


Einführung in Support-Vektor-Maschinen

Einleitender Vortrag im Seminar
„Mustererkennung mit SVM“ WS 02/03

Übersicht

1. Lineare SVM:
 separabler Fall
2. Lineare SVM:
 nicht separabler Fall
3. Nichtlineare SVM
4. Eigenschaften
5. Anwendung
6. Zusammenfassung

1. Lineare SVM: separabler Fall



Annahmen


- Zweiklassenproblem
- Überwachtes Lernen:
Lerndatensatz aus n Beobachtungen

$$(x_1, y_1), \dots, (x_n, y_n) \in \mathbb{R}^d \times \{-1, +1\}$$


Linear separabler Fall

- Anschauliche Definition:
 - Daten **linear separabel**, wenn eine Hyperebene existiert, die die Daten separiert.
 - In \mathbb{R}^2 :

linear separabel



nicht linear separabel




14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg

5

Idee

- Trennende Hyperebene mit **größtem Rand**:



- Anschaulich sinnvoll
- Theoretisch sinnvoll
- Lösung abhängig von wenigen Daten (**Support Vektoren**)

14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg


6

Formalisierung

- Hyperebene
 - Menge der Punkte x mit $w \cdot x + b = 0$
 - $w \in \mathbb{R}^d$ Normalenvektor
 - $b \in \mathbb{R}$ skaliertes Abstand vom Ursprung

- Linearer Klassifikator

$$\hat{y}(x) = \text{sgn}(w \cdot x + b)$$



14.11.2002


B. Haasdonk, IIF-LMB, Universität Freiburg

7

- Beobachtung: $w \cdot x + b = 0 \Leftrightarrow aw \cdot x + ab = 0$
daher Normierung der Hyperebene:

$$\min_i |w \cdot x_i + b| = 1$$

hiermit ist Rand $\gamma = \frac{2}{\|w\|}$



- Ansatz als Optimierungsproblem:
Minimieren von $\|w\|^2$

mit $y_i(w \cdot x_i + b) \geq 1$ (\Leftrightarrow korrekt klassifiziert und leere Randzone)

14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg

8

Optimierungsproblem

- Verallgemeinerte Lagrangefunktion

Minimiere

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i [y_i (w \cdot x_i + b) - 1]$$

mit $\alpha_i \geq 0$

- Duale Formulierung

Maximiere

$$L'(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j (x_i \cdot x_j)$$

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

- numerische Lösung via Karush-Kuhn-Tucker-Bedingungen (KKT).

14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg

9

Lösung

- Lösung α des dualen Problems liefert gewünschte Hyperebene

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

$$b = - \frac{\max_{y_i=-1} (w \cdot x_i) + \min_{y_i=1} (w \cdot x_i)}{2}$$

- Beobachtungen:

- Für alle Beispiele außerhalb des Randes ist $\alpha_i = 0$
=> „spärliche“ Darstellung der Lösung!!
- $\alpha_i \neq 0$ => x_i Support-Vektor,
- Eindeutigkeit der Ebene, globales Optimum.

14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg

10

Entscheidungsregel


- Einsetzen von w :

$$\begin{aligned}\hat{y}(x) &= \text{sgn}(w \cdot x + b) \\ &= \text{sgn}\left(\sum_{i:\alpha_i \neq 0} \alpha_i y_i(x_i \cdot x) + b\right)\end{aligned}$$

Demo separabler Fall


- svmtoy
 - Randzone ist leer
 - Unabhängigkeit von „äußeren“ Daten
- Matlab toolbox
 - Kleiner Anteil der SV an Gesamtdaten
 - SV auf den Geraden $w \cdot x + b = \pm 1$

2. Lineare SVM: nicht separabler Fall



Nicht linear separabler Fall

- Idee: Bestrafen von Randverletzungen via Lockerungsvariablen ξ_i



Formalisierung

- Minimieren von $\|w\|^2 + C \sum_{i=1}^n \xi_i$ (C fest gewählt)

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

- Duale Formulierung

Maximiere

$$L'(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j (x_i \cdot x_j)$$


mit $C \geq \alpha_i \geq 0$ und $\sum_{i=1}^n y_i \alpha_i = 0$

- Wieder garantiertes globales Optimum.

Demo nicht separabler Fall


- svmtoy
 - Randzone nicht leer
 - Wachsendes C => kleinerer Rand
- Matlab toolbox
 - Support-Vektoren: Vektoren innerhalb Randzone und falsch klassifizierte
 - Qualitativ mehr SV als separabler Fall

3. Nichtlineare SVM



Idee

- Nichtlineare Abbildung $\Psi(x) : \mathbb{R}^N \rightarrow H$ anschließend lineare SVM
- Beispiel XOR-Problem:



Kernel Trick

- **Problem:**
Berechnungskomplexität bei Operieren auf $\Psi(x_i)$
- **Beobachtung:**
in Training und Klassifikation treten nur
Skalarprodukte $\Psi(x_i) \cdot \Psi(x_j)$ auf.
- **Trick:**
Effizient berechenbare **Kernfunktion**
$$K(x_i, x_j) = \Psi(x_i) \cdot \Psi(x_j)$$

macht Kenntnis von Ψ und H überflüssig!
- **Anwendbar auf Vielzahl linearer Algorithmen**
„kernelization“

14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg

19

Kernfunktionen

- **Vorstellung:**
 - Ähnlichkeitsmaß, verallgemeinertes Skalarprodukt
- **Einfache Beispiele**
 - **Linear** $K(x, y) = x \cdot y$
 - **Polynomial** $K(x, y) = (x \cdot y + c)^d$
 - **Sigmoid** $K(x, y) = \tanh(\kappa(x \cdot y) + \theta)$
 - **Gauß** $K(x, y) = \exp(-\|x - y\|^2 / (2\sigma^2))$
- **Allgemeine Bedingung**
 - Mercer Theorem oder
 - **Positive Definitheit**

14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg

20

Endformulierung

- Trainieren:

maximiere

$$L(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j K(x_i, x_j)$$

mit $\sum_{i=1}^l y_i \alpha_i = 0, \quad C \geq \alpha_i \geq 0$

$$\left(b = \frac{\max_{y_i=1} \sum_{i=1}^n y_i \alpha_i K(x_i, x_j) + \min_{y_i=-1} \sum_{i=1}^n y_i \alpha_i K(x_i, x_j)}{2} \right)$$

- Klassifizieren:

$$\hat{y}(x) = \operatorname{sgn} \left(\sum_{i:\alpha_i \neq 0} \alpha_i y_i K(x_i, x) + b \right)$$

14.11.2002


B. Haasdonk, IIF-LMB, Universität Freiburg

21

Demo nichtlinearer Fall

- Rolle der Kerne:

- Polynomialer Kern => spezieller Polynomklassifikator
- Ähnliche SV-Mengen bei verschiedenen Kernen
- Gamma-Variation bei Gauß-Kern



14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg

22

4. Eigenschaften

Komplexitäten

- Training:
 - Speicher $O(n^2)$
 - Laufzeit $O(n^3)$
- Klassifikation ($\hat{y}(x) = \text{sgn}(\sum \alpha_i y_i K(x_i \cdot x) + b)$)
 - Speicher $O(n_s)$ mit $n_s :=$ Anzahl der SV
 - Laufzeit $O(n_s \cdot d)$ (d Dimension von x)

Generalisierungsfähigkeit


- Overfitting?
 - scheint nicht einzutreten
 - Vorurteil: viele Parameter im Klassifikator => schlechte Generalisierungsfähigkeit.
- Curse of Dimensionality?
 - Komplexitätsproblem: durch Kern-Trick irrelevant
 - Problem der Lerndatenmenge: empirisch irrelevant
- Statistische Lerntheorie:
 - Erklärung für gute Generalisierung

14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg

25

5. Anwendung



Anwendungen qualitativ

- Allgemein: beste bzw. state-of-the-art Ergebnisse
- Quelle für SVM-bezogene Arbeiten:
 - www.kernel-machines.org
- Gebiete [www.clopinet.com/isabelle/Projects/SVM/applist.html]
 - Medizin:
 - Brustkrebsdiagnose/Prognose
 - Biologie:
 - Protein-Anfangspunkterkennung in Nukleotidsequenzen
 - Voraussage funktionaler Eigenschaften von Proteinsequenzen
 - Pollenerkennung

Anwendungen qualitativ

- Physik:
 - Partikel-/Quarkfarben-Identifikation, Detektion von Motorklopfen
- Allgemeine Bild- / Signalverarbeitung:
 - Zeitreihenvoraussage
 - Bildklassifikation
 - 3D Objekterkennung
 - Gesichtserkennung in Bildern
- Dokumentenanalyse:
 - Handschriftenerkennung, Textkategorisierung

Anwendungen quantitativ

- Beispiel US Postal Service Digits
 - 16x16 Grauwertbilder
 - 7291 Training, 2007 Test-Beispiele



- Ergebnisse:

Klassifikator	Fehlerrate
Mensch	2.5%
2-Schicht NN	5.9%
5-Schicht NN	5.1%
SVM (polynom grad 3)	4.0%
SVM + Invarianz	3.2%

14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg

29

Verfügbare Implementationen

- MATLAB-Toolboxen
- Svmlight:
 - 2 Programme, Skalierung Training $o(n^2)$
 - Datenübergabe per Datei
 - Strikte Lizenzregelung
 - Keine Multiklassenprobleme
- Libsvm:
 - Funktionalität/Effizienz vergleichbar mit Svmlight
 - Freie C++ Funktionensammlung
 - Multiklassenprobleme

14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg

30

Vorgehen bei konkreter Anwendung

- Geeignete **Datenrepräsentation** wählen und implementieren
- Geeigneten **Kern** wählen
 - Richtlinie: Kern muß Ähnlichkeit zwischen Mustern messen
 - Daten in Vektorraum -> Standardkerne vielversprechend
 - Sonst Design (und Implementation) eines problemspezifischen Kerns.
- Wählen/Variieren der **Kernparameter + C**
- **Training und Evaluation**
- Wahl der besten SVM

14.11.2002

B. Haasdonk, IIF-LMB, Universität Freiburg

31

6. Zusammenfassung

Schwächen

- Langsames, speicherintensives Lernen
- Langsames Klassifizieren
- Keine offensichtliche Multiklassenerweiterung
- Fehlende Aussagen zu Klassifikationssicherheit
- Keine allgemeinen Kriterien zur Kernwahl

Stärken

- Empirisch hervorragend
- Schöne Theorie
 - Garantiert globales Optimum des Funktionals
 - Aussagen zur Generalisierungsfähigkeit
- Existenz schneller Implementationen
- Leichte Handhabbarkeit
 - Wenig Parameter per Hand zu setzen
 - (fast) keine Architektur-Wahl
 - Kaum a-priori-Wissen benötigt
- Spärliche Darstellung der Lösung
- Anschauliche Funktionsweise