

# Statistische und neuronale Lernverfahren

**Martin Stetter**

**WS 05/06, 2 SWS**

**Bereich:**

prüfbare Vorlesung im Bereich praktischer und theoretischer Informatik:  
Künstliche Intelligenz / Maschinelles Lernen

**Zeit: Dienstag 8.30 (s.t.) - 10.00**

**Ort: 00.08.038**

**Beginn: 25.10.2005**

# Behandelte Themen

- 0. „Motivation“: Lernen in Statistik und Biologie**
- 1. Überblick über statistische Datenmodellierungs-Verfahren**
- 2. Das lineare Modell (Regression)**
- 3. Perceptron und Multilagen-Perceptron (Funktionsapproximation)**
- 4. Selbstorganisierende Merkmalskarten (Dichteschätzung)**
- 5. Lernen von Datenmodellen**
  - Approximation: Bayes'sches Schließen, MAP, ML
  - Maximum Likelihood Schätzung und Fehlerminimierung
  - Generalisierung und Regularisierung
  - Optimierungsverfahren
- 6. Bayesianische Netze (Dichteschätzung und Funktionsapproximation)**
- 7. Kern-Trick und Support Vector Machine**

# Literatur

## Statistische Lernverfahren:

- B. Schölkopf, A. Smola: *Learning with Kernels*. MIT Press, Cambridge, MA (2002)
- S. Lauritzen. *Graphical Models*, Oxford Univ. Press (1996)
- Kevin Murphy's tutorial. *A Brief Introduction to Graphical Models and Bayesian Networks*  
<http://www.ai.mit.edu/~murphyk/Bayes/bayes.html>

## Statistische und neuronale Verfahren:

- C. M. Bishop, *Neural Networks for Pattern Recognition*, Clarendon Press Oxford (1995)

## Neuronale Netze:

- J. Hertz, A. Krogh, R. G. Palmer, *Introduction to the Theory of Neural Computation*, Addison Wesley, Redwood City CA (1991)

## Computational Neuroscience und Bioinformatik

- M. Stetter, *Exploration of Cortical Function*, Kluwer Academic Publishers, Dordrecht (2002)
- P. Baldi, G. W. Hatfield, *DNA Microarrays and Gene Expression*, Cambridge University Press Cambridge, MA (2002)

# Einführung: Lernen in Statistik und Biologie

## **Biologisches Lernen**

**Erkennen von Zusammenhängen im Lebensraum**

**„Synaptische Plastizität“ im Gehirn**

**Erlernen von Fähigkeiten aus Beispielen (prozedurales Lernen)**

**Erlernen von Fähigkeiten durch Probieren**

**Finden einfacher Lösungen**

**Schlußfolgern**

## **Maschinelles Lernen**

**Erkennen von statistischer Struktur in Datensätzen**

**Einstellung der Modellparameter**

**Überwachtes Lernen**

**Unüberwachtes Lernen**

**Regularisierung**

**Bayes'sches Schließen (Inferenz)**

# Statistisches Lernen: Beispiel

Statistisches / Maschinelles Lernen: „Entdeckung von Struktur in Daten“

## Beispiel: 2D-Klassifikation:

*M* Fiktive Daten eines Geldinstituts:

$x_1$  = Mittl. abgehobener Geldbetrag


$x_2$  = Häufigkeit Abhebevorgänge

$\mathbf{x} = (x_1, x_2)$  = „Muster“

$y$  = Scheckkartenbetrug (1=ja, 0=nein)

$y$  = „Klassenlabel“, Soll, Output

$(\mathbf{x}^{(1)}, y^{(1)}) \dots (\mathbf{x}^{(M)}, y^{(M)})$



**Ziel:** Lerne Klassifikationsregel, um künftige Betrüger frühzeitig an ihrem Verhalten zu erkennen.

## Lernen eines Klassifikators:

Linearer Klassifikator:

$$\hat{y} = \Theta(\mathbf{w} \cdot \mathbf{x} + b)$$

$$\Theta(x) = 1, x \geq 0$$

$$\Theta(x) = 0, x < 0$$

$$\mathbf{w} \cdot \mathbf{x} := w_1 x_1 + w_2 x_2$$

$(\mathbf{w}, b)$  = Parametersatz, „Modell“,  
„Hypothese“


„Lernen“: Finde besten Parametersatz

Offline-Lernen:

$$\mathbf{c}_{+/-} = \frac{1}{M_{+/-}} \sum_{\{m|y^{(m)}=\pm 1\}} \mathbf{x}^{(m)} \quad \text{Klassenzentren}$$

$$\hat{\mathbf{w}} = \mathbf{c}_+ - \mathbf{c}_-$$

$$\hat{b} = -\mathbf{w} \cdot (\mathbf{c}_+ + \mathbf{c}_-) / 2$$



Online-Lernen (Beispiel für  $b=0$ ):

Für jeden Datenpunkt ändere  $\mathbf{w}$  gemäß

$$\Delta \mathbf{w} = \eta (y^{(m)} - \hat{y}^{(m)}) \mathbf{x}^{(m)}$$

(Perceptron-Lernregel, siehe später)


## Warum „statistisches“ Lernen?

Daten sind unsicher:

- Datenpunkte  $x$  könnten versetzt sein
- Gemessene Klassen können falsch sein

Klassifikationsgesetz ist unsicher

- Mitglieder unterschiedlicher Klassen könnten dasselbe Muster  $x$  aufweisen




## Lösung: Probabilistischer Klassifikator („soft classifier“)

Spezifiziere Wahrscheinlichkeit für  
Klassenmitgliedschaft

$$\Pr(y(\mathbf{x}) = 1) = g(\mathbf{w} \cdot \mathbf{x} + b)$$

Beispiel: Logistische Transferfunktion :

$$g(x) = \frac{1}{1 + \exp(-x)}$$



# Neuronales Lernen: Gehirn und Nervenzelle


## Das menschliche Gehirn

Besteht aus Nervenzellen (Neuronen) und Hilfszellen

Hochstrukturiert (Kerne, Areale der Grosshirnrinde)


Gigantisches Netz aus Neuronen:

- 100 000 000 000 Nervenzellen
- Jede Zelle erhält synaptischen Input von ca. 10 000 anderen Nervenzellen (Konvergenz)
- Jede Zelle sendet ca. 10 000 Outputs (Divergenz)
- Gesamte Leitungslänge: 750 000 km !!!



## Nervenzelle

Besteht aus Dendrit,  
Soma (Zellkörper)  
Axon



# Neuronales Lernen: Reizleitung in Neuronen

## Funktionsweise des Neurons

**Signal: Aktionspotential, „Spike“**

**Signalfluss:**

**Dendrit --> Soma --> Axon-->**

**Synapse--> Dendrit ...**

**(a) Spike kommt an;**

**Synapse injiziert Strom I**

**Membranspannung steigt (PSP)**


**(b) Viele PSPs summieren sich**

**Bei Schwellenspannung: Spike**

**(c) Spike läuft Axon entlang**

**verzweigt sich mit dem Axon**

**(d) Spike kommt an.....**



## Biologisches Lernen (Hypothese):

**Synaptischer Strom I ändert sich in Abhängigkeit von der Zeit und der Hirnaktivität („LTP, LTD“.....)**

## Ratenmodell des Neurons


- Neuron erhält Signale von  $d$  Synapsen
- An Synapse  $i$  kommen Spikes mit der Rate  $x_i$  an
- Synapse  $i$  induziert Spannung  $U_i = w_i x_i$   
 $w_i$  heißt synaptisches Gewicht

- Das Soma summiert die Spannungsänderungen:

$$U = \sum_{i=1}^d w_i x_i = \mathbf{w} \cdot \mathbf{x}$$

- Die Spikerate  $y$  am Axon ist eine sigmoide Funktion der Summenspannung

$$y(\mathbf{x}) = g(\mathbf{w} \cdot \mathbf{x} - \theta)$$



### Lernen im Modellneuron:

Synaptische Gewichte  $w$  ändern sich abhängig von der Aktivität

Biologisch motivierte Lernregeln...  
(zB. „Hebb-Regel“)


# Statistische und Neuronale Lernverfahren: Beispiele

## Künstliche Neuronale Netze

Modellneuronen können zu künstlichen neuronalen Netzen zusammengeschaltet werden, zB.

## Statistische Datenmodellierung

Modellneuronen können auch als statistische Datenmodelle interpretiert werden, z.B.



## Zusammenfassung

- **Ein biologisch motiviertes Modellneuron lässt sich mit einem linearen probabilistischen Klassifikator identifizieren**
- **Viele künstliche Neuronale Netze lassen sich mit statistischen Lernverfahren identifizieren**
- **Viele Verfahren, viele Aufgaben**

## „Road Map“

- **Bayes'sche Inferenz als genereller Rahmen für statistische Lernverfahren**
- **Statistische Datenmodellierung durch Optimierung und Regularisierung**
- **Spezielle maschinelle Lernverfahren und Neuronale Netzwerk-Typen**

# Parallelveranstaltung Unüberwachte Lernverfahren

**PD Dr. Thomas Runkler: Data Mining und Knowledge Discovery**

**Bereich:** prüfbare Vorlesung im Bereich 1.4 Künstliche Intelligenz / Maschinelles Lernen

**Zeit:** Montag 8.30 - 10.00

**Ort:** Raum 00.13.009A

**Beginn:** 24.10.05

## **Inhalt:**

Einführung: Ziel, Definitionen, Schritte der Knowledge Discovery (KDD)

Datenquellen, -charakteristika und Fehlerquellen,

Datenvorverarbeitung und -filterung

Datenvisualisierung; Projektionen, Hauptachsentrafo., mehrdim. Skalierung, Sammon-Methode, selbstorg. Karten

Datentransformationen und Merkmalsgenerierung

Datenanalyse; Korrelationsanalyse und Scheinkorrelationen, Regression, Klassifikation (Entscheidungsbäume, ID3)

Clustering (SAHN, HCM, FCM, GK, FCL, FCE, ACE, RBF, LVQ, FGLVQ), Regeln (scharf, unscharf, lokale Modelle)

Anwendungsbeispiele