

Máquinas de Vectores de Soporte

Casos No Lineales

Luis Norberto Zúñiga Morales

24 de agosto de 2022

- 1 Introducción de la idea general
- 2 Truco del Kernel

Funciones de Decisión No Lineales




Figura: ¿Cómo separarían los datos?


Funciones de Decisión No Lineales

- Una opción sería utilizar funciones complejas, como polinomios de alto grado. Por ejemplo, $y = 1$ si

$$\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_1 x_2 + \theta_4 x_1^2 + \dots \geq 0$$

y 0 en cualquier otro caso.

- No es buena idea:
 - Son computacionalmente caros.
 - ¿Cómo elegir la mejor función?



MVS Caso No Lineal

Durante la construcción del clasificador se llegó a la ecuación

$$\sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i H_{ij} \alpha_j$$

donde se construyó la matriz

$$H_{ij} = y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j$$

El producto punto de los vectores de entradas en la matriz anterior se puede representar como una función:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i \cdot \mathbf{x}_j = \mathbf{x}_i^T \mathbf{x}_j \quad (1)$$

Kernel

La función $k(\mathbf{x}_i, \mathbf{x}_j)$ es un ejemplo de una familia de funciones llamadas **kernels**, las cuales se basan en el calculo de productos puntos de los vectores de entrada del conjunto de datos.

Los kernels son funciones $x \mapsto \phi(x)$ que permiten mapear los datos a diferentes dimensiones **sin la necesidad de determinar la función ϕ** que realiza el mapeo.

Truco del Kernel

El **truco del kernel** permite atacar problemas que no son linealmente separables en el espacio en turno, y al realizar el mapeo por medio del kernel, es posible que en otro espacio sí sea separable.

MVS Caso No Lineal




Figura: Ejemplo de un caso no linealmente separable y como el truco del kernel puede ser de utilidad.

Truco del Kernel

Los kernels más comunes en la práctica son:

- Kernel Lineal: $k(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i \cdot \mathbf{x}_j$
- Kernel Polinomial: $[\gamma(\mathbf{x}_i \cdot \mathbf{x}_j) + r]^d$
- Kernel Función de Base Radial: $\exp(-\gamma \cdot \|\mathbf{x}_i - \mathbf{x}_j\|^2)$
- Kernel Sigmoid: $\tanh(\mathbf{x}_i \cdot \mathbf{x}_j + r)$

donde $\gamma > 0$ y $r, d \in \mathbb{R}$.

Truco del Kernel

Expresado en la formulación del clasificador en la ecuación del primal:

$$\begin{aligned} \text{mín} \quad & \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^L \xi_i \\ \text{sujeto a} \quad & y_i (\mathbf{w}^T \cdot \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i \quad \forall i \end{aligned} \tag{2}$$

Truco del Kernel

Y su dual en la ecuación

$$\begin{aligned} \max_{\alpha} \quad & \sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T \mathbf{H}_k \alpha \\ \text{sujeto a} \quad & 0 \leq \alpha_i \leq C \quad \forall_i \\ & \sum_{i=1}^L \alpha_i y_i = 0 \end{aligned} \tag{3}$$

donde

$$\mathbf{H}_k = y_i y_j k(\mathbf{x}_i, \mathbf{x}_j). \tag{4}$$

Truco del Kernel

1. Elegir de antemano cual es el kernel que se aplicará en la MVS y la función de mapeo $\phi(\mathbf{x})$. En práctica, el kernel de función de base radial funciona mejor.

Truco del Kernel

1. Elegir de antemano cual es el kernel que se aplicará en la MVS y la función de mapeo $\phi(\mathbf{x})$. En práctica, el kernel de función de base radial funciona mejor.
2. Crear \mathbf{H}_k , donde $H_{ij} = y_i y_j k(\mathbf{x}_i, \mathbf{x}_j)$.

Truco del Kernel

1. Elegir de antemano cual es el kernel que se aplicará en la MVS y la función de mapeo $\phi(\mathbf{x})$. En práctica, el kernel de función de base radial funciona mejor.
2. Crear \mathbf{H}_k , donde $H_{ij} = y_i y_j k(\mathbf{x}_i, \mathbf{x}_j)$.
3. Elegir el valor del parámetro C , el cual permitirá penalizar clasificaciones erróneas.

4. Encontrar las α_j que maximicen

$$\sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T \mathbf{H}_k \alpha$$

sujeto a las restricciones

$$0 \leq \alpha_j \leq C, \quad \sum_{i=1}^L \alpha_i y_i = 0.$$

mediante un programa para resolver problemas de optimización cuadrática.

4. Encontrar las α_j que maximicen

$$\sum_{i=1}^L \alpha_j - \frac{1}{2} \alpha^T \mathbf{H}_k \alpha$$

sujeto a las restricciones

$$0 \leq \alpha_j \leq C, \quad \sum_{i=1}^L \alpha_j y_i = 0.$$

mediante un programa para resolver problemas de optimización cuadrática.

5. Calcular $\mathbf{w} = \sum_{i=1}^L \alpha_i y_i \phi(\mathbf{x}_i)$.

- Determinar el conjunto de vectores de soporte S mediante la identificación de los índices i tales que $0 \leq \alpha_i \leq C$.

- Determinar el conjunto de vectores de soporte S mediante la identificación de los índices i tales que $0 \leq \alpha_i \leq C$.
- Calcular el valor de b mediante la ecuación

$$b = \frac{1}{N_S} \sum_{s \in S} (y_s - \sum_{k \in S} \alpha_k y_k k(\mathbf{x}_k, \mathbf{x}_s)).$$

Truco del Kernel

- Determinar el conjunto de vectores de soporte S mediante la identificación de los índices i tales que $0 \leq \alpha_i \leq C$.
- Calcular el valor de b mediante la ecuación

$$b = \frac{1}{N_S} \sum_{s \in S} (y_s - \sum_{k \in S} \alpha_k y_k k(\mathbf{x}_k, \mathbf{x}_s)).$$

- Cada elemento del conjunto de prueba x_t se clasifica evaluando

$$y_t = \text{sgn}(\mathbf{w}^T \cdot \phi(\mathbf{x}_t) + b).$$

Consideraciones sobre el Truco del Kernel

- 1 Usar el truco del kernel puede generar sobreajuste si se aplica en conjuntos de datos pequeños. Una solución es usar kernels no tan complejos.
- 2 Un kernel debe seguir ciertas reglas, las cuales no se cubren en este curso.

- 1 Investigar sobre el kernel de la función de Bessel.
- 2 Investigar sobre el kernel radial ANOVA.
- 3 Investigar sobre el kernel gaussiano.