

# Máquinas de Vectores Soporte (SVM)

Norberto Corral, Carlos Carleos

12 de noviembre de 2025

# Máquinas de Vectores Soporte (SVM)

Dados  $\vec{w} \in \mathbb{R}^p$  y  $b \in \mathbb{R}$ , fijos, se define una aplicación lineal  $f : \mathbb{R}^p \rightarrow \mathbb{R}$  como:

$$f(\vec{x}) = \langle \vec{w}, \vec{x} \rangle + b = \vec{w}^\top \vec{x} + b = \sum_{j=1}^p w_j x_j + b$$

Se llama hiperplano,  $\pi$ , al subconjunto de puntos  $\mathbb{R}^p$  que verifican:

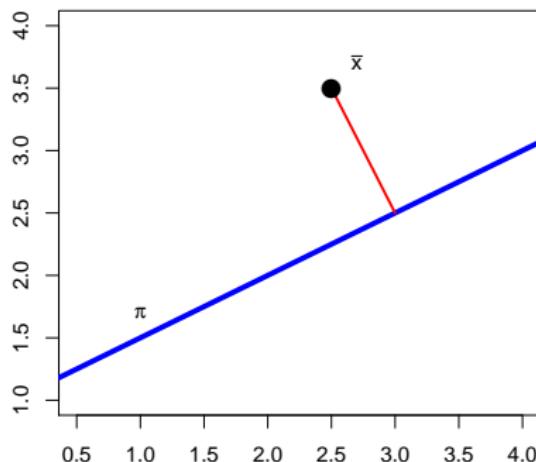
$$\pi = \{ \vec{x} \mid f(\vec{x}) = 0 \}$$

Cualquier hiperplano de  $\mathbb{R}^2$  define una recta.

# Máquinas de Vectores Soporte (SVM)

El vector  $\vec{w}$  es ortogonal a todos los puntos del hiperplano.  
La distancia entre un hiperplano  $\pi$  y un punto  $\vec{x} \in \mathbb{R}^p$  es:

$$\text{dist}(\pi, \vec{x}) = \frac{f(\vec{x})}{\|\vec{w}\|} \quad \text{con} \quad \|\vec{w}\| = \sqrt{\sum_{j=1}^p w_j^2}$$



# Máquinas de Vectores Soporte (SVM)

## Conjunto linealmente separable

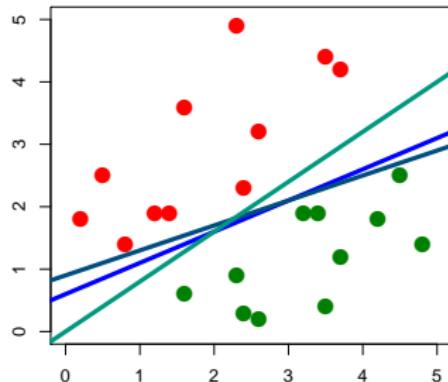
Un conjunto de puntos  $(\vec{x}_i, y_i)_{i=1}^n$  con  $\vec{x}_i \in \mathbb{R}^p$ ,  $y_i \in \{-1, +1\}$ , es linealmente separable si existe un hiperplano  $\pi$  tal que:

- ▶  $f(\vec{x}_i) = \langle \vec{w}, \vec{x}_i \rangle + b \geq 0 \quad \text{si } y_i = +1$
- ▶  $f(\vec{x}_i) = \langle \vec{w}, \vec{x}_i \rangle + b \leq 0 \quad \text{si } y_i = -1$

Esas dos condiciones son equivalentes a:

$$y_i f(\vec{x}_i) = y_i(\langle \vec{w}, \vec{x} \rangle + b) \geq 0 \quad i = 1, \dots, n$$

# Máquinas de Vectores Soporte (SVM)



Cuando existe un hiperplano de separación un criterio razonable para clasificar un punto  $\vec{x}$  es:

$$G(\vec{x}) = \text{signo}(f(\vec{x}))$$

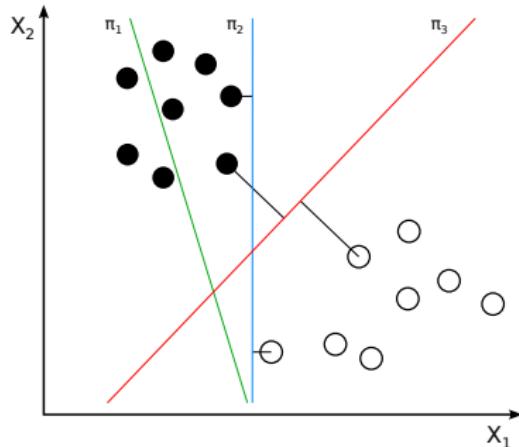
# Máquinas de Vectores Soporte (SVM)

## Margin de un hiperplano de separación

Dado un conjunto de puntos  $(\vec{x}_i)_{i=1}^n$  con  $\vec{x}_i \in \mathbb{R}^p$ , y un hiperplano de separación  $\pi = \{\vec{x} \mid \vec{w}^\top \vec{x} + b = 0\}$  se define su margen como el valor  $M$  tal que

$$M = \min_{i=1, \dots, n} \text{dist}(\vec{x}_i, \pi)$$

- ▶  $\pi_1$  no es hiperplano de separación
- ▶  $\pi_2$  es hiperplano de separación con margen pequeño
- ▶  $\pi_3$  es el hiperplano de separación con margen máximo



# Máquinas de Vectores Soporte (SVM)

## Hiperplano óptimo

Es el hiperplano de separación con margen máximo. El problema se puede plantear como la búsqueda del hiperplano óptimo de separación, es decir,

Maximizar  $M$

$$y_i \cdot \frac{\langle \vec{w}, \vec{x}_i \rangle + b}{\|\vec{w}\|} \geq M \quad \forall i = 1, \dots, n$$

Si

$$y_j \cdot \frac{\langle \vec{w}, \vec{x}_j \rangle + b}{\|\vec{w}\|} = M$$

entonces  $\vec{x}_j$  es un **vector soporte**.

# Máquinas de Vectores Soporte (SVM)

Como solamente interviene la dirección de  $\vec{w}$  y no su norma, se puede imponer la condición

$$M \cdot \|\vec{w}\| = 1 \iff M = \frac{1}{\|\vec{w}\|}$$

$$\begin{aligned} & \text{Maximizar } \frac{1}{\|\vec{w}\|} \\ & y_i [\langle \vec{w}, \vec{x} \rangle + b] \geq 1 \iff \text{Minimizar } \|\vec{w}\| \\ & \iff y_i [\langle \vec{w}, \vec{x} \rangle + b] - 1 \geq 0 \\ & \qquad \qquad \qquad \text{Minimizar } \frac{1}{2} \|\vec{w}\|^2 \\ & \qquad \qquad \qquad y_i [\langle \vec{w}, \vec{x} \rangle + b] - 1 \geq 0 \end{aligned}$$

# Máquinas de Vectores Soporte (SVM)

- ▶ Problema de optimización cuadrática con restricciones lineales.
- ▶ Se aplican las condiciones de Karush–Kuhn–Tucker (KKT) a un *problema cuadrático convexo* con restricciones lineales.
  - ▶ formulación general
  - ▶ función Lagrangiana
  - ▶ condiciones KKT y su interpretación

# Máquinas de Vectores Soporte (SVM)

## Problema cuadrático convexo con restricciones lineales (general)

Sea el problema

$$\begin{aligned} & \text{minimizar } f(\vec{x}) = \frac{1}{2} \vec{x}^T Q \vec{x} + \vec{c}^T \vec{x}, \\ & \text{sujeto a } A \vec{x} \geq \vec{b}, \end{aligned}$$

con  $Q$  simétrica y semidefinida positiva (convexo),  
 $A \in \mathbb{R}^{m \times n}$ .

**Objetivo:** encontrar  $\vec{x}^*$  que minimice  $f$  cumpliendo las restricciones.

# Máquinas de Vectores Soporte (SVM)

## Función Lagrangiana

Introducimos multiplicadores  $\vec{\lambda} \in \mathbb{R}^m$  (uno por restricción), con  $\lambda_i \geq 0$ . La lagrangiana es

$$L(\vec{x}, \vec{\lambda}) = \frac{1}{2} \vec{x}^\top Q \vec{x} + \vec{c}^\top \vec{x} - \vec{\lambda}^\top (A \vec{x} - \vec{b}).$$

Interpretación: se incorporan las restricciones al objetivo con pesos  $\lambda_i$ .

# Máquinas de Vectores Soporte (SVM)

## Condiciones KKT

Un par  $(\vec{x}^*, \vec{\lambda}^*)$  que satisfaga las siguientes condiciones es óptimo (en problemas convexos estas condiciones son necesarias y suficientes):

- ▶ Estacionariedad:  $\nabla_{\vec{x}} L(\vec{x}^*, \vec{\lambda}^*) = 0$ .
- ▶ Factibilidad primal:  $A\vec{x}^* \geq \vec{b}$ .
- ▶ Factibilidad dual:  $\vec{\lambda}^* \geq 0$ .
- ▶ Complementariedad:  $\lambda_i^*(A_i\vec{x}^* - b_i) = 0, \quad \forall i$ .

Aquí  $A_i$  denota la  $i$ -ésima fila de  $A$ .

# Máquinas de Vectores Soporte (SVM)

## Interpretación de la estacionariedad

La derivada de  $L$  respecto a  $\vec{x}$ :

$$\nabla_{\vec{x}} L = Q\vec{x} + \vec{c} - A^T \vec{\lambda}.$$

La estacionariedad exige

$$Q\vec{x}^* + \vec{c} - A^T \vec{\lambda}^* = \vec{0}.$$

Esta ecuación relaciona la solución primal  $\vec{x}^*$  con los multiplicadores duales.

# Máquinas de Vectores Soporte (SVM)

## Interpretación de la complementariedad

La condición  $\lambda_i^*(A_i\vec{x}^* - b_i) = 0$  implica:

- ▶ Si  $\lambda_i^* > 0$  entonces  $A_i\vec{x}^* = b_i$   
(la restricción está activa).
- ▶ Si  $A_i\vec{x}^* > b_i$  entonces  $\lambda_i^* = 0$   
(la restricción tiene holgura).

Por tanto los  $\lambda_i^*$  son “precios sombra”: cuánto cambiaría el objetivo al relajar  $b_i$  en una unidad.

# Máquinas de Vectores Soporte (SVM)

## Dualidad fuerte

Definimos el problema dual como

$$\max_{\vec{\lambda} \geq 0} \inf_{\vec{x}} L(\vec{x}, \vec{\lambda}).$$

Para problemas convexos con condiciones de regularidad (p. ej. Slater), existe *dualidad fuerte*: el valor óptimo primal coincide con el valor óptimo dual. Esto permite resolver el problema a través del dual cuando convenga.

# Máquinas de Vectores Soporte (SVM)

## Formulación primal en SVM (separable)

$$\text{minimizar } \frac{1}{2} \|\vec{w}\|^2$$

$$\text{sujeto a } y_i(\langle \vec{w}, \vec{x}_i \rangle + b) \geq 1, \quad i = 1, \dots, n$$

Es un problema cuadrático convexo con restricciones lineales en  $(\vec{w}, b)$ .

# Máquinas de Vectores Soporte (SVM)

## Función Lagrangiana

Multiplicadores:  $\alpha_i \geq 0$  (uno por punto)

$$L(\vec{w}, b, \vec{\alpha}) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^n \alpha_i [y_i (\langle \vec{w}, \vec{x}_i \rangle + b) - 1].$$

# Máquinas de Vectores Soporte (SVM)

## KKT: condiciones explícitas

Estacionariedad:

$$\frac{\partial L}{\partial \vec{w}} = 0 \Rightarrow \vec{w}^* = \sum_{i=1}^n \alpha_i^* y_i \vec{x}_i$$

$$\frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^n \alpha_i^* y_i = 0$$

Factibilidad primal:

$$y_i(\langle \vec{w}^*, \vec{x}_i \rangle + b^*) \geq 1$$

Factibilidad dual:  $\alpha_i^* \geq 0$

Complementariedad:

$$\alpha_i^* [y_i(\langle \vec{w}^*, \vec{x}_i \rangle + b^*) - 1] = 0, \quad \forall i$$

# Máquinas de Vectores Soporte (SVM)

De las KKT se deduce:

- ▶ Si  $y_i(\langle \vec{w}^*, \vec{x}_i \rangle + b^*) > 1$  entonces  $\alpha_i^* = 0$  (punto estrictamente dentro del margen).
- ▶ Si  $y_i(\langle \vec{w}^*, \vec{x}_i \rangle + b^*) = 1$  entonces  $\alpha_i^* > 0$  (punto en el margen: vector soporte).

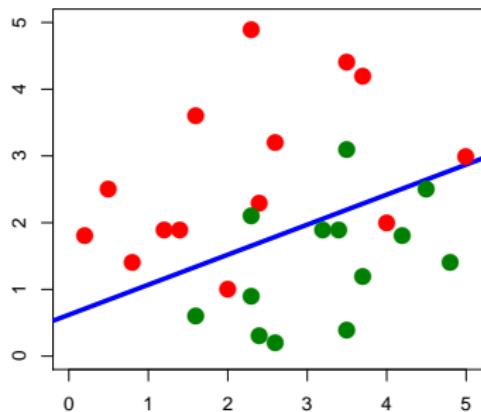
Por tanto la solución se expresa como combinación lineal de *pocos* vectores.

# Máquinas de Vectores Soporte (SVM)

En la mayor parte de los problemas reales no existen hiperplanos de separación y se plantea la búsqueda de hiperplanos que verifiquen unas condiciones más suaves:

$$y_i \cdot (\langle \vec{w}, \vec{x}_i \rangle + b) \geq 1 - \xi_i \quad \text{con } \xi_i \geq 0 \quad i = 1, \dots, n$$

- ▶ Las variables  $\xi_i$  se denominan de holgura y permiten la existencia de puntos mal clasificados.
- ▶ Cuando  $\xi_i = 0$ , es el problema anterior.



# Máquinas de Vectores Soporte (SVM)

El nuevo problema de optimización viene dado por:

$$L(\vec{w}, \xi) = \frac{1}{2} \langle \vec{w}, \vec{w} \rangle + C \sum_{i=1}^n \xi_i$$

sujeto a las restricciones

$$y_i \cdot (\langle \vec{w}, \vec{x}_i \rangle + b) + \xi_i - 1 \geq 0; \quad \xi_i \geq 0; \quad i = 1, \dots, n$$

C representa la penalización de los puntos mal clasificados.

Estos hiperplanos se denominan de margen blando.

# Máquinas de Vectores Soporte (SVM)

- La función lagrangiana del hiperplano de margen blando es:

$$L(\vec{w}, b, \vec{\xi}, \vec{\alpha}, \vec{\beta}) =$$

$$= \frac{1}{2} \langle \vec{w}, \vec{w} \rangle + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i [y_i (\langle \vec{w}, \vec{x}_i \rangle + b) + \xi_i - 1] - \sum_{i=1}^n \beta_i \xi_i$$

- Aplicando las condiciones KKT se obtiene

$$\forall i = 1, \dots, n : \quad \frac{\partial L}{\partial \vec{w}} = 0 \iff \vec{w}^* = \sum_{i=1}^n \alpha_i^* \cdot y_i \cdot \vec{x}_i$$

$$\frac{\partial L}{\partial b} = 0 \iff \sum_{i=1}^n \alpha_i^* \cdot y_i = 0$$

$$\frac{\partial L}{\partial \xi_i} = 0 \iff C = \alpha_i^* + \beta_i^*$$

$$\alpha_i^* [1 - y_i (\langle \vec{w}^*, \vec{x}_i \rangle + b^*) - \xi_i^*] = 0$$

$$\beta_i^* \xi_i^* = 0$$

# Máquinas de Vectores Soporte (SVM)

Teniendo en cuenta las condiciones que debe cumplir la solución

$$C = \alpha_i^* + \beta_i^*; \quad \beta_i^* \xi_i^* = 0, \quad i = 1, \dots, n$$

$$\alpha_i^*[1 - y_i(\langle \vec{w}^*, \vec{x}_i \rangle + b^*) - \xi_i^*] = 0, \quad i = 1, \dots, n$$

se pueden caracterizar los puntos  $\vec{x}_i$ :

- $\vec{x}_i$  no es separable  $\iff \xi_i^* > 0$ . Por tanto  $\beta_i^* = 0$ ,  $\alpha_i^* = C$  y

$$y_i(\langle \vec{w}^*, \vec{x}_i \rangle + b^*) = 1 + \xi_i^*$$

- $\alpha_i^* = 0 \implies \beta_i^* = C$ ,  $\xi_i^* = 0$  y el punto  $\vec{x}_i$  es separable
- $0 < \alpha_i^* < C \iff \beta_i^* \neq 0 \iff \xi_i^* = 0$ . Por lo tanto

$$y_i(\langle \vec{w}^*, \vec{x}_i \rangle + b^*) = 1$$

es decir,  $\vec{x}_i$  es un vector soporte y permite estimar  $b^*$

$$b^* = \frac{1}{N_{vs}} \sum_{k=1}^{N_{vs}} (y_k - \langle \vec{w}^*, \vec{x}_k \rangle)$$

# Máquinas de Vectores Soporte (SVM)

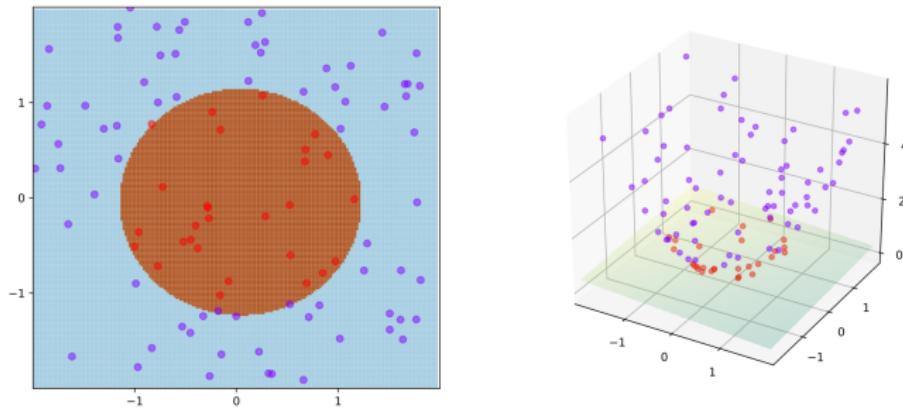
- ▶ Cuando las clases no son separables se plantea “pasar” los datos a un espacio de dimensión mayor en el que se cumpla la condición de separabilidad.

$$\begin{aligned}\Phi : \mathbb{X} &\rightarrow \mathcal{F} \\ \vec{x} &\mapsto \Phi(\vec{x}) = (\phi_1(\vec{x}), \dots, \phi_m(\vec{x}))\end{aligned}$$

donde alguna de las funciones  $\phi_j$  no es lineal.

- ▶ El espacio transformado se denomina *espacio de características*.
- ▶ El objetivo es buscar el hiperplano óptimo, en el espacio de características, que produce una frontera no lineal en el espacio inicial.

# Máquinas de Vectores Soporte (SVM)



Transformación (núcleo):  $(a, b) \rightarrow (a, b, a^2 + b^2)$

# Máquinas de Vectores Soporte (SVM)

## Funciones Núcleo

Sea  $K$  una función  $K : \mathbb{X} \times \mathbb{X} \rightarrow \mathbb{R}$   
que verifica las condiciones

1.  $K(\vec{x}_1, \vec{x}_2) = K(\vec{x}_2, \vec{x}_1)$  (simétrica)
2.  $K(\vec{x}, \vec{x}) \geq 0$  (semidefinida positiva)

Algunos ejemplos de funciones núcleo ( $\lambda > 0, \gamma > 0$ ):

- ▶  $K(\vec{x}_1, \vec{x}_2) = \langle \vec{x}_1, \vec{x}_2 \rangle$
- ▶  $K(\vec{x}_1, \vec{x}_2) = (\lambda \langle \vec{x}_1, \vec{x}_2 \rangle + \gamma)^\rho$
- ▶  $K(\vec{x}_1, \vec{x}_2) = \exp(-\lambda \langle \vec{x}_1 - \vec{x}_2, \vec{x}_1 - \vec{x}_2 \rangle) = \exp(-\lambda \|\vec{x}_1 - \vec{x}_2\|^2)$

# Máquinas de Vector Soporte

## Teorema de Moore-Aronszajn

Para cualquier función  $K : \mathbb{X} \times \mathbb{X} \rightarrow \mathbb{R}$  simétrica y semidefinida positiva, existe un espacio de Hilbert (normado y completo) y una función  $\Phi : \mathbb{X} \rightarrow F$  tal que

$$K(\vec{x}, \vec{x}') = \langle \Phi(\vec{x}), \Phi(\vec{x}') \rangle$$

Este resultado permite calcular el producto escalar  $\langle \Phi(\vec{x}), \Phi(\vec{x}') \rangle$  sin necesidad de conocer la función  $\Phi$ .

# Máquinas de Vectores Soporte (SVM)

## Derivación del problema dual

Recordando primera condición KKT (estacionariedad):

$$\frac{\partial L}{\partial \vec{w}} = 0 \Rightarrow \vec{w}^* = \sum_{i=1}^n \alpha_i^* y_i \vec{x}_i$$

Sustituyendo  $\vec{w} = \sum_j \alpha_j y_j \vec{x}_j$  en la lagrangiana y simplificando:

$$L(\vec{\alpha}) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \langle \vec{x}_i, \vec{x}_j \rangle.$$

Problema dual: maximizar  $L(\vec{\alpha})$  sujeto a

$$\sum_i \alpha_i y_i = 0, \quad \alpha_i \geq 0$$

# Máquinas de Vectores Soporte (SVM)

$$L(\vec{\alpha}) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \langle \vec{x}_i, \vec{x}_j \rangle.$$

Problema dual: maximizar  $L(\vec{\alpha})$  sujeto a

$$\sum_i \alpha_i y_i = 0, \quad \alpha_i \geq 0$$

Interpretación geométrica y algorítmica:

- ▶ El dual depende únicamente de productos escalares  $\langle \vec{x}_i, \vec{x}_j \rangle$ .
- ▶ Esto permite introducir un *kernel*  $K(\vec{x}_i, \vec{x}_j)$  y trabajar en espacios de características sin calcular  $\Phi$ .

# Máquinas de Vectores Soporte (SVM)

En el espacio de características se busca la función:

$$f(\vec{x}) = \langle \vec{w}, \Phi(\vec{x}) \rangle + b$$

que en su forma dual se expresa como:

$$f(\vec{x}) = \sum_{i=1}^n \alpha_i^* \cdot y_i \cdot K(\vec{x}, \vec{x}_i)$$

Se resuelve mediante el siguiente problema de optimización

$$\text{Max} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \langle \vec{x}_i, \vec{x}_j \rangle$$

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

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

# Máquinas de Vectores Soporte (SVM)

## El problema XOR

Caso	$(X_1, X_2)$	Y
1	$(+1, +1)$	-1
2	$(-1, -1)$	-1
3	$(+1, -1)$	+1
4	$(-1, +1)$	+1

Para representar el producto escalar en el espacio de las características se usa el siguiente kernel polinómico:

$$K(\vec{x}, \vec{x}') = (\langle \vec{x}, \vec{x}' \rangle + 1)^2$$

# Máquinas de Vectores Soporte (SVM)

El problema dual por resolver es:

$$\text{Maximizar} \quad \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \cdot \alpha_j \cdot y_i \cdot y_j \cdot K(\vec{x}, \vec{x}')$$

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

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

La solución de  $\alpha$  es:

$$\alpha^* = 0,125 \quad i = 1, \dots, 4$$

La función de clasificación que se obtiene es:

$$f(\vec{x}) = 0,125 \cdot \sum_{i=1}^4 y_i \cdot K(\vec{x}, \vec{x}')$$

# Máquinas de Vectores Soporte (SVM)

En este caso se pueden obtener las funciones de transformación.

$$\langle \Phi(\vec{x}), \Phi(\vec{x}') \rangle = K(\vec{x}, \vec{x}') = (\langle \vec{x}, \vec{x}' \rangle + 1)^2 =$$

$$1 + x_1^2(x'_1)^2 + x_2^2(x'_2)^2 + 2x_1x_2x'_1x'_2 + 2x_1x'_1 + 2x_2x'_2$$

con

$$\Phi = (\phi_1, \phi_2, \phi_3, \phi_4, \phi_5, \phi_6)$$

$$f(\vec{x}) = \frac{1}{\sqrt{2}}\phi_4(\vec{x}) = x_1x_2$$

# Máquinas de Vectores Soporte (SVM)

## Puntos débiles de las Máquinas de Vector Soporte

- ▶ Las MVS son muy sensibles a los parámetros que intervienen en su cálculo. Es aconsejable probar con diferentes valores y analizar los resultados y su estabilidad.
- ▶ En los problemas de clasificación es preferible usar un núcleo gausiano y la función objetivo basada en el coste  $C$ . En este caso sólo son necesarios los parámetros  $\lambda$  y  $C$ . Estrategias posibles de búsqueda:
  - ▶ Buscar un  $C$  adecuado probando con valores entre 1 y 1000, usando validación cruzada. Con el  $C$  seleccionado buscar el  $\lambda$  adecuado.
  - ▶ Buscar simultáneamente sobre  $\lambda$  y  $C$ , usando una malla.
- ▶ Las MVS son sensibles a las unidades de las variables y es conveniente realizar una tipificación previa.

# Máquinas de Vectores Soporte (SVM)

La librería `e1071` de R puede usarse para aplicar las máquinas de vector soporte.

```
library (e1071)
mvs_salida <- svm (y ~ x, datos.entrena)
mvs_pred   <- predict (mvs_salida, datos.prueba)
## para optimizar parámetros en una malla:
tune (svm, y ~ x, data = datos.entrena,
       ranges = list (cost=10^(-1:3),
                      gamma=10^(-3:0)))
```

Por omisión, usa núcleo gausiano (radial)  
donde  $\lambda = \text{gamma}$ .