



Bildverarbeitung 1 Vom Pixel zum Objekt

Dr. Andrea Miene

Verarbeitungsstufen der Bildanalyse

- ▶ **Bildgebung**
 - Bilderfassung durch verschiedene Sensoren
- ▶ **Vorverarbeitung**
 - Bildverbesserung, ...
- ▶ **Segmentierung**
 - Trennung: Objekt/Hintergrund
- ▶ **Merkmalsextraktion**
 - Farbe, Kontur, Textur...
- ▶ **Klassifikation**
 - Diskriminantenfkt., Abstand, Wahrscheinlichkeit, ...



**Mustererkennungs-
Paradigma**

Klassifikation – Kurze Wiederholung

- ▶ Zuordnung unbekannten Bildobjekte zu Klassen (Kategorien)
- ▶ Voraussetzung: Wahl signifikanter Merkmale
- ▶ Merkmale müssen ggf. normiert werden und bilden eine n -dimensionalen Merkmalsvektor der die Lage des Objektes beschreibt
- ▶ Annahme: Ähnliche Merkmale habe ähnliche Vektoren,
- ▶ Ähnlichkeit wird mit Abstandsmaßen gemessen
 - z.B. Euklid, Manhattan, ...
- ▶ Lernen der Klassen anhand einer Stichprobe von Objekten und ihrer Merkmalsvektoren
 - Möglichst signifikante Beispiele
 - Möglichst gleichmäßige Verteilung über die Klassen

Klassifikation

- ▶ Einführung
- ▶ Klassifikationsverfahren
 - Distanzfunktionen
 - Abstandsmaße
 - Diskriminantenfunktionen
 - Bayes Klassifikator
 - Entscheidungsbaum
 - Clusteranalyse
- ▶ Zusammenfassung

Distanzfunktionen

- ▶ Minimum-Distanz-Klassifikation (1)
 - Räumliche Nähe als Maß für Ähnlichkeit zwischen Merkmalsvektoren einer Klasse
 - Voraussetzung sind identifizierbare Punktehaufen (Cluster) im Merkmalsraum
 - Merkmalsvektor-Ballungen sollten eine möglichst geringe Streuung haben
 - Zuordnung des zu klassifizierenden Vektors zu der Klasse, zu der er den **kleinsten Abstand** hat

Distanzfunktionen


- ▶ Minimum-Distanz-Klassifikation (2)
 - Verschiedene Abstandsmaße möglich
 - Messen des Abstands zwischen einem einzelnen Vektor und einer Klasse – verschiedene Varianten
 - Vergleich mit genau **einem** Prototypen der die Klasse repräsentiert
 - Vergleich mit einer **Menge** von Prototypen pro Klasse
 - Zuordnung zur Klasse des **nächsten Nachbarn** in einer Menge bereits klassifizierter Vektoren
 - Bestimmung von k **nächsten Nachbarn** und Mehrheitsentscheid

Distanzfunktionen

- ▶ Abstandsklassifikator mit einem Prototypen pro Klasse
 - Geeignet für kompakte Klassen mit geringer Merkmalsstreuung
 - M Klassen mit je einem Prototypen $\bar{z}_1, \bar{z}_2, \dots, \bar{z}_M$
 - Für jede Klasse ω_i Berechnung des Abstands $D_i = \left\| x - \bar{z}_i \right\|$
 - Entscheidungsregel

$$\bar{x} \rightarrow \omega_i \quad \text{wenn} \quad D_i < D_j,$$


$$\forall i \neq j, \quad i = 1, 2, \dots, M$$
 - Zusätzlich kann ein maximaler Abstand pro Klasse definiert werden
 - Bei Überschreitung Rückweisung des zu klassifizierenden Vektors



Distanzfunktionen

► Abstandsklassifikator mit >1 Prototypen pro Klasse

- M Klassen mit je N_i Prototypen $\vec{z}_i^1, \vec{z}_i^2, \dots, \vec{z}_i^{N_i}$
- Abstand pro Klasse ω_i : $D_i = \min_l \left\| \vec{x} - \vec{z}_i^l \right\|, \quad l = 1, 2, \dots, N_i \quad \text{und} \quad i = 1, 2, \dots, M$
- Entscheidungsregel
 $\vec{x} \rightarrow \omega_i \quad \text{wenn} \quad D_i < D_j,$
 $\forall i \neq j, \quad i = 1, 2, \dots, M$
- Ggf. zusätzlich maximaler Abstand pro Klasse und Prototyp
 - Bei Überschreitung Rückweisung des zu klassifizierenden Vektors
- Geeignet für Klassen mit größerer Merkmalsstreuung und/oder mehreren isolierten Ballungen im Merkmalsraum



Distanzfunktionen


► Nächster-Nachbar-Klassifikator

- Jeder Vektor $\vec{s}_1, \vec{s}_2, \dots, \vec{s}_N$ gehört eindeutig zu einer der Klassen $\omega_1, \omega_2, \dots, \omega_M$ (Stichprobenraum mit bekannter Klassifikation)
- $\vec{s}_i \in \{\vec{s}_1, \vec{s}_2, \dots, \vec{s}_N\}$ ist nächster Nachbar zu dem noch zu klassifizierenden \vec{x} , wenn

$$D(\vec{s}_i, \vec{x}) = \min_l \{D(\vec{s}_l, \vec{x})\} \quad l = 1, 2, \dots, N$$

D : beliebiges Distanzmaß im Merkmalsraum


- Entscheidungsregel:
 $\vec{x} \rightarrow \omega_i$ zu der \vec{s}_i gehört
- Neu klassifizierte Vektoren können den Stichprobenraum erweitern



Distanzfunktionen

► k -nächste-Nachbarn-Klassifikator ($k > 1$)


- Bestimme die Menge der k nächsten Nachbarn
- Ermittle Klassenzugehörigkeit von \hat{x} durch Mehrheitsentscheid (z.B. über die jeweilige Anzahl k der nächsten Nachb. pro Klasse)
- Im Beispiel würde der Mehrheitsentscheid bei 5 nächsten Nachbarn 3:2 für ω_j ausgehen
- Ein zu großes k führt dazu, dass weit entfernte Nachbarn mit einbezogen werden
- Wenn die Trainingsdaten nicht gleichverteilt sind, werden Klassen mit vielen Beispielen bevorzugt
- Erweiterung: Höhere Gewichtung näherer Nachbarn



Distanzfunktionen

► k -nächste-Nachbarn-Klassifikator ($k > 1$) – Beispiel

- Grünes Quadrat ist neu zu klassifizieren
- Mit $k=1$ Klassifikation zu der mit gelben Sternen markierten Klasse (dunkel blauer Bereich)
- Mit $k=5$ Klassifikation zu der mit roten Fünfecken markierten Klasse (hell blauer Bereich)



<http://de.wikipedia.org/wiki/Bild:Knn.png>

Klassifikation


- ▶ Einführung
- ▶ Klassifikationsverfahren
 - Distanzfunktionen
 - Diskriminantenfunktionen
 - Bayes Klassifikator
 - Entscheidungsbaum
 - Clusteranalyse
- ▶ Zusammenfassung

Diskriminantenfunktionen

- ▶ Trennfunktionen, in die der gemessene Merkmalsvektor des zu klassifizierenden Objekts eingesetzt wird
- ▶ Klassifikation aufgrund des berechneten Ergebnisses
- ▶ Man kann Trennfunktionen unterscheiden hinsichtlich
 - Grad des Polynoms (linear, quadratisch, kubisch ...)
 - Dimension des Merkmalsraums
 - einfacher Fall (für grafische Beispiele): 2 Dimensionen
 - typischerweise höhere Dimensionen (=Anzahl Merkmale!)
 - Anzahl der zu trennenden Klassen
 - einfacher Fall: zwei Klassen
 - Fälle mit > 2 Klassen und entsprechend vielen Trennfunktionen

Diskriminantenfunktionen

► Lineare Trennfunktionen im **zweidimensionalen** Raum



$$d(\hat{x}) = w_1 x_1 + w_2 x_2 + w_3 = 0$$

Entscheidungsregel

$$\hat{x} \rightarrow \omega_1 \quad \text{falls} \quad d(\hat{x}) > 0$$

$$\hat{x} \rightarrow \omega_2 \quad \text{falls} \quad d(\hat{x}) < 0$$

(für $d(\hat{x}) = 0$ unbestimmt!)

- Bestimmung der Parameter w_i aus Klassenstichprobe
- Problem: Anordnung der Klassen im Merkmalsraum erlauben oft keine lineare Trennung
 - Dann Verwendung nicht-linearer Trennfunktionen

Diskriminantenfunktionen

- ▶ **Lineare** Trennfunktionen im **n -dimensionalen** Raum

$$d(\vec{x}) = w_1 x_1 + w_2 x_2 + \dots w_n x_n + w_{n+1} = \vec{W}_0^T \vec{x} + w_{n+1}$$

mit $\vec{W}_0 = [w_1, w_2, \dots, w_n]$ als Gewichts/Parameter – Vektor

- ▶ Bei n Merkmalen hat die Funktion $n+1$ Parameter
- ▶ Gemessene Werte für x_i einsetzen und klassifizieren
- ▶ Für **2 Klassen**:

$$d(\vec{x}) = \vec{W}^T \vec{x} = \begin{cases} > 0 & \text{falls } \vec{x} \rightarrow \omega_1 \\ < 0 & \text{falls } \vec{x} \rightarrow \omega_2 \end{cases}$$

mit

$$\vec{W} = [w_1, \dots, w_{n+1}]^T \quad \text{und} \quad \vec{x} = [x_1, \dots, x_n, 1]^T$$

Diskriminantenfunktionen

- ▶ **Lineare** Trennfunktionen im **n -dimensionalen** Raum
- ▶ Allgemein, für **$M > 2$ Klassen**
- ▶ **Fall 1:** Jede Klasse ist von den anderen Klassen durch **eine** Trennfunktion separierbar, M Funktionen mit


$$d_i(\hat{x}) = \hat{W}_i^T \hat{x} = \begin{cases} > 0 & \text{falls } \hat{x} \rightarrow \omega_i \\ < 0 & \text{sonst} \end{cases}$$

mit $i = 1, \dots, M$

$$\hat{W}_i = [w_{i_1}, \dots, w_{i_n}, w_{i_{n+1}}]^T$$

Diskriminantenfunktionen

- ▶ Beispiel: **Lineare** Trennfunktionen im **zweidimensionalen** Raum für **drei** Klassen, separierbar durch **eine** Funktion pro Klasse



$$\begin{aligned} d_1(\vec{x}) &= -x_1 + x_2 = 0 \\ d_2(\vec{x}) &= x_1 + x_2 - 5 = 0 \\ d_3(\vec{x}) &= -x_2 + 1 = 0 \end{aligned}$$

$$\begin{aligned} \vec{x} &\rightarrow \omega_1, \text{ wenn } d_1(\vec{x}) > 0, \\ \vec{x} &\rightarrow \omega_2, \text{ wenn } d_2(\vec{x}) > 0, \\ \vec{x} &\rightarrow \omega_3, \text{ wenn } d_3(\vec{x}) > 0, \end{aligned}$$

Beispiel: Wenn $\vec{x} = (6, 5)^T$ gemessen wurde, dann

$$\left. \begin{aligned} d_1(\vec{x}) &= -1 \\ d_2(\vec{x}) &= 6 \\ d_3(\vec{x}) &= -4 \end{aligned} \right\} \Rightarrow \vec{x} \rightarrow \omega_2$$

Diskriminantenfunktionen


- ▶ **Lineare** Trennfunktionen im **zweidimensionalen** Raum für $M > 2$ **Klassen**
- ▶ Fall 2: Jede Klasse ist **nur paarweise** separierbar

- ▶ $\Rightarrow M(M-1)/2$ Trennfunktionen mit

$$d_{ij}(\vec{x}) = \vec{w}_{ij}^T \vec{x} \quad \text{mit} \quad d_{ij}(\vec{x}) = -d_{ji}(\vec{x})$$

- ▶ Entscheidungsregel:


$$\vec{x} \rightarrow \omega_i \quad \text{wenn} \quad d_{ij}(\vec{x}) > 0, \quad \forall i \neq j$$



Diskriminantenfunktionen

► Lineare Trennfunktionen im zweidimensionalen Raum

- Beispiel mit **drei** Klassen, die nur paarweise separierbar sind



$$d_{12}(\vec{x}) = -x_1 - x_2 + 5 = 0$$

$$d_{13}(\vec{x}) = -x_1 + 3 = 0$$

$$d_{23}(\vec{x}) = -x_1 + x_2 = 0$$

z.B.

$\vec{x} \rightarrow \omega_1$, wenn

$$d_{12}(\vec{x}) > 0,$$

$$d_{13}(\vec{x}) > 0$$

Beispiel: Wenn $\vec{x}^T = (4, 3)^T$ gemessen wurde, dann

$$d_{12}(\vec{x}) = -2 \Leftrightarrow d_{21}(\vec{x}) = 2$$

$$d_{13}(\vec{x}) = -1 \Leftrightarrow d_{31}(\vec{x}) = 1$$

$$d_{23}(\vec{x}) = -1 \Leftrightarrow d_{32}(\vec{x}) = 1$$

$\Rightarrow \vec{x} \rightarrow \omega_3$, da $d_{3j}(\vec{x}) > 0$ für $\forall i \neq j$

Klassifikation

- ▶ Einführung
- ▶ Klassifikationsverfahren
 - Distanzfunktionen
 - Diskriminantenfunktionen
 - Bayes Klassifikator
 - Entscheidungsbaum
 - Clusteranalyse
- ▶ Zusammenfassung

Bayes Klassifikator

► Definitionen und Voraussetzungen

- $x = (x_1, x_2, \dots, x_M)$ M -dimensionaler Merkmalsvektor
- $P(C_i)$ Wahrscheinlichkeit für das Auftreten der Klasse C_i , $i = 1, \dots, N$ (a-priori Wahrscheinlichkeit)
- $P(x/C_i)$ Wahrscheinlichkeit für das Auftreten des Vektors x , wenn die Klasse C_i gegeben ist (klassenbedingte Wahrscheinlichkeit)
- $P(x)$ Wahrscheinlichkeit für das Auftreten des Vektors x ohne Vorgabe einer bestimmten Klasse
- $P(C_i/x)$ Wahrscheinlichkeit, dass ein gegebener Vektor x aus der Klasse C_i stammt (a posteriori Wahrscheinlichkeit, gesucht)

Bayes Klassifikator

► Bayes Satz:

$$P(C_i | x) = \frac{P(x | C_i) \cdot P(C_i)}{P(x)}$$

Wkt. für x in
Klasse C_i

a-priori
Wkt.
von C_i

Wkt. das x
gemessen
wird

► wobei

$$P(x) = \sum_{k=1}^N P(x | C_k) \cdot P(C_k)$$

Bayes Klassifikator

- ▶ Beispiel: Zwei Urnen U_1 und U_2 identischen Aussehens
 - U_1 enthält 900 weiße und 100 rote Kugeln
 - U_2 enthält 100 weiße und 900 rote Kugeln
- ▶ Frage: Wie wahrscheinlich ist es jeweils, dass man aus U_1 bzw. U_2 gezogen hat, wenn die Kugel weiß ist?
- ▶ A priori Wahrscheinlichkeiten $P(U_1)=P(U_2)=0,5$
- ▶ Klassenbedingte Wahrscheinlichkeit für eine weiße Kugel:

$$P(\text{weiß} | U_1) = \frac{900}{1000} = 0,9 \quad P(\text{weiß} | U_2) = \frac{100}{1000} = 0,1$$

Bayes Klassifikator

- ▶ A posteriori Wahrscheinlichkeit, dass wir aus U_1 bzw. U_2 gezogen haben, wenn die Kugel weiß ist:

$$P(U_1 | \text{weiß}) = \frac{P(\text{weiß} | U_1) \cdot P(U_1)}{P(\text{weiß})} =$$

$$\frac{P(\text{weiß} | U_1) \cdot P(U_1)}{P(\text{weiß} | U_1) \cdot P(U_1) + P(\text{weiß} | U_2) \cdot P(U_2)} = \frac{0,9 \cdot 0,5}{0,9 \cdot 0,5 + 0,1 \cdot 0,5} = 0,9$$

$$P(U_2 | \text{weiß}) = 0,1$$

Bayes Klassifikator

- ▶ Definitionen und Voraussetzungen im kontinuierlichen Fall
 - $x = (x_1, x_2, \dots, x_M)$ M -dimensionaler Merkmalsvektor
 - $P(C_i)$ Wahrscheinlichkeit für das Auftreten der Klasse C_i , $i = 1, \dots, N$ (a-priori Wahrscheinlichkeit)
 - $p(x/C_i)$ Wahrscheinlichkeit für das Auftreten des Vektors x , wenn die Klasse C_i gegeben ist (klassenbedingte Verteilungsdichte)
 - $p(x)$ Verteilungsdichte für das Auftreten des Vektors x ohne Vorgabe einer bestimmten Klasse
 - $P(C_i/x)$ Wahrscheinlichkeit, dass ein gegebener Vektor x aus der Klasse C_i stammt (a posteriori Wahrscheinlichkeit)

Bayes Klassifikator

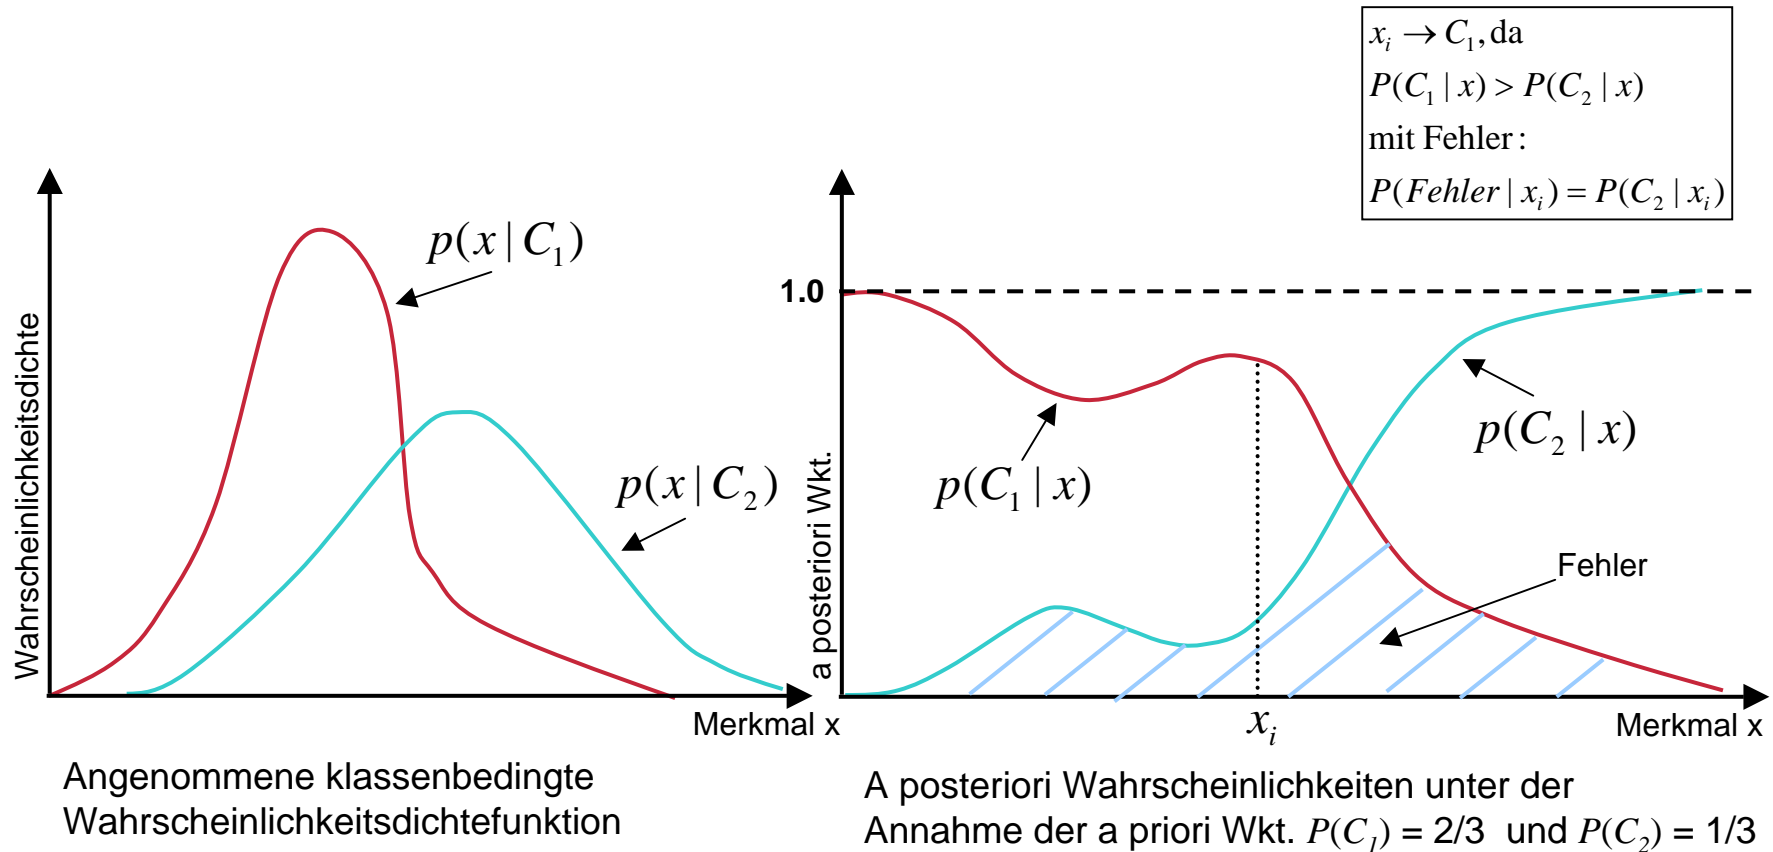
- ▶ Bayes Entscheidungsregel:
 - Klassifikation von x unter der Voraussetzung, dass die a priori Wahrscheinlichkeiten und die klassenbedingten Wahrscheinlichkeiten bekannt sind:

$$x \rightarrow C_i \Leftrightarrow \forall j \neq i : P(C_i | x) > P(C_j | x)$$

- ▶ Berechnung des Fehlers bei Zuordnung von x zu einer Klasse C_i

$$P(\text{Fehler} | x) = \sum_{j \neq i} P(C_j | x) = 1 - P(C_i | x) \quad \text{für } x \rightarrow C_i$$

Bayes Klassifikator



Klassifikation

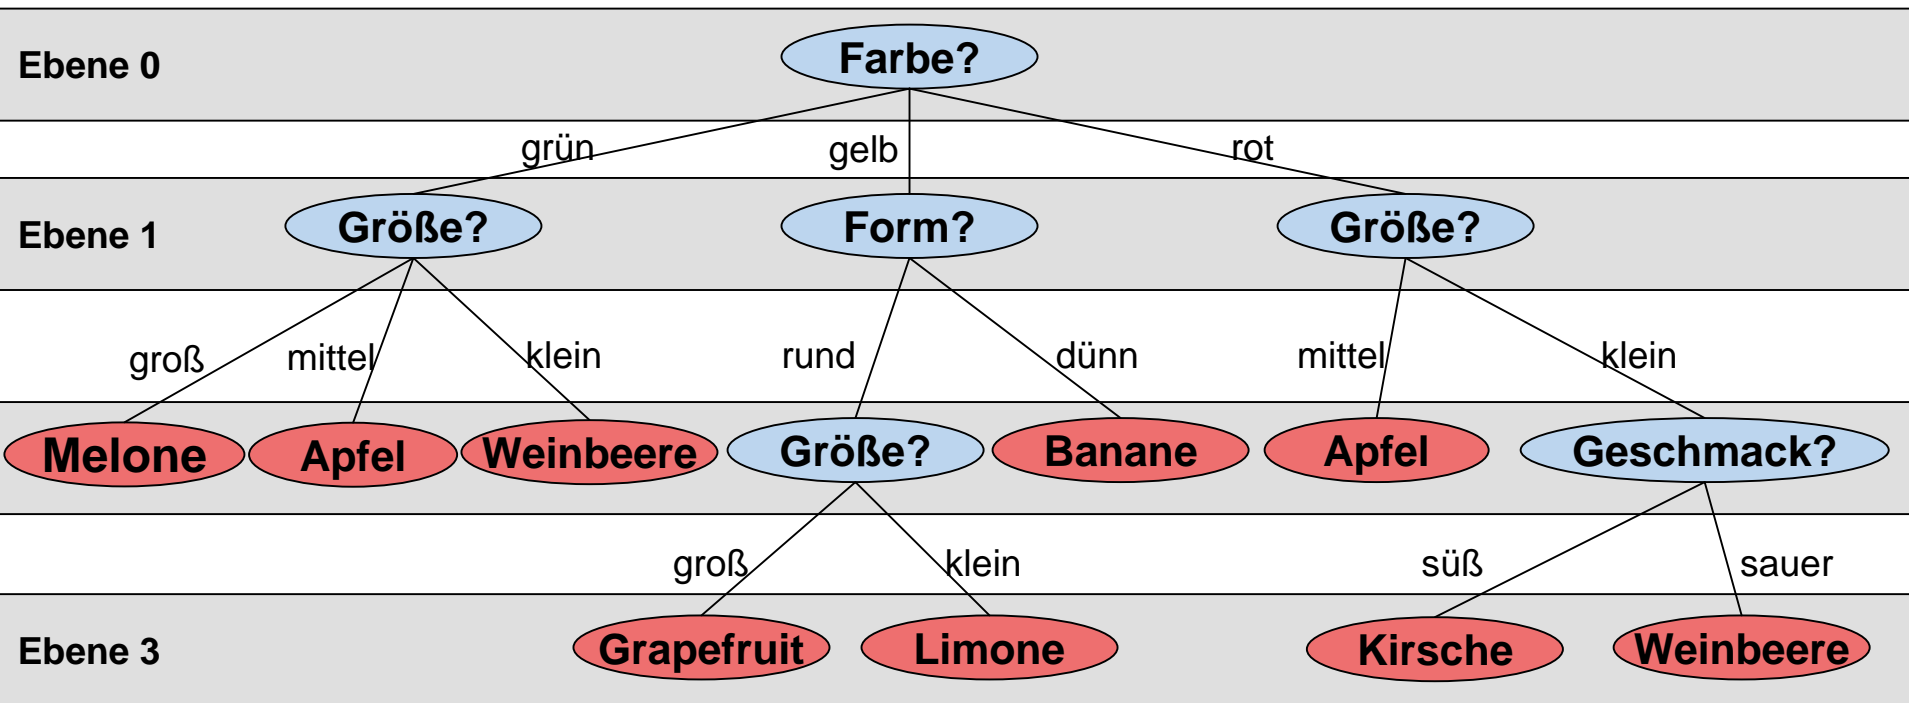
- ▶ Einführung
- ▶ Klassifikationsverfahren
 - Distanzfunktionen
 - Diskriminantenfunktionen
 - Bayes Klassifikator
 - Entscheidungsbaum
 - Clusteranalyse
- ▶ Zusammenfassung

Entscheidungsbaum

- ▶ Muster wird mittels einer Reihe von Fragen klassifiziert
- ▶ Die nächste zu stellende Frage ist abhängig von der Position im Baum
- ▶ Entscheidungen: ja/nein, wahr/falsch oder Werte (Eigenschaften) ...
- ▶ Reihenfolge der Fragen beeinflusst u.U. das Ergebnis, z.B. wenn
 - Bestimmte Eigenschaften sicherer erkannt werden können als andere
 - Bestimmte Eigenschaften besonders wichtig für die Entscheidung sind

Entscheidungsbaum

► Beispiel: Klassifikation von Früchten



Klassifikation


- ▶ Einführung
- ▶ Klassifikationsverfahren
 - Distanzfunktionen
 - Diskriminantenfunktionen
 - Bayes Klassifikator
 - Entscheidungsbaum
 - Clusteranalyse
- ▶ Zusammenfassung

Clusteranalyse

- ▶ Cluster = Anhäufung von Punkten im Merkmalsraum
- ▶ Zusammenfassen von Ansammlungen ähnlicher Objekte (bzw. Merkmalsvektoren) zu Clustern
 - Bewertung der Abstände der Vektoren im Cluster (z.B. Summe der Abstände zu einem Mittelwert oder Schwerpunkt) bzw. der Streuung
 - Verwendung eines geeigneten Abstandsmaßes
- ▶ Aufbau von Baumstrukturen abhängig vom maximal erlaubten Abstand der Cluster
- ▶ Hierarchisches versus partitionierendes Clustern

Clusteranalyse

► Visualisierung der Baumstrukturen: Dendrogramm



Hierarchische Clusteranalyse

▶ Anhäufende Verfahren

- Beginne mit ein-elementigen Clustern (pro Objekt ein Cluster)
- In jedem Schritt werden die jeweils einander nächsten Cluster zusammengefasst

▶ Teilende Verfahren

- Beginne mit großen Clustern und verfeinere sie durch schrittweise Teilung

▶ Abbruchbedingungen

- Anzahl der Cluster klein genug oder
- Distanz zwischen Clustern groß genug

Hierarchische Clusteranalyse

- ▶ Abstand zwischen Paaren *einzelner* Elementen a, b über Abstandsmaß (euklidisch, Manhattan, etc.)
- ▶ Bestimmung des Abstandes zwischen *Clustern* – verschiedene Varianten
 1. Minimaler Abstand zweier Elemente aus den beiden Clustern (*Single Linkage*)

$$\min_{a \in A, b \in B} \{d(a, b)\}$$

- Bewertung der Nähe der Grenzen
- Begünstigt die Bildung weniger, großer Cluster
- Ausreißer in den Messwerten beeinflussen das Ergebnis nicht

Hierarchische Clusteranalyse

► Bestimmung des Abstandes zwischen Clustern (2)

2. Maximaler Abstand zweier Elemente aus den beiden Clustern (*Complete Linkage*)

- Bewertung der Ausdehnung
- Begünstigt die Bildung kleiner, homogener Cluster
- Ausreißer können dazu führen, dass Cluster trotz grundsätzlicher Ähnlichkeit nicht als ähnlich bewertet werden

$$\max_{a \in A, b \in B} \{d(a, b)\}$$

3. Durchschnittlicher Abstand aller Elementpaare aus den beiden Clustern (*Average Linkage*)

$$\frac{1}{|A| \cdot |B|} \sum_{a \in A} \sum_{b \in B} d(a, b)$$

Hierarchische Clusteranalyse

► Bestimmung des Abstandes zwischen Clustern (3)

4. Durchschnittlicher Abstand aller Elementpaare aus der Vereinigung der beiden Cluster (*Zentroid*)

$$\frac{1}{|C|} \sum_{x,y \in C, C=A \cup B} d(x, y)$$

5. Abstand der Mittelwerte der beiden Cluster
6. Bewertung der Ähnlichkeit anhand der Zunahme der Varianz durch Vereinigung der beiden Cluster.
 - Je geringer die Zunahme, desto ähnlicher sind die Cluster

Partitionierende Clusteranalyse

► k-means-Algorithmus

- Voraussetzungen
 - Anzahl k der gesuchten Cluster bekannt
 - Funktion zur Bestimmung des Mittelpunktes eines Clusters bekannt
- Vorgehensweise
 1. Initialisierung mit k zufällig gewählten Clustermittelpunkten
 2. Zuordnung jedes Elements zum nächsten Clustermittelpunkt
 3. Neuberechnung der Clustermittelpunkte
 4. Weiter mit 2. bis ein stabiler Zustand erreicht wird (oder max. Anzahl Iterationen erreicht ist)

Partitionierende Clusteranalyse

- ▶ k-means-Algorithmus - Eigenschaften
 - Leicht und effizient zu implementieren
 - Konvergiert nicht immer
 - Cluster können leer werden (und bleiben)
 - Anzahl k der gesuchten Cluster muss bekannt sein
 - Wahl der initialen Clustermittelpunkte beeinflusst das Ergebnis

Klassifikation

- ▶ Einführung
- ▶ Klassifikationsverfahren
 - Distanzfunktionen
 - Diskriminantenfunktionen
 - Bayes Klassifikator
 - Entscheidungsbaum
 - Clusteranalyse
- ▶ Zusammenfassung

Zusammenfassung

- ▶ Ziel der Klassifikation: Zuordnung unbekannten Bildobjekte zu Klassen bzw. Kategorien
- ▶ Vorbedingung: Segmentierung und Merkmalsextraktion
- ▶ Wahl signifikanter, ggf. zuvor normierter Merkmale ist entscheidend, da die Klassifikation aufgrund der beobachteten Merkmale erfolgt (Mustererkennung)
- ▶ Klassenzuordnung über verschiedene Verfahren
 - Überwacht, mit vorgegebenen Klassen
 - Distanzfunktionen, Trennfunktionen, Entscheidungsbaum
 - Bayes Klassifikator (statistisch)
 - Unüberwacht, ohne Vorgabe von Klassen (Clusteranalyse)

Klassifikation – Literatur

- ▶ [Duda 00] R. O. Duda, P.E. Hart and G. Storck. *Pattern Classification*. 2nd Ed., Wiley, 2000.
- ▶ [Mitchell 97] T. M. Mitchell. *Machine Learning*. Mc Graw Hill, 1997.
- ▶ [Berkhin 02] P. Berkhin. Survey of clustering data mining techniques, 2002. <http://citeseer.ist.psu.edu/berkhin02survey.html>
- ▶ [Russell 03] S. Russell and P. Norvig. *Artificial Intelligence. A modern Approach*. 2nd Edition, Prentice Hall, 2003.
- ▶ [Niemann 03] H. Niemann. *Klassifikation von Mustern*. 2. überarbeitete Auflage im Internet. <http://www5.informatik.uni-erlangen.de/Personen/niemann/klassifikation-von-mustern/m00links.html>

Verarbeitungsstufen der Bildanalyse

- ▶ **Bildgebung**
 - Bilderfassung durch verschiedene Sensoren
- ▶ **Vorverarbeitung**
 - Bildverbesserung, ...
- ▶ **Segmentierung**
 - Trennung: Objekt/Hintergrund
- ▶ **Merkmalsextraktion**
 - Farbe, Kontur, Textur...
- ▶ **Klassifikation**
 - Diskriminantenfkt., Abstand, Wahrscheinlichkeit,...



**Mustererkennungs-
Paradigma**

Bildgebende Verfahren

- ▶ Prinzip: Physikalische Größen messen und als Bild darstellen
 - Licht (Fotografie)
 - Infrarotstrahlung (z.B. Thermografie)
 - Röntgenstrahlung (Röntgen, Computertomographie (CT))
 - Radioaktivität (z.B. Positronen-Emissions-Tomographie (PET))
 - (Ultra-)Schall
 - Kernspinresonanz (NMR, *Nuclear Magnetic Resonance*)
 - Zeit (z.B. Echolot, Laser-Entfernungsmessung)

Bildgebende Verfahren

- ▶ Gewinnung von Bildinformationen
 - Passive Sensoren empfangen nur
 - Fotokamera
 - Digitalkamera
 - Aktive Sensoren senden und empfangen
 - Lauflängenverfahren (z.B. EBK, Ultraschall, Radar, Sonar)
 - Strukturiertes Licht

Bildgebende Verfahren: Fotografie

- ▶ Lochkamera (camera obscura)
 - Hohler schwarzer Würfel (Kamera)
 - Kleines Loch auf einer Seite (Lochblende)
 - Halbtransparente Fläche auf der gegenüberliegenden Seite (Bildebene)
 - Objekt wird verkleinert und kopfüber auf die Fläche im Kamerainneren projiziert
 - Je kleiner das Loch, desto schärfer (aber auch lichtschwächer) die Abbildung




Bild: http://upload.wikimedia.org/wikipedia/de/9/9d/Lochkamera_prinzip.jpg

Bildgebende Verfahren: Fotografie

► Lochkameramodell

- **A**: optische Achse
- **C**: Optisches Kamerazentrum
- **R**: Bildebene
- **F**: Fokalebene
- **f**: Brennweite
- **g**: Höhe des Gegenstands

► Blendenzahl= f/D

- D = Durchmesser der Blende





Bild: Erich Rome und Marina Kolesnik: 3D-Szenenrekonstruktion aus Bilddaten. Einführung in den Stand der Technik. Technischer Bericht MAKRO/V1/1, 1998. S. 6
 URL: www.ais.fraunhofer.de/projects/Makro/reports/makro-report-VI-1.pdf

Bildgebende Verfahren: Fotografie

► CCD-Kamera


- CCD = charge coupled device statt Film
 - Matrix aus Fotodioden
 - Auftreffenden Licht erzeugt (analoge) Spannungswerte




<http://upload.wikimedia.org/wikipedia/commons/a/a1/CCD.jpg>

Bildgebende Verfahren: Fotografie

► Farb-CCD



Color Filter Array Sensor



© 2003 Vincent Bockaert [123di.com](http://www.123di.com)

http://www.dpreview.com/Learn/Articles/Glossary/Camera_System/images/123di_cfa.gif

- Progressive-Scan-CCD
- RGB Bilder durch Beschichtung mit Farbfilter (Bayer-Sensor)
- Fehlende Farbinformationen werden aus benachbarten Werten interpoliert

Bildgebende Verfahren: Fotografie

► A/D-Wandlung

- Analog/digital Wandlung
- Digitalisierung der Spannungswerte des CCD in Helligkeitswerte




Bild: http://www.dpreview.com/Learn/Articles/Glossary/Camera_System/images/123di_adc.gif

Bildgebende Verfahren: Scannen

- ▶ To scan= abtasten
 - Flachbettscanner (s. Bild)
 - Durchlichtscanner
- ▶ Bildgewinnung durch eine Vielzahl von Einzelmessungen
- ▶ CCD Sensor
 - Kamera: Flächensensor
 - Scanner: Einzel- oder Zeilensensor (punktweise bzw. zeilenweise Erfassung)




http://cgi.zdnet.de/glossar/i/small/id18f10_t.png

Bildgebende Verfahren: Thermographie

- ▶ Wärmestrahlung sichtbar machen
 - Rettungseinsätze (Aufspüren von Verletzten)
 - Wärmeverlust an Gebäuden (Bauthermografie)
 - Sichtbar machen von inneren Defekten an Bauteilen
 - Vorherige Erwärmung
 - Beobachtung der Wärmeausbreitung über die Zeit
- ▶ Berührungsloses Verfahren
- ▶ Flächige Temperaturmessung und –darstellung
- ▶ Ggf. auch über die Zeit

Bildgebende Verfahren: Thermographie



- ▶ Wärmebild vom Aufrüsten eines Heißluftballons

http://commons.wikimedia.org/wiki/Image:Infarot_9.jpg

Bildgebende Verfahren: Thermographie

- ▶ Wärmebildkamera



http://upload.wikimedia.org/wikipedia/commons/d/de/Thermal_camera.jpg

Bildgebende Verfahren: Röntgen


- ▶ Durchstrahlung des zu erfassenden Körpers mit elektromagnetischen Wellen
- ▶ Die je nach Dichte unterschiedlich starke Absorption wird in Grauwerten kodiert
- ▶ Einsatz vorwiegend in der Medizin, aber auch in der Materialprüfung
- ▶ Berührungslos und zerstörungsfrei



http://upload.wikimedia.org/wikipedia/commons/1/1c/Polydactyly_01_Lhand_AP.jpg

Bildgebende Verfahren: CT


- ▶ Computertomographie (CT)
- ▶ Bildfolge von Röntgenbildern aus verschiedenen Blickwinkeln
- ▶ Computergestützte Aufbereitung zu einem dreidimensionalen Bild
- ▶ Einsatz vorwiegend in der Medizin, aber auch in der Materialprüfung
- ▶ Berührungslos und zerstörungsfrei



http://isgnw.cs.uni-magdeburg.de/~regina/skript_ct.html

Bildgebende Verfahren: MRT

- ▶ Magnetresonanztomographie (MR, MRT, Kernspintomographie)
- ▶ Schnittbilder des untersuchten Körpers oder Objektes
- ▶ Darstellung von weichem Gewebe und Organen
- ▶ Nutzung magnetische Felder statt Röntgenstrahlen
- ▶ Einsatz in der Medizin, aber auch auf anderen Gebieten, z.B. in der Materialprüfung
- ▶ Berührungslos und zerstörungsfrei



http://upload.wikimedia.org/wikipedia/commons/7/72/Brain_chrischan_300.gif

Bildgebende Verfahren: MRT

- ▶ Aufbau eines starken, gleichmäßiges Magnetfeld um den Körper
- ▶ Anregung der Kerne der Wasserstoffatome im Körper durch Radiowellen (Resonanz)
- ▶ Wasserstoffatome werden in eine spezielle Schwingung bzw. Drehbewegung versetzt
- ▶ Abschalten des Impulses lässt die Schwingungen abklingen
- ▶ Visualisierung des je nach Umgebung der Wasserstoffatome unterschiedliche Abklingverhalten (→ Bildgebung!)



www.radnuk-am-ring.de/MRT.jpg

Bildgebende Verfahren: Ultraschall

- ▶ Ultraschall = Schallfrequenzen 20 kHz-1 GHz
- ▶ Für den Menschen nicht hörbar
- ▶ Messung der Laufzeit und der Ausbreitungsgeschwindigkeit der Schallwellen
- ▶ Echolot: akustische Tiefenmessung im Wasser, ca. 100 KHz (siehe Bild)
- ▶ Sonar (sound navigation and ranging): Ortung von Objekten unter Wasser
- ▶ Sonographie: Klinische Diagnostik und Werkstoffprüfung, ca. 1-40 KHz
- ▶ Anwendung auch in der Tierwelt: Fledermäuse, Delphine



Bild: <http://upload.wikimedia.org/wikipedia/de/7/7e/Echolot.png>

Bildgebende Verfahren: Sonographie

- ▶ Ultraschall in der klinischen Diagnostik und zur Untersuchung technischer Strukturen
- ▶ Keine Strahlenbelastung
- ▶ Hohe Ortsauflösung
- ▶ Darstellung der Stärke der Schallreflexion als Grauwerte
- ▶ Gewebe und Knochen reflektieren je nach Flüssigkeitsgehalt unterschiedlich stark



Bild: <http://upload.wikimedia.org/wikipedia/de/1/16/Sonographie.jpg>

Verarbeitungsstufen der Bildanalyse

- ▶ **Bildgebung**
 - Bilderfassung durch verschiedene Sensoren
- ▶ **Vorverarbeitung**
 - Bildverbesserung, ...
- ▶ **Segmentierung**
 - Trennung: Objekt/Hintergrund
- ▶ **Merkmalsextraktion**
 - Farbe, Kontur, Textur...
- ▶ **Klassifikation**
 - Diskriminantenfkt., Abstand, Wahrscheinlichkeit,...



**Mustererkennungs-
Paradigma**

Prüfungen

- ▶ Insgesamt ca. 80 Prüflinge für mündliche oder schriftliche Prüfung
- ▶ Termine wurden per Mail bekannt gegeben und können nachgesehen werden unter <http://www.tzi.de/~andrea/BV-1-Pruefungen.html>
- ▶ Dort findet ihr auch Informationen, die sich nach Ende der Veranstaltung noch ergeben
- ▶ Prüfungstermine sind verbindlich, nicht Erscheinen muss als nicht bestanden gewertet werden (Ausnahme: Krankheit mit ärztlichem Attest)

Nachweise für Prüfungsleistungen

- ▶ SBLN Formulare brauchen nicht selber ausgefüllt werden!

- ▶ Andere spezielle Bescheinigungen
 - Bitte wenn möglich die jeweilige Bescheinigung vorausgefüllt mitbringen
 - Bitte informiert mich, falls ich selber vorab Prüfungsunterlagen anfordern muss!

Prüfungen

- ▶ Prüfungsrelevante Themen:
Stoff von Bildverarbeitung 1, **außer**
 - Menschliches Sehen / biologische Grundlagen
 - Optische Täuschungen
 - Teilgebiet Hit or Miss (Binär-BV), Skelettierung aber schon!
 - Texturwahrnehmung (Julesz + eigene Experimente)

Prüfungen – Fragen (1)

- ▶ Wissensfragen, z.B.
 - Was ist ein Histogramm?
 - Nenne drei geometrische Merkmale
- ▶ Praktische Anwendung von Wissen, z.B.
 - Kante in einer Bildzeile berechnen durch Bilden der diskreten ersten Ableitung
 - Ein einfaches Bild mit einer gegebenen Filtermaske filtern
- ▶ Erläuterung von Algorithmen (informell), z.B.
 - Wie funktioniert Blob-Coloring?

Prüfungen - Fragen

- ▶ Interpretation von Ergebnissen, z.B.
 - Vorgegeben wird eine Cooccurrence Matrix.
Was kann man daran ablesen?
 - Siehe auch Übungsaufgaben
- ▶ Verständnisfragen: Warum ist etwas so oder anders?
 - Beispiel: Wieso sind die zentralen Momente erster Ordnung 0?
 - Siehe auch Übungsaufgaben

Prüfungen

- ▶ Soll man Formeln auswendig lernen?
 - Nein, es bringt nichts, Formeln auswendig zu lernen!
 1. Man vergisst sie sowieso wieder
 2. Man kann sie im Bedarfsfall nachschlagen, vorausgesetzt man weiß, was man erreichen will
- ▶ Man soll die Verfahren und Formeln verstanden haben
 - Formeln, die in der Vorlesung besprochen wurden, sollte man kennen und erläutern können
 - z.B. Formel für Kreisförmigkeit wird gezeigt und ihr erläutert, was sie berechnet
 - Vorgehensweisen und Verfahren sollte man beschreiben können, woraus sich die Formel oft ergibt
 - z.B. lineare Histogrammskalierung

Prüfungen

- ▶ Bei Formeln, die in der Vorlesung nur der Vollständigkeit halber angegeben wurden, reicht es zu wissen, dass es sie gibt 😊, das betrifft
 - Umrechnung zwischen Farbmodellen
 - Hu Momente
 - Statistische Merkmale auf der Cooccurrence- und der Grauwertlauflängenmatrix
- ▶ Falls diese Formeln in der Prüfung gebraucht werden (unwahrscheinlich!), werden sie vorgegeben

Schriftliche Prüfungen

- ▶ Fragen wie bei der mündlichen Prüfung
- ▶ Längere Bearbeitungszeit (zur Sicherheit 90 Minuten, die aber bestimmt niemand brauchen wird)
- ▶ Drei Termine zur Wahl:
 - Donnerstag, 15.02.2007, 10:30-12:00
 - Dienstag, 27.02.2007, 11:30-13:00
 - Mittwoch, 28.03.2007, 14:00-15:30
- ▶ Verbindliche Anmeldung erforderlich (ggf. bereits vereinbarter Termin für mündliche Prüfung entfällt dann)
- ▶ Nicht geeignet für diejenigen, die für ihr Diplom eine Modulprüfung brauchen

Prüfungen

- ▶ Fragen zu den Prüfungen?
- ▶ Wenn sich während der Vorbereitung noch Fragen ergeben, könnt ihr mich per Mail erreichen
- ▶ Fragen und Antworten von allgemeinem Interesse werde ich auf die Webseite stellen