

Statistische Lerntheorie

Theoretische Grundlage der Support- Vektor-Maschinen

17.01.2003

Magnus Herold - Institut für
Informatik - Universität Freiburg

1

Statistische Lerntheorie

Überblick

1. Motivation
2. Begriffe
3. Kapazität und VC-Dimension
4. Fehler, Schranken und ihre Minimierung
5. Structural Risk Minimization
6. Beziehung zu den SVMs
7. Zusammenfassung
8. Literatur

17.01.2003

Magnus Herold - Institut für Informatik - Universität Freiburg

2

Motivation

- Warum Lerntheorie?
 - Versuch, allgemeine Probleme beim Lernen formal zu fassen und zu lösen
- Hauptproblem (und Thema dieses Vortrags):

Wie gut ist die **Generalisierungsleistung** einer Lernmaschine?

- Wir werden sehen: Hängt zusammen mit ihrer **Kapazität**
 - Kapazität zu groß: Overfitting
 - Kapazität zu klein: Underfitting

Begriffe


- **Trainingsdaten:** $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m) \in \mathcal{X} \times \{\pm 1\}$
 - \mathbf{x}_i : die **Samples**, y_i : die **Labels**
 - der Einfachheit halber nur „Mustererkennungsfall“, $y \in \{\pm 1\}$
 - aus unbekannter Wahrscheinlichkeitsverteilung $P(\mathbf{x}, y)$
- **Lernmaschine:** Eine Menge von Funktionen $\{f(\alpha)\}$ mit $f(\alpha) : \mathcal{X} \rightarrow \{\pm 1\}$
 - α : Menge von Parametern, eine bestimmte Wahl von α generiert eine „Trainierte Maschine“
- Bekanntestes Maß für die Kapazität einer Lernmaschine:
Die **VC-Dimension**

VC-Dimension

- m Samples können auf 2^m Arten „gelabelt“ werden.
- Wenn für jede dieser 2^m Arten eine Funktion aus $\{f(\alpha)\}$ existiert, sagt man, die Lernmaschine „zerschmettert“ (engl. „to shatter“) diese m Punkte
- **VC-Dimension h :** Die maximale Anzahl von Punkten, die durch die Lernmaschine zerschmettert werden können
 - **Achtung:** Nicht jede Menge der Mächtigkeit m wird zerschmettert, sondern es existiert mindestens eine Menge von m Punkten, die zerschmettert werden.

Beispiel: Hyperebenen in \mathbb{R}^2

- Die Funktionenklasse der trennenden Hyperebenen in \mathbb{R}^2 hat eine VC-Dimension von 3



- Allgemein gilt: Die Funktionenklasse der trennenden Hyperebenen in \mathbb{R}^n hat eine VC-Dimension von $n+1$ (ohne Beweis)

VC-Dimension und die Zahl der Parameter

- Intuitiv könnte man glauben, eine Lernmaschine mit vielen Parametern hat eine hohe VC-Dim, und eine mit wenigen Parametern eine niedrige.
- Dies ist i.a. NICHT der Fall !
- Es gibt Lernmaschinen mit nur einem Parameter und doch unendlicher VC-Dimension
 - Man sagt eine Lernmaschine hat $h = \infty$, wenn sie m Punkte zerschmettern kann, egal wie groß m ist.

Beispiel

- Sei $x \in \mathbb{R} : \{\theta(x) = 1 \forall x > 0; \theta(x) = -1 \forall x \leq 0\}$
 $f(x, \alpha) \equiv \theta(\sin(\alpha x)), \quad x, \alpha \in \mathbb{R}$
- Für beliebiges m wähle man m Punkte
 $x_i = 10^{-i}, \quad i = 1, \dots, m$
- Und beliebige Labels $y_1, y_2, \dots, y_m, \quad y_i \in \{\pm 1\}$
- Dann gibt $f(\alpha)$ diese Labels für

$$\alpha = \pi \left(1 + \sum_{i=1}^m \frac{(1 - y_i) 10^i}{2} \right) \quad \text{also ist } h(\{f(\alpha)\}) = \infty$$

Fehler und ihre Minimierung

- „Actual Risk“: Erwarteter Fehler für trainierte Lernmaschine

$$R(\alpha) = \int \frac{1}{2} |y - f(\mathbf{x}, \alpha)| dP(\mathbf{x}, y)$$

→ Diesen wollen wir minimieren, aber: leider nicht berechenbar, da $P(\mathbf{x}, y)$ unbekannt


- Was können wir berechnen?

- „Empirical Risk“: $R_{emp}(\alpha) = \frac{1}{m} \sum_{i=1}^m \frac{1}{2} |y_i - f(\mathbf{x}_i, \alpha)|$

→ Fehler auf den Trainingsdaten

ERM allgemein nicht ausreichend

- $R_{emp}(\alpha)$ minimieren führt aber nicht automatisch zu kleinem $R(\alpha)$!



- Ziel ist also, eine Lernmaschine von **angemessener** Kapazität zu finden

Eine Schranke für $R(\alpha)$

- Statistische Lerntheorie gibt einige Schranken, um $R(\alpha)$ nach oben abzuschätzen.

- Eine wichtige ist: $R(\alpha) \leq R_{emp}(\alpha) + \phi(h, m, \delta)$


(Vapnik, 1995)

wobei
$$\phi(h, m, \delta) = \sqrt{\frac{1}{m} \left(h \left(\ln \frac{2m}{h} + 1 \right) + \ln \frac{4}{\delta} \right)}$$

- $\phi(h, m, \delta)$ wird **VC-Konfidenz** genannt.
- Die Schranke hält mit **Wahrscheinlichkeit δ**
- Sie ist **unabhängig von $P(\mathbf{x}, y)$**
- Sie ist **leicht zu berechnen**, wenn wir **h** kennen

Structural Risk Minimization

- Wie können wir nun aber $R_{emp}(\alpha) + \phi(h, m, \delta)$ (den „Risk Bound“) minimieren?
- Die VC-Konfidenz ist abhängig von der Funktionsklasse, nicht von einer bestimmten Wahl von α , kann also nicht so einfach minimiert werden
- Idee: Wir führen eine Struktur auf $\{f(\alpha)\}$ ein




Ineinander geschichtete
Untermengen, mit
absteigender VC-Dimension

$$h_4 > h_3 > h_2 > h_1$$

Structural Risk Minimization 2

- Jetzt können wir den Risk Bound minimieren, indem wir für jede Unterklasse R_{emp} minimieren



- Dieses Prinzip heißt **Structural Risk Minimization (SRM)**

Leider kein Allheilmittel...

- Risk Bound $R_{\text{emp}}(\alpha) + \phi(h, m, \delta)$ theoretisch schön, aber praktisch nicht immer nützlich
 - Macht oft keine nichttrivialen Aussagen
 - Gilt nicht für Lernmaschinen mit $h = \infty$
 - Trotzdem können Lernmaschinen mit $h = \infty$ eine gute Performance haben: Beispiel k-Nearest Neighbour Klassifikator mit $k=1$
 - VC-Dimension unendlich
 - $R_{\text{emp}} = 0$ (falls Trainingsmenge widerspruchsfrei)
- VC-Dimension als Kapazitätsmaß oft ein bisschen grob

Was es sonst noch gibt


- Es gibt noch andere, engere Bounds
 - Benutzen teilweise andere Kapazitätsmaße
 - VC-Entropie
 - Annealed Entropy
 - Growth Function
 - Sind teilweise nicht mehr verteilungsunabhängig
 - Geht über den Rahmen dieses Vortrags hinaus...
- Stattdessen: Bezug der Theorie zu SVMs

Beziehung zu den SVMs:

- SVMs und Neuronale Netze als Instanzen von Lernmaschinen:
 - SVMs halten R_{emp} fest und versuchen, die VC-Konfidenz zu minimieren
 - Im Gegensatz dazu: Neuronale Netze halten VC-Konfidenz konstant (durch die Wahl der Struktur) und versuchen, R_{emp} zu minimieren
- Funktionenklasse die SVMs zugrunde liegt, sind die separierenden Hyperebenen im \mathbb{R}^n
- SVMs machen SRM, indem sie die optimal (mit maximalem Rand) separierende Hyperebene bestimmen
- Warum ist das so? Formal kompliziert, daher nur eine Anschauung...

Optimal separierende Hyperebene

- Indem ein Constraint über die Breite des Randes auf die Funktionenklasse der separierenden Hyperebenen gelegt wird, beschränkt man deren Kapazität



Zusammenfassung

- Wir haben das allgemeine Konzept der **Lernmaschine** und ihrer Trainingsdaten formal gefasst.
- Wir haben ein wichtiges Maß für die Kapazität einer Lernmaschine kennengelernt, die **VC-Dimension**.
- Wir haben gesehen, dass der **empirische Fehler** im Allgemeinen kein guter Indikator für den **zu erwartenden Fehler** ist.

Zusammenfassung 2

- Wir haben den zu erwartenden Fehler, den empirischen Fehler und die **Kapazität** der Lernmaschine in Beziehung gesetzt und eine allgemeine Abschätzung für den zu erwartenden Fehler, den **Risk Bound**, kennengelernt.
- Mit dem induktiven Prinzip der **Structural Risk Minimization** haben wir eine Methode kennengelernt, den Risk Bound zu minimieren
- Wir haben eine Intuition erhalten, wie SVMs auf der Statistischen Lerntheorie aufsetzen und wie die optimal separierenden Hyperebenen zum SRM in Beziehung stehen

Literatur

- C. J. C. Burges. A Tutorial on Support Vector Machines for Pattern Recognition, Knowledge Discovery and Data Mining, 2(2), 1998.
- V. Vapnik: The Nature of Statistical Learning Theory, Springer-Verlag New York, 1995.
- B. Schölkopf, A. Smola: Learning With Kernels, MIT-Press Cambridge, 2002.