

Einführung in das maschinelle Lernen

Christian Pölitz

23. April 2014

Support Vector Maschinen

Eine kleine Wiederholung vom letzten Mal.

Maximal Margin Classifier

Für einen gegebenen Datensatz $S = \{(x_1, y_1), \dots, (x_n, y_n)\}$, suchen wir eine lineare Funktion $g(x) = \langle \beta, \phi(x) \rangle + \beta_0$, die für ein gegebenes x , ein korrespondierendes y vorhersagt.

Klassifikation

$y_i \in \{-1, 1\}$ und wir wollen $g(x_i) \leq -\gamma$ wenn $y_i = -1$ und $g(x_i) > \gamma$ sonst. Generell: $y_i \cdot (\langle \beta, \phi(x_i) \rangle + \beta_0) \geq \gamma$

Margin

Der Margin für einen Datensatz S und eine lineare Funktion $g(x)$ ist definiert durch: $m(S, g) = \min y_i \cdot g(x_i) \geq \gamma$.

Bild SVM




Abbildung: <http://yottamine.com/machine-learning-svm>

Formalisierung als Optimierungsaufgabe

$$\max \quad \gamma \quad (1)$$

$$\text{s.t.} \quad y_i \cdot (\langle \beta, \phi(x_i) \rangle + \beta_0) \geq \gamma \quad (2)$$

$$\|\beta\|^2 = 1 \quad (3)$$

Formalisierung als Optimierungsaufgabe als Minimierungsproblem

$$\min \quad -\gamma \quad (4)$$

$$s.t. \quad -y_i \cdot (\langle \beta, \phi(x_i) \rangle + \beta_0) + \gamma \leq 0 \quad (5)$$

$$\|\beta\|^2 = 1 \quad (6)$$

Lagrangian (Primales Problem)

$$L_P(\beta, \beta_0, \alpha, \lambda) = -\gamma - \sum_i \alpha_i \cdot (y_i \cdot (\langle \beta, \phi(x_i) \rangle + b) + \gamma) + \lambda \cdot (\|\beta\|^2 - 1)$$

Partielle Ableitungen

$$\frac{\partial L_P(\beta, \beta_0, \alpha, \lambda)}{\partial \beta} = \beta - \frac{1}{2} \cdot \lambda \cdot \sum_i \alpha_i \cdot y_i \cdot \phi(x_i) = 0$$

$$\frac{\partial L_P(\beta, \beta_0, \alpha, \lambda)}{\partial \beta_0} = -1 + \sum_i \alpha_i = 0$$

$$\frac{\partial L_P(\beta, \beta_0, \alpha, \lambda)}{\partial \gamma} = - \sum_i \alpha_i \cdot y_i = 0$$

Lagrangian (Duales Problem)

- $L_P(\alpha) = - \sum_{i,j} \alpha_i \cdot \alpha_j \cdot y_i \cdot y_j \cdot \phi(x)^T \phi(x) \rightarrow \max$
- $\sum_i \alpha_i \cdot y_i = 0$
- $\alpha_i \geq 0$

Form der Lösung

$\beta = \frac{1}{2} \cdot \lambda \cdot \sum_i \alpha_i \cdot y_i \cdot x_i$ und damit ist die Lösung eine lineares Funktional der Form $\sum_i a_i \cdot \phi(x_i)$.

Kernel Methoden

- Einbettung der Daten in einem Vektorraum V
- In diesem Vektorraum werden lineare Beziehungen und trennende Funktionale gesucht
- Algorithmen arbeiten nicht auf den Elementen von V , sondern mit paarweisen inneren Produkten $\langle \cdot, \cdot \rangle$

Bild Kernel Methoden




Abbildung:

http://commons.wikimedia.org/wiki/File:Kernel_Machine.png

Kernel

Inneres Produkt in V , das von einer Abbildung ϕ kommt.

- $k(x, y) = \langle \phi(x), \phi(y) \rangle$
- $\phi : x \rightarrow \phi(x) \in V$

Beispiel

$$\phi((x_1, x_2)) = (x_1^2, x_2^2, \sqrt{2} \cdot x_1 \cdot x_2) \in V = \mathbb{R}^3$$

Beispiel




Abbildung: <http://nlp.stanford.edu/IR-book/html/htmledition/nonlinear-svms-1.html>

Beispiel

Zwei Teilmengen A_1 und A_2 einer Menge Ω $k(A_1, A_2) = 2^{|A_1 \cap A_2|}$
ist ein inneres Produkt der Abbildung:

$$\phi(A)_U = \begin{cases} 1, & U \subseteq A \\ 0, & \text{otherwise} \end{cases} \quad (7)$$

U sind Teilmengen von Ω , also Elemente der Potentmenge von Ω .

Hilbertraum

Ein vollständiger normierter Vektorraum mit einem inneren Produkt $\langle \cdot, \cdot \rangle$ ist ein Hilbertraum.

- Vollständig heißt, dass alle Cauchy Folgen konvergieren
- Ein Vektorraum ist eine Menge, die bezüglich Addition und Skalarmultiplikation (mit Skalaren eines bestimmten Körpers) abgeschlossen ist

Inneres Produkt

- Symmetrische Bilinearform: $\langle \alpha \cdot x, \beta \cdot y \rangle = \alpha \cdot \bar{\beta} \cdot \langle x, y \rangle$
- Positiv definit: $\langle x, x \rangle \geq 0$ und $\langle x, x \rangle = 0 \iff x = 0$
- Norminduzierend: $\|x\| = \sqrt{\langle x, x \rangle}$
- Standard Inner Product: $\langle x, y \rangle = \sum x_i \cdot y_i$

Winkel

- $\cos \theta = \frac{\langle x, y \rangle}{\|x\| \cdot \|y\|}$
- $\theta = 0 \Rightarrow \cos \theta = 1$ und $\langle x, y \rangle = \|x\| \cdot \|y\|$
- $\theta = \frac{\pi}{2} \Rightarrow \cos \theta = 0$ und $\langle x, y \rangle = 0$ Orthogonalität

Darstellung von Riesz

Es existiert eine isometrischer Isomorphismus von einem Hilbertraum V in seinen (stetigen) Dualraum V' . D.h. jedes Element $f_v \in V'$ genügt $f_v(x) = \langle x, v \rangle$. Die Punktauswertung ist ein stetiges lineares Funktional. Unsere Abbildungen sind also innere Produkte, die in einem Argument fest sind. $\phi(x) = \langle x, \cdot \rangle$.

Beispiel

Die Menge aller Folgen reellwertiger Zahlen

$l_2(\mathbb{N}) = \{(x_1, \dots, x_n, \dots) \mid \sum x_i^2 < \infty\}$ mit dem inneren Produkt
 $\langle x, y \rangle = \sum x_i \cdot y_i$ ist ein Hilbertraum.

Beispiel

Die Menge der quadratintegrierbaren Funktionen
 $L_2(X) = \{f \mid \int_X f(x)^2 \cdot dx < \infty\}$ mit dem inneren Produkt
 $\langle x, y \rangle = \int_X f(x) \cdot g(x) \cdot dx$ ist ein Hilbertraum.

Gram Matrix

Alle paarweise inneren Produkte für eine Menge S können in einer Matrix $G_{i,j} = \langle \phi(x_i), \phi(x_j) \rangle = k(x, y)$ zusammengefasst werden. Diese Matrix ist symmetrisch und positiv definit.

Feature Raum F

Für die SVM suchen wir ein lineares Funktional $\beta = \sum \beta_i \cdot \phi(x_i)$.
Der Raum all dieser Funktionale ist ein Hilberraum (dessen Vervollständigung).

$$F = \left\{ \sum b_i \cdot k(x_i, \cdot) \right\}$$

Inneres Produkt in F

Sei $f = \sum \alpha_i \cdot k(x_i, \cdot) \in F$ und $g = \sum \beta_i \cdot k(x_i, \cdot) \in F$. Wir definiere folgendes innere Produkt:

$$\langle f, g \rangle = \sum \sum a_i \cdot b_i \cdot k(x_i, x_j) = \sum a_i \cdot g(x_i) = \sum b_i \cdot f(x_i)$$

Reproducing Property

$$\langle f, k(x, \cdot) \rangle = \sum a_i \cdot k(x_i, \cdot) = f(x)$$

Die Abbildungen

$\phi : X \rightarrow \mathfrak{R}$, X muss kein Menge reeller Zahlen sein. Wir können auch komplexe Strukturen, wie Parse Bäume oder Sequenzen von Wörtern sein.

Abschlusseigenschaften

- Addition
- Skalarmultiplikation
- Multiplikation
- Verknüpfung