


Support Vector Machines


SVM

Support Vector Machines (SVM) - Clasificador Lineal

- representa +1
- representa -1



SVM- Clasificador lineal



Cualquiera de estas rectas podría estar bien..


¿cuál es mejor?

$$f(\mathbf{x}, \mathbf{w}, b) = \text{signo}(\mathbf{w} \cdot \mathbf{x} + b)$$

SVM- Clasificador Lineal

Clasificador de máximo margen

- representa +1
- representa -1




SVM lineal:
Encontrar w y b tal que
márgen se máximo

$$f(\mathbf{x}, \mathbf{w}, b) = \text{sign}(\mathbf{w} \cdot \mathbf{x} + b)$$

SVM- Clasificador Lineal

Clasificador de máximo margen



Mediante un cambio de variable se puede ver que maximizar M es equivalente a minimizar $\frac{1}{2} \mathbf{w}^t \mathbf{w}$

De esa forma el problema de optimización se expresa como

$$\text{Minimizar } \Phi(\mathbf{w}) = \frac{1}{2} \mathbf{w}^t \mathbf{w}$$

Sujeto a las restricciones:

$$y_i (\mathbf{w} x_i + b) \geq 1 \quad \forall i$$

Solución del clasificador de máximo margen

De las condiciones KKT:

$$y_i(\langle x_i, w^* \rangle + b^*) - 1 \geq 0$$

$$\lambda_i \geq 0$$

$$\lambda_i(y_i(\langle x_i, w^* \rangle + b^*) - 1) = 0$$

$$\nabla L(w^*, b^*, \lambda) = 0, \text{ donde } L(w^*, b^*, \lambda) = \frac{1}{2} \|w^*\|^2 - \sum_{i=1}^n \lambda_i (y_i(\langle x_i, w^* \rangle + b^*) - 1)$$


De donde se obtiene:

$$w^* = \sum_{i=1}^n \lambda_i y_i x_i$$

$$b^* = \frac{1 - y_{i_0} \langle x_{i_0}, w^* \rangle}{y_{i_0}}$$

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

Vectores soporte




nsv: número de vectores soporte, Aquellos que tienen multiplicador no nulo

$$f(x) = \langle w^*, x \rangle + b^* = \sum_{i=1}^n \lambda_i y_i \langle x_i^*, x \rangle + b^* = \sum_{j=1}^{n_{SV}} \lambda_j y_j \langle x_j, x \rangle + b^*$$

El problema anterior puede no ser factible

Se pueden agregar variables auxiliares ξ_i que midan el error de los puntos que quedan mal clasificados de datos complejos o con ruido



En este caso el problema de optimización se modifica:

Minimizar
$$\frac{1}{2} \mathbf{w} \cdot \mathbf{w} + C \sum_{k=1}^R \varepsilon_k$$

Sujeto a:

$$y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i \quad \text{and} \quad \xi_i \geq 0 \text{ for all } i$$

La constante C pondera el peso que se le da a los errores de clasificación.

El caso no separable

- En este caso el Lagrangiano queda:


$$L(w, b, \xi, \lambda, \mu) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \lambda_i (y_i (\langle x_i, w \rangle + b) - 1 + \xi_i) - \sum_{i=1}^n \mu_i \xi_i.$$

- Planteando las condiciones KKT se obtiene una expresión similar a la anterior:

$$f(x) = \sum_{i=1}^{n_{SV}} \lambda_i y_i \langle x_i, x \rangle + b^*$$

SVM en el caso no lineal

- Para conjuntos de datos que se pueden separar linealmente y que contienen ruido funciona correctamente:




- Pero que sucede si los datos no pueden ser separados linealmente?



- La idea es mapear los datos a un espacio de dimensión mayor:


Ej.: Hacemos una transformación y pasamos de la recta a \mathbb{R}^2 mediante la transformación

$$\Phi: \mathbf{x} \rightarrow \varphi(\mathbf{x}) = (x, x^2)$$



SVM no lineal: Espacio de características

- Idea general: El espacio original puede siempre ser mapeado en un espacio de dimensión mayor donde la muestra de entrenamiento sea separable linealmente




Se puede probar que no es necesario conocer explícitamente la transformación Φ sino que alcanza con conocer la función que permite calcular el producto interno en el espacio de dimensión mayor. Esta función se llama Kernel o Núcleo

Ejemplo de algunas funciones de kernel

- Lineal: $K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$
- Polinomial de potencia p : $K(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i^T \mathbf{x}_j)^p$
- Gaussiana :
$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right)$$


Kernel: $K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / \sigma^2)$

plot by Bell SVM applet



SVM en regresión

- El problema de optimización se formula de manera similar al caso de clasificación
- Buscar el plano tal que en un tubo de radio ε caigan la mayor cantidad de puntos y penalizar a aquellos que queden fuera.



$$C \sum_{n=1}^N E_{\varepsilon}(f(x_n) - y_n) + \frac{1}{2} \|w\|^2$$

Variables auxiliares


Para que un punto caiga dentro del tubo:

$$f(x_n) - \epsilon \leq y_n \leq f(x_n) + \epsilon$$

Introducimos variables auxiliares para permitirle a los puntos a residir fuera del tubo:

$$y_n \leq f(x_n) + \epsilon + \xi_n$$

$$y_n \geq f(x_n) - \epsilon - \xi_n^-$$



$$\mathbf{f}(\mathbf{x}, \mathbf{w}, b) = \mathbf{w} \mathbf{x} + b \quad 14$$

Minimizamos la siguiente función de error:

Minimizar:

$$C \sum_{n=1}^N (\xi_n + \xi_n^-) + \frac{1}{2} \|w\|^2$$

Sujeto a:

$$\xi_n \geq 0 \quad y \quad y_n \leq f(x_n) + \epsilon + \xi_n$$

$$\xi_n^- \geq 0 \quad y_n \geq f(x_n) - \epsilon - \xi_n^-$$

Construimos el Lagrangiano

$$L = C \sum_{n=1}^N (\xi_n + \xi_n^-) + \frac{1}{2} \|w\|^2 - \sum_{n=1}^N (\mu_n \xi_n + \mu_n^- \xi_n^-) - \sum_{n=1}^N a_n (\epsilon + \xi_n + y_n - f(x_n)) - \sum_{n=1}^N a_n^- (\epsilon + \xi_n^- - y_n + f(x_n))$$

$$\frac{\partial L}{\partial w} = 0 \Rightarrow w = \sum_{n=1}^N (a_n - a_n^-) x_n$$

$$\frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{n=1}^N (a_n - a_n^-) = 0$$

$$\frac{\partial L}{\partial \xi_n} = 0 \Rightarrow a_n + \mu_n = C$$

$$\frac{\partial L}{\partial \xi_n^-} = 0 \Rightarrow a_n^- + \mu_n^- = C$$

Karush-Kuhn-Tucker (KKT)

Los vectores soporte son los puntos que se encuentran sobre la frontera del tubo o fuera de él.

$$a_n (\epsilon + \xi_n + y_n - f(x_n)) = 0$$

$$a_n^- (\epsilon + \xi_n^- - y_n + f(x_n)) = 0$$

$$(C - a_n) \xi_n = 0$$

$$(C - a_n^-) \xi_n^- = 0$$

La forma dual del Lagrangiano

Maximizar:

$$W(a, a^-) = -\frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N (a_n - a_n^-)(a_m - a_m^-)(x_n, x_m) - \epsilon \sum_{n=1}^N (a_n + a_n^-) + \sum_{n=1}^N (a_n - a_n^-) y_n$$

$$0 \leq a_n \leq C$$

$$0 \leq a_n^- \leq C$$

La predicción puede ser realizada utilizando:

$$y(x) = \sum_{n=1}^N (a_n - a_n^-)(x, x_n) + b$$

Referencias

- Está presentación está basada en los siguientes trabajos:
- A Tutorial on Support Vector Regression Alex J. Smola and Bernhard Schölkopf, *Statistics and Computing*, Volume 14, Number 3, August 2004 , pp. 199-222(24), Springer
- Prof. Andrew Moore's SVM tutorial at <http://www.cs.cmu.edu/~awm/tutorials>
- INTRODUCTION TO *Machine Learning* ETHEM ALPAYDIN © The MIT Press, 2004
- Vladimir N. Vapnik, *The nature of statistical learning theory*, Springer-Verlag New York, Inc., New York, NY, 1995
- Support Vector Machine & Its Applications, Mingyue Tan, The University of British Columbia, November 2004