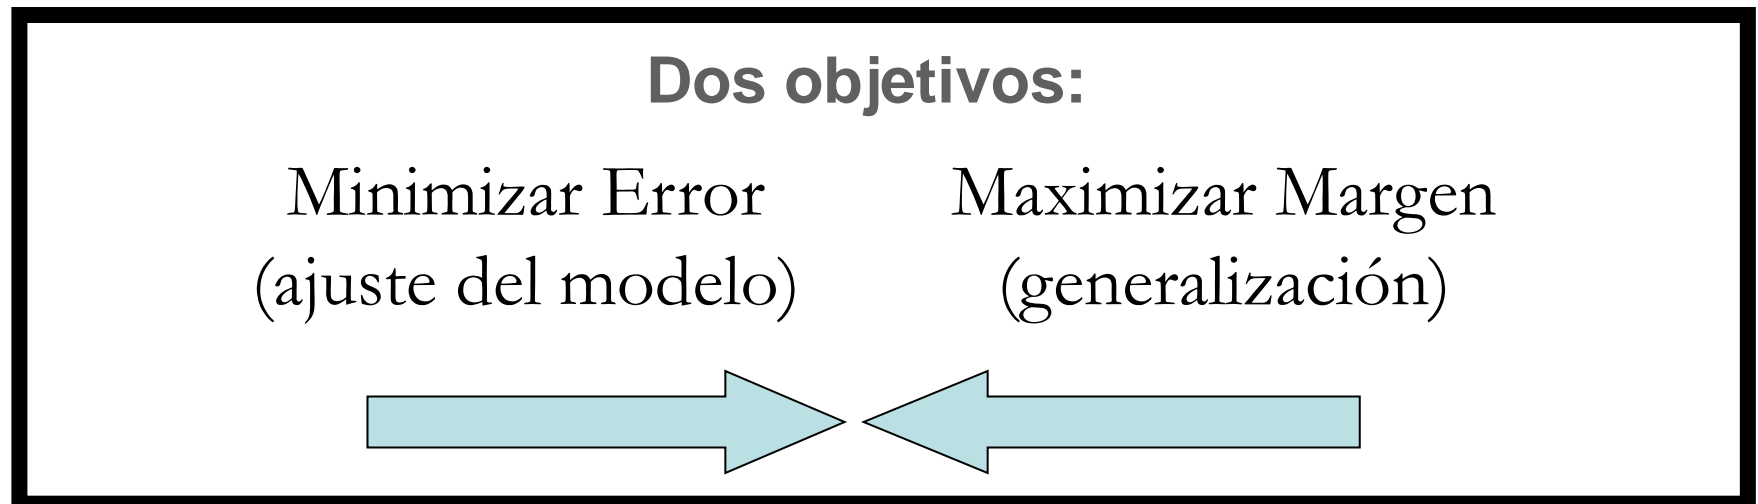


# Support Vector Machines (Para Clasificación)

IDEA:

Construir una función clasificadora que:

- Minimice el error en la separación de los objetos dados (del conjunto de entrenamiento)
- Maximice el margen de separación (mejora la generalización del clasificador en conjunto de test)



# SVM Lineal – Caso Separable

$N$  objetos que consisten del par :  $\mathbf{x}_i \in \mathbb{R}^m, i=1, \dots, n$  y de su “etiqueta” asociada  $y_i \in \{-1, 1\}$

Supongamos que  $\exists$  un hiperplano separador  $\mathbf{w} \cdot \mathbf{x} + b = 0$  que separa los ejemplos positivos de los ejemplos negativos. Esto es, Todos los objetos del conjunto de entrenamiento satisfacen:

$$x_i \cdot w + b \geq +1 \text{ cuando } y_i = +1$$

$$x_i \cdot w + b \leq -1 \text{ cuando } y_i = -1$$

equivalentemente:


$$y_i (x_i \cdot w + b) - 1 \geq 0 \forall i$$

Sean  $d_+$  ( $d_-$ ) las distancias más cercanas desde el hiperplano separador al ejemplo positivo (negativo) más cercano. El *margen* del hiperplano separador se define como  $d_+ + d_-$



# SVM Lineal – Caso Separable

$w \cdot x + b = 0$



# Formulación matemática (SVM primal)

1/Margen



$$\text{Minimizar } \frac{1}{2} \|w\|^2$$

sujeto a :

$$y_i (x_i \cdot w + b) - 1 \geq 0$$

$w$ : Normal al hiperplano  
separador.


$b$  : Posición del hiperplano

$X_i$ : Objetos de entrenamiento

$Y_i$  : Clase del objeto  $i$ .

# Formulación matemática (SVM L dual)

KERNELS!!!



Luego...

$$\text{Maximizar } \sum \alpha_i - \frac{1}{2} \sum \alpha_i \alpha_s y_i y_s x_i x_s$$

sujeto a :

$$\alpha_i \geq 0 \quad i = 1, \dots, n$$

$$\sum_{i=1}^n \alpha_i y_i = 0$$

# SVM Lineal – Caso No Separable

$N$  objetos que consisten en el par :  $\mathbf{x}_i \in \mathbb{R}^m, i=1, \dots, n$  y de su “etiqueta” asociada  $y_i \in \{-1, 1\}$

Se introducen variables de holgura positivas  $\xi_i$ :

$$x_i \cdot w + b \geq +1 - \xi_i \quad \text{cuando } y_i = +1$$

$$x_i \cdot w + b \leq -1 + \xi_i \quad \text{cuando } y_i = -1$$

Y se modifica la función objetivo a:


$$\|w\|^2 / 2 + C(\sum \xi_i)$$

# Formulación matemática (SVM primal)

1/Margen



Error en  
clasificación



$$\text{Minimizar } \frac{1}{2} \|w\|^2 + C \sum \xi_i$$

sujeto a :

$$y_i (x_i \cdot w + b) - 1 + \xi_i \geq 0$$

$$\xi_i \geq 0$$

$w$ : Normal al hiperplano  
separador.

$b$  : Posición del hiperplano


$X_i$ : Objetos de entrenamiento

$Y_i$  : Clase del objeto  $i$ .

$\xi_i$  : Error en la separación

# Formulación matemática (SVM dual)

KERNELS!!!



Luego...

$$\text{Maximizar } \sum \alpha_i - \frac{1}{2} \sum \alpha_i \alpha_s y_i y_s x_i x_s$$

sujeto a :

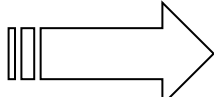
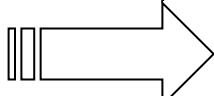
$$C \geq \alpha_i \geq 0 \quad i = 1, \dots, n$$

$$\sum_{i=1}^n \alpha_i y_i = 0$$


# Clasificador

- El clasificador lineal de los SVM es:

$$f(x) = \mathbf{W} \cdot x + b = \sum_i \alpha_i y_i \cdot x + b$$

- Se determina el signo de la función  $f(x)$ 
  - Si  $\text{signo}(f(x)) = +1$   pertenece a clase +1
  - Si  $\text{signo}(f(x)) = -1$   pertenece a clase -1

# SVM no lineal




Objetos linealmente no separables en  $\mathbb{R}^2$ , pueden serlo otro espacio



# SVM no lineal

- Idea:
  - Proyectar los objetos a un espacio de mayor dimensión y realizar una clasificación lineal en este nuevo espacio.
  - Función de transformación
  - $K(x_i, x_s) = \Phi(x_i) \cdot \Phi(x_s)$
  - Basta reemplazar  $x_i, x_s$  por  $K(x_i, x_s)$


# Kernel Machines



$$\Phi(\cdot)$$

$$\mathbf{X}_i = \Phi(\mathbf{x}_i)$$


$$\mathbf{X} = \Phi(\mathbf{x})$$



$$\mathbf{X}_i \cdot \mathbf{X} = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x})$$

$$y = \text{sign} \left( \sum_{i \in S} \alpha_i y_i \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}) + b \right)$$

$$y = \text{sign} \left( \sum_{i \in S} \alpha_i y_i \mathbf{X}_i \cdot \mathbf{X} + b \right)$$



$$\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}) = K(\mathbf{x}_i, \mathbf{x})$$

Condición de Mercer

$$y = \text{sign} \left( \sum_{i \in S} \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b \right)$$

# Funciones de Kernel

$$K(\mathbf{x}, \mathbf{y}) = (\mathbf{x} \cdot \mathbf{y} + 1)^p$$

$$K(\mathbf{x}, \mathbf{y}) = e^{-\|\mathbf{x} - \mathbf{y}\|^2 / 2\sigma^2}$$

$$K(\mathbf{x}, \mathbf{y}) = \tanh(\kappa \mathbf{x} \cdot \mathbf{y} - \delta)$$

# SVM para selección de atributos

- Idea:  
Penalizar en la función objetivo por cada atributo utilizado.
- Función de penalización:  
Penalizar si el coeficiente asociado al atributo es mayor que cero.

$$f(x) = e - \exp(-\alpha x)$$

$$\alpha > 0$$

e :vector de unos

# SVM para selección de atributos

$$\text{Minimizar } \frac{1}{2} \|W\|^2 + C_1 \sum \xi_i + \boxed{C_2 e^T (e - \exp(-\alpha v))}$$

sujeto a :

$$y_i (x_i \cdot w + b) - 1 + \xi_i \geq 0$$

$$\xi_i \geq 0$$

$$-v \leq w \leq v$$

$$v \geq 0$$



# Características de SVM

- Herramienta matemática
- No tiene mínimos locales (árboles de decisión)
- No tiene el problema de Overfitting (Redes Neuronales)
- Solución no depende de estructura del planteamiento del problema.
- Aplicabilidad en distintos tipos de problemas (Clasificación, Regresión, descubrimiento de patrones en general)

# Referencias

- Apuntes Curso “Introducción a la minería de datos”, Richard Weber.
- C. Burges, A tutorial on support vector machines for pattern recognition, *Data Mining and Knowledge Discovery* 2 (1998), no. 2, 121–167

# CEiNE.

Centro de Investigación en  
Inteligencia de Negocios



INGENIERIA INDUSTRIAL  
UNIVERSIDAD DE CHILE



fcfm

FACULTAD DE CIENCIAS  
FÍSICAS Y MATEMÁTICAS  
UNIVERSIDAD DE CHILE