

# Maschinelles Lernen

## 9. Übung

Prof. Tobias Scheffer  
Dr. Niels Landwehr  
Christoph Sawade  
Jules Rasetaharison

WS10/11

Ausgabe am: 10.01.11  
Besprechung am: 17.01.11

### Aufgabe 1 (1/3 Punkt):

Das Margin-Perzeptron führt ein Update des Gewichtsvektors durch wenn

$$y_i \frac{\mathbf{w}^\top \mathbf{x}_i}{\|\mathbf{w}\|} \leq \delta.$$

- (a) Welche Verlustfunktion minimiert das Margin-Perzeptron?
- (b) Zu Beginn des Trainings ist der maximale Margin  $\delta_{max}$  i.A. unbekannt. Angenommen wir wählen  $\delta > \delta_{max}$ . Welche Auswirkung hat diese Wahl auf das Ergebnis des Margin-Perzeptrons?

### Aufgabe 2 (1/3 Punkt):

In der Vorlesung wurde das Optimierungskriterium der *Support Vector Machine* vorgestellt.

- (a) Wir betrachten zunächst die *Hard Margin SVM*. Begründen sie warum das Minimieren der Länge des Gewichtsvektors unter der Nebenbedingung  $y_i \mathbf{w}^\top \mathbf{x}_i \geq 1, \forall i$ , äquivalent zur Maximierung des geometrischen Margins ist.
- (b) Was sind die Support-Vektoren?
- (c) Worin besteht der Unterschied zw. *Hard* und *Soft Margin SVM*? Geben sie die Verlustfunktionen und die Regularisierer beider Verfahren an.

### Aufgabe 3 (1/3 Punkt):

Bisher haben wir im Zusammenhang mit dem Perzeptron, der SVM usw. die Daten immer als Punkte im Raum aufgefasst welche wir durch eine Ebene – im zweidimensionalen eine Gerade – trennen möchten (im unteren Bild rechts). Eine äquivalente Darstellung bildet der *konjugierte Vektorraum*. In diesem wird jeder Datenpunkt als Normalenvektor  $y_i \frac{\mathbf{x}_i}{\|\mathbf{x}_i\|}$  einer Ebene aufgefasst. Der Normalenvektor  $\mathbf{w}$  einer Trennebenen (mit Länge 1) wird hingegen als Punkt dargestellt (im unteren Bild links). Wo befindet sich in dieser Darstellung  $\mathbf{w}_{SVM}$  (Lösung der Hard Margin SVM) und wo liegt der Bayes Point  $\mathbf{w}_{BP}$  (Lösung der Bayes Point Machine)?

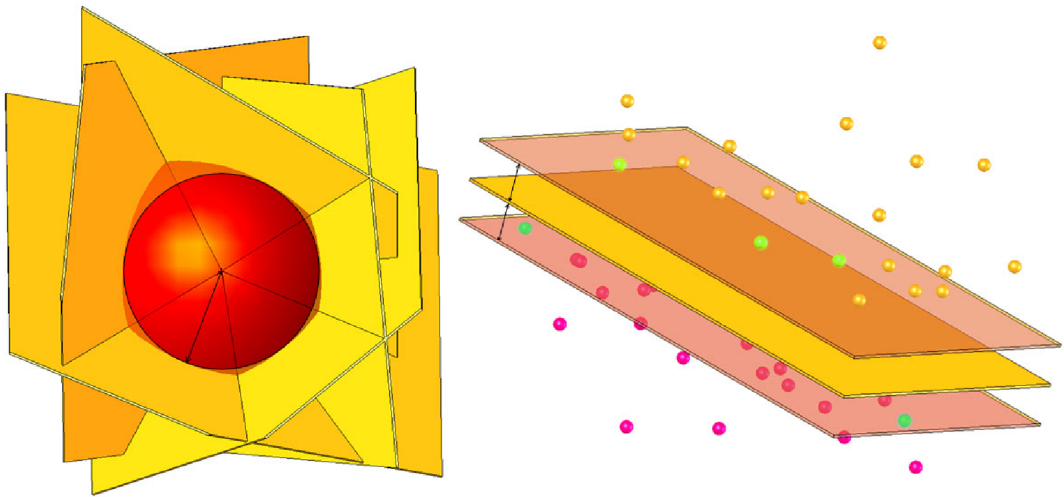


Abbildung 1: SVM im Vektorraum (rechts) und im konjugierten Vektorraum (links)