

---

# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
<b>2</b>	<b>Intuitive Klassifikation</b>	<b>15</b>
<b>3</b>	<b>Digitalisierung</b>	<b>32</b>
<b>3</b>	<b>Vorverarbeitung</b>	<b>34</b>
<b>4</b>	<b>Merkmalsextraktion</b>	<b>57</b>
<b>5</b>	<b>Klassifikation</b>	<b>72</b>
<b>6</b>	<b>Polynomklassifikator</b>	<b>128</b>

---

<b>7</b>	<b>Multi-Layer-Perzeptron (MLP)</b>	<b>154</b>
<b>8</b>	<b>Radiale Basisfunktionen</b>	<b>161</b>
<b>9</b>	<b>Güte der Klassifikation</b>	<b>163</b>
<b>10</b>	<b>Support Vektor Maschinen</b>	<b>164</b>
<b>11</b>	<b>Hidden Markov Modelle</b>	<b>181</b>
<b>12</b>	<b>Markov Random Fields</b>	<b>211</b>
<b>13</b>	<b>Bayes-Netze</b>	<b>228</b>

## 1 Einleitung

Die Vorlesung beschäftigt sich mit Teilgebiet der:

**Mustererkennung** : mathematisch-technischer Aspekt von Perzeption

**Perzeption** : Erfassen, Auswerten und Interpretieren von Sinneseindrücken

Perzeption ist für die Aktivitäten aller Lebewesen wichtig, aber auch für technische Systeme, die (immer) mit der Umwelt/Umgebung interagieren.

Bei der Realisierung solcher perzeptiver Systeme steht die Spannweite von Nachbildung

- eines biologischen Vorbildes bis zur
- rein technisch-ingenieurwissenschaftlicher Sichtweise.

# 1 Einleitung

---

In vielen Bereichen zeigen biologische visuelle Systeme erstaunliche Fähigkeiten, die automatisch i.d.R. nur sehr unzulänglich erreicht werden können.

Bei quantitativen Auswertungen und repetitiven Aufgaben sind technische Systeme typischerweise überlegen.

In der Vorlesung:

- im wesentlichen technisch-ingenieurwissenschaftlicher Standpunkt,
- aber auch biologisches Vorbild (neuronale Netze)

### 1.1 Beispiele

#### 1. gesprochener Text:

- Identifizieren/Authentifizieren der Person
- möglichst exakte Transskription (Diktiersystem)
- Auskunftsdiallog: Erkennung aller Wörter nicht nötig, die Bedeutung muß erkannt werden

#### 2. handschriftlicher Name:

- Name des Adressaten (Postanschriftenleser)
- Charaktereigenschaften (Graphologie)
- gültig/ungültig (Zugangskontrolle)

#### 3. gescannte Formulare: Geldbeträge, Empfänger

#### 4. Bildsequenz (Vidoesequenz) der Umgebung:

- Navigation einer autonomen Systems (z.B. Hindernisvermeidung, Verfolgung)
- Erkennen von Teilen und deren Lage (Montage)

## 1.1 Beispiele

---

5.
  - CT/MR-Bilder: erkennen von Organen, deren Größe, Form
  - EKG: Diagnose
6. Radarbilder (in der Nähe von Flughäfen): Quantifizierung von Vögeln
7. Satellitenbilder:
  - Waldschäden erfassen
  - Umweltverschmutzung
  - Kartographie
  - militärische Aufklärung
8. chemische Analyse des Gehalts an verschiedenen Fettsäuren in Olivenöl: Herkunftsregion
9. Stärke der Expression unterschiedlicher Gene (mRNA, Protein)
  - Type der Zellen, z.B. krankhaft vs. normal
10. Primärsequenz von Proteinen: Vorhersage der Sekundärstrukturelemente
11. DNA-Sequenz: Bindestellen von DNA-bindenden Proteinen, Splice-Stellen

### 1.2 Definitionen, Begriffe

Perzeption hat zum Gegenstand die Eindrücke der Umwelt

**Umwelt** :  $U = \{\rho \vec{b}(\vec{x}) \mid \rho = 1, 2, \dots\}$

(Menge aller meßbaren Größen;  $\vec{x}$  ist Zeit, Raum und  $\vec{b}$  sind Messungen physikalischer Eigenschaften, z.B. Lautstärke, Nukleotid)

**Problemkreis** :  $\Omega = \{\rho \vec{f}(\vec{x}) \mid \rho = 1, 2, \dots\} \subset U$

(Menge von Mustern des gleichen Typs)

**Muster** : Elemente eines Problemkreises

$$\vec{f}(\vec{x}) = \begin{bmatrix} f_1(x_1, \dots, x_n) \\ \vdots \\ f_m(x_1, \dots, x_n) \end{bmatrix}$$

Beispiele für Muster haben wir oben schon kennengelernt.

- Sprache:  $f(t)$
- S/W – Foto:  $f(x, y)$
- Farbfernsehbild:  $\begin{pmatrix} r(x, y) \\ g(x, y) \\ b(x, y) \end{pmatrix}$
- Aminosäure-Sequenz:  $\Sigma^L$ , mit  $\Sigma = \{A, C, G, T\}$
- Expressionswerte von Genen:  $\mathcal{R}^M$

Muster werden in zwei Typen unterschieden:

- einfache Muster (direkt klassifizierbar)
- komplexe Muster

## 1.2 Definitionen, Begriffe

---

**Klassifikation** von (einfachen) Mustern, ist die Zuordnung eines Musters zu einer von  $k$  erlaubten Klassen  $\Omega_\lambda$

Beispiel: Buchstabe, isoliert gesprochenes Wort, (kurze) DNA-Sequenz

**Musterklasse od. Klasse** : Zerlegung des Problemkreises in disjunkte Klassen:

$$\begin{aligned}\Omega_\lambda &\neq \emptyset \\ \Omega_\lambda \cap \Omega_\kappa &= \emptyset \quad \text{für } \lambda \neq \kappa \\ \bigcup_{\lambda=1}^k \Omega_\lambda &= \Omega\end{aligned}$$

Erweiterung um Rückweisungsklasse  $\Omega_0 \Rightarrow \bigcup_{\lambda=0}^k \Omega_\lambda = \Omega$

**Einfache Muster** :

- dem Anwender genügt der Klassenname
- die Klassifikation ist als Ganzes möglich

**Analyse** von (komplexen) Mustern erzeugt eine symbolische Beschreibung

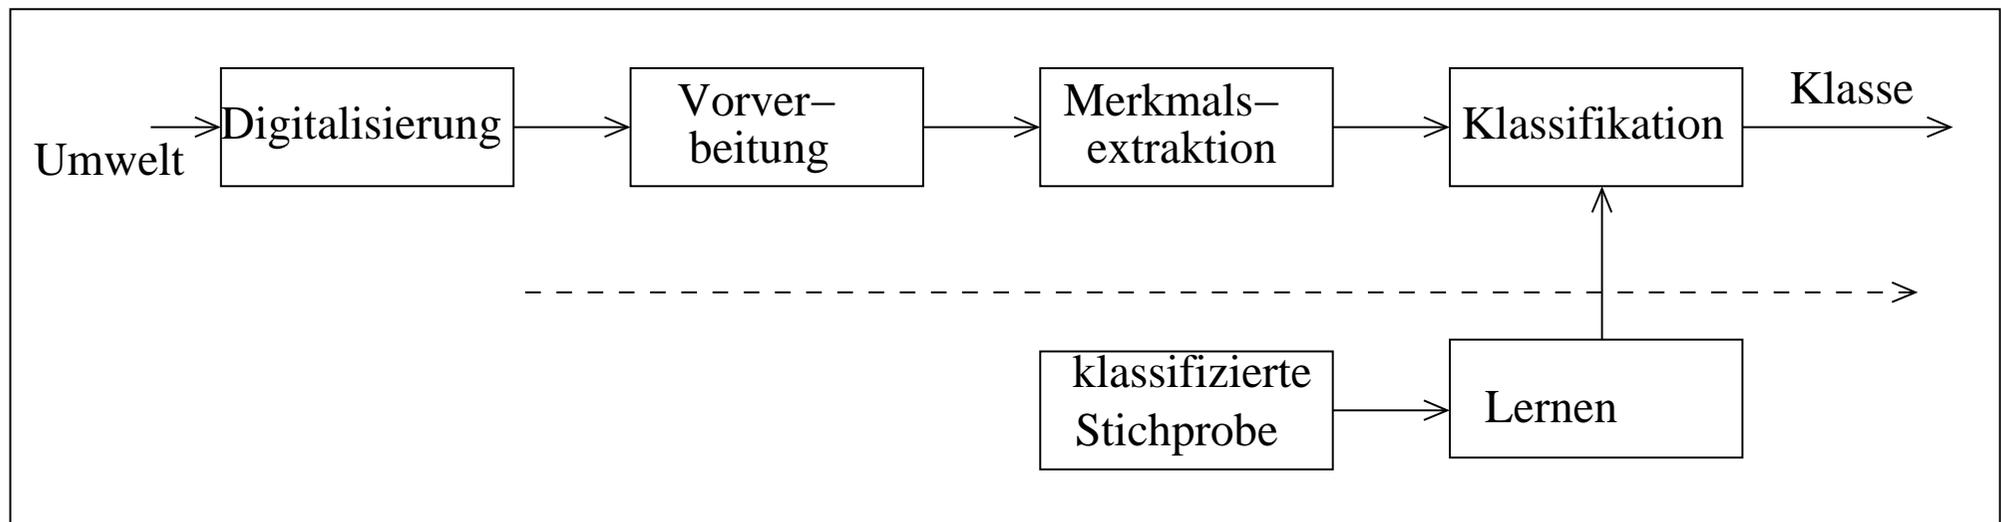
**Typen** von symbolischen Beschreibungen:

- 1) ausführliche Auflistung der Teile und Relationen
- 2) interessante Teile
- 3) Beschreibung von Veränderungen
- 4) Klassennamen

**Komplexes Muster** : liegt vor, wenn der Anwender mehr als einen Klassennamen benötigt oder die Klassifikation als Ganzes nicht möglich ist

### 1.3 Aufbau von Klassifikationssystemen

In der Vorlesung geht es um Klassifikation von (einfachen) Mustern  
(bemerke nochmals: die Unterscheidung ist fließend!)



### 1.4 Grundsätzliche Vorgehensweise

Bei allen Unterschieden zwischen verschiedenen Ansätzen gibt es einige gemeinsame Prinzipien (Niemann 83):

**Postulat 1:** es steht eine repräsentative Stichprobe  $\omega$  zur Verfügung

$$\omega = \left\{ {}^1\vec{f}(\vec{x}), \dots, {}^N\vec{f}(\vec{x}) \right\} \subset \Omega$$

- $\omega \subset \Omega$ : da alles andere irrelevant
- in der Regel klassifizierte Stichprobe
- repräsentativ: wichtig, aber schwer zu erreichen, sogar schwer zu beurteilen
- Frage nach  $N$  (Größe der Stichprobe)
  - abhängig von statistischen Eigenschaften des Problemkreises
  - oft  $N$  eher zu klein, als groß (wegen Aufwand)

Für die Klassifikation:

**Postulat 2:** Ein einfaches Muster besitzt Merkmale, die für die Zugehörigkeit zu seiner Klasse charakteristisch sind.

- numerische Merkmale: Vektor reeller Zahlen
- symbolische Merkmale: Kette von Symbolen

Merkmale werden aus dem Muster durch die **Merkmalsextraktion** gewonnen, für numerische Merkmale:

$$\varphi : \varphi \left( \vec{f}(\vec{x}) \right) = \vec{c} = \begin{pmatrix} c_1 \\ \vdots \\ c_M \end{pmatrix}$$

Dabei sollte die Dimension der Merkmalsvektoren  $M$  möglichst klein sein, u.a. da von dieser Größe der mathematische Aufwand bei der Klassifikation abhängt.

**Postulat 3:** Die Merkmale für Muster einer Klasse bilden einen einigermaßen kompakten Bereich. Die Bereiche für verschiedene Klassen sind getrennt.

- geeignete Merkmale finden ist (oft) schwierig
- die Klassifikation wird relativ gut beherrscht
- lokale Optimierung gewährleistet i.A. nicht eine Optimierung des gesamten Systems

Für die Analyse:

**Postulat 4:** Ein komplexes Muster besitzt einfachere Bestandteile, die untereinander eine bestimmte Beziehung haben. Das Muster läßt sich in diese Bestandteile zerlegen.

**Postulat 5:** Ein komplexes Muster eines Problemkreises hat eine bestimmte Struktur:

1. nicht jede Anordnung von Bestandteilen kommt vor
2. es genügen relativ wenige einfachere Bestandteile zur Darstellung eines Musters

Fragen:

- welche einfacheren Bestandteile ?
- Technik zur Repräsentation und Analyse der strukturellen Eigenschaften
- Systemstruktur (z.B. Black-Board- oder Datenbankarchitektur)

## 1.4 Grundsätzliche Vorgehensweise

---

Klassifikation und Analyse haben einiges gemeinsam, Trennlinie nicht fest

**Postulat 6:** Zwei Muster sind ähnlich, wenn ihre Merkmale oder einfacheren Bestandteile sich wenig unterscheiden

# Literatur

- [1] Heinrich Niemann. *Klassifikation von Mustern*. Springer, Berlin, 1983.  
<http://www5.informatik.uni-erlangen.de/Personen/niemann/klassifikation-von-mustern/m00links.html?language=en>.
- [2] Jürgen Schürmann. *Pattern Classification, A unified view of statistical and neural approaches*. Wiley-International, 1996.
- [3] Simon Haykin. *Neural Networks: A Comprehensive Foundation*. Macmillan, New York, 1999.
- [4] Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.
- [5] Andreas Zell. *Simulation neuronaler Netze*. Oldenbourg Verlag, München, 2000.
- [6] Gernot A. Fink. *Mustererkennung mit Markov-Modellen*. Leitfäden der Informatik. B. G. Teubner, Stuttgart – Leipzig – Wiesbaden, 2003.
- [7] Christopher J. C. Burges. A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2):121–167, 1998.
- [8] S.Z. Li. *Markov Random Field Modeling in Computer Vision*. Springer, 1995.
- [9] Judea Pearl. *Probabilistic Reasoning in Intelligent Systems*. Morgan Kaufmann, Los Altos, 1988.