

Gliederung

Bildabtastung und Digitalisierung

Technische Komponenten

Grauwertstatistik

Punktoperatoren

Lokale Operatoren

Globale Operatoren

Merkmalsextraktion

Klassifikation (Mustererkennung)

Codierung

Gliederung

1. Verfahren / Übersicht
2. Segmentierung / ROI (siehe auch Vorlesungskomplex 8)
3. Klassifikation
 - 3.1 Begriffe, grundlegende Sachverhalte
 - 3.2 Phasen der Klassifikation
 - 3.3 Merkmalsextraktion / Klassifikation: einfache Beispiele
 - 3.4 Klassentrennung anhand von Merkmalen / Merkmalsgüte
 - 3.5 Klassifikatoren: Übersicht, Zielstellungen
 - 3.6 ausgewählte nichtstatistische Klassifikatoren und Beispiele
 - 3.6.1 Parallel-Epipiped-Klassifikatoren
 - 3.6.2 Nearest-Neighbour-Klassifikator
 - 3.6.3 K-Nearest-Neighbour-Klassifikator
 - 3.6.4 Minimum-Distanz-Klassifikator
 - 3.6.5 Klassifikation mittels LUT
 - 3.7 Statistische Klassifikatoren
 - 3.7.1 kurze Wiederholung zur Wahrscheinlichkeitsrechnung / math. Statistik
 - 3.7.2 Maximum-Likelihood-Klassifikator
 - 3.7.3 Bayes-Klassifikator

1. Verfahren / Übersicht


Klassifikationsschritte:

- . Segmentierung,
- . Merkmalsextraktion,
- . Anordnung im Merkmalsraum,
- . eigentliche Klassifikation


Klassifikationsverfahren (Auswahl):

- . Ebenen-, Quader-, Hyperquader-Klassifikator,
- . Hauptebenen transformation (Hilfsmittel für Ebenen- und Hyperquader-Klassifikatoren)
- . Minimal-Distanz
- . Maximum Likelihood


Klassifikation anschaulich



Segmentierung



Merkmalsextraktion



Klassifikation


2. Segmentierung / ROI

Segmentierung:

Trennung von Objekt(en) und Hintergrund im gesamten Bild oder in ausgewählten Bereichen (ROI → region of interest)

Verfahren der Segmentierung (Auswahl), siehe auch bisherige Vorlesungskomplexe:

- Kantenextraktion / Konturverfolgung
- Punkt- bzw. lokale und globale Operatoren (Grauwertstatistik)
- Schwellwertverfahren (statisch bzw. adaptiv)
- Farben
- ...




Verfahren zur Festlegung von ROI

manuell / interaktiv

An Labor- bzw.
Entwicklerarbeitsplätzen,


Bei Stichprobenprüfungen z.B.
in Prüflabors zur
Qualitätsicherung



Beispiel: Partikel auf
Objekträger aus Glas


automatisch

bei der Prozesskontrolle in fortlaufenden
Serienprüfungen, z.B. in Förderstrecken




Beispiel: Werkstück mit
Bohrungen

Automatische Festlegung von ROI




Statisch (feste Position innerhalb des Bildfeldes bei verschiedenen Bildern), mögliches Problem: Objekt außerhalb des ROI




dynamisch (Festlegung in Abhängigkeit von anderen Bildmerkmalen, z.B. Positionen von Justiermarken, Referenzkanten usw.), Nachteil: höherer Rechenaufwand

Automatische Festlegung von ROI




Objekte innerhalb des ROI

Automatische Festlegung von ROI



Objekte innerhalb des ROI

Automatische Festlegung von ROI




Objekte außerhalb des ROI !!!

Segmentierung (Trennung von Objekt und Hintergrund) / Variante:


Definition von Bereichen innerhalb Objekte umschließender Flächenelemente (meist Rechtecke → Sub-ROI's); Ein ROI enthält dann nur ein Objekt

Anwendung z.B. bei der Klarschriftlesung



Beispiel der Segmentierung bei der Klarschriftlesung

Segmentierung (Trennung von Objekt und Hintergrund) im ROI



Beispiele: Trennung von Objekten und Hintergrund durch Anwendung der Grauwertstatistik (Binarisierung), jeweils in einer ROI

3. Klassifikation

3.1 Begriffe, grundlegende Sachverhalte

Klassifikation: Begriffe / grundlegende Sachverhalte

- Zuordnung von Objekten zu Klassen anhand der Merkmale (Merkmalsvektoren)
- Anforderungen an Objektmerkmale: signifikant, miteinander nicht korreliert

Klassifikation: Begriffe / grundlegende Sachverhalte

1. Merkmalsextraktion: von einem Objekt wird ein Satz von n -Merkmalen C_v ermittelt (Fläche, Form, Farbe, Textur...)
2. Merkmalsraum: Eintragen der Merkmale in n -dimensionalen Merkmalsraum; Beachte: n -Merkmale spannen n -dim. Merkmalsraum auf.
3. Merkmalsvektor: Von jedem Objekt gibt es einen Merkmalsvektor (Gesamtheit der Merkmale)
4. Merkmalscluster: Anhäufung von Objektmerkmalen im Merkmalsraum nennt man Cluster.
4. Eindeutige Klassenzuordnung: wenn sich die Cluster nicht überlappen, ist eine fehlerfreie Klassifikation möglich (andernfalls ist es das Ziel, die Klassifikationsfehler zu minimieren, z. B. Bayes-Klassifikator)

3.2 Phasen der Klassifikation

Klassifikation / Phasen

- 1. Einlernphase (während der Anwendungsentwicklung oder Prozessanpassung):** Bildung von Clustern durch Merkmalsextraktion von bekannten Stichproben; Cluster beschreiben die Zugehörigkeit zu Klassen im Merkmalsraum
- 2. Klassifikationsphase (im laufenden Prozess, in der Serienprüfung usw.)**
Untersuchung unbekannter Objekte auf Zugehörigkeit zu Clustern bzw. Klassen

Klassifikation / Phasen

Verschiedene Möglichkeiten des Einlernens

Überwachtes Lernen

Merkmale (Farbe, Form usw.) und Klassen sind bereits vorher weitestgehend bekannt. Durch genügend große Stichproben werden beim Anlernen die Clustergrenzen bestimmt

Unüberwachtes Lernen

Es sind keine Merkmale bekannt, welche die Objekte signifikant beschreiben. Ggf. ist auch die Anzahl möglicher Klassen nicht bekannt. Von Stichproben werden verschiedene Merkmale bestimmt und diese auf Clusterbildung untersucht. Merkmale mit signifikanter Clusterbildung werden dann in der Klassifikationsphase verwendet, die anderen Merkmale werden wieder verworfen.

Klassifikation: Einlernphase

Beispiel Klarschriftlesung

Teach In: z.B. Erfassung der Merkmale von Binärbildern, welche die Ziffern 0..9 präsentieren durch Untersuchung einer repräsentativen Anzahl von Stichproben


Datensatz																					
Muster				...				...			...		...		...			...			
Bedeutung	"1"	"1"	"1"	...	"2"	"2"	"2"	...	"3"	"3"	...	"4"	...	"5"	...	"9"	"9"	...	"0"	"0"	"0"
Klasse (Nr)	1	1	1	...	2	2	2	...	3	3	...	4	...	5	...	9	9	...	10	10	10

Klassifikation / Einlernphase: mögliche Fehler

- **Gewählte Stichprobe zu klein → Merkmalsraum wird nicht vollständig abgedeckt (in der Klassifikationsphase können dann viele Objekte nicht klassifiziert werden),**
- **nahezu Wertgleichheit eines oder mehrerer Parameter für Objekte unterschiedlicher Klassen (Clustergrenzen zu dicht bzw. Clusterüberschneidungen) → Parameter ungeeignet, da zu große Überschneidungen mit anderen Parametern oder: anderen Klassifikator verwenden,**
- **Abhängigkeit voneinander (z.B. sind bei Rechtecken mit konstanten Seitenverhältnis beide Seitenlängen als Merkmale voneinander abhängig, eine Seitenlänge kann also weggelassen werden),**

3.3 Klassifikation / einfache Beispiele

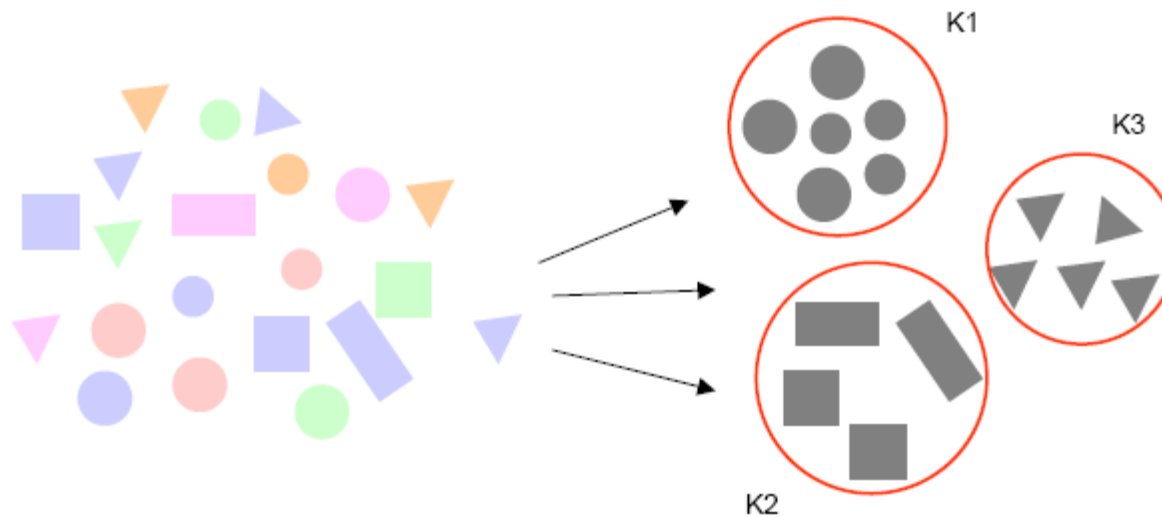
Klassifikation: Beispiele



Merkmal: Farbe

(1-dim. Merkmalsraum)

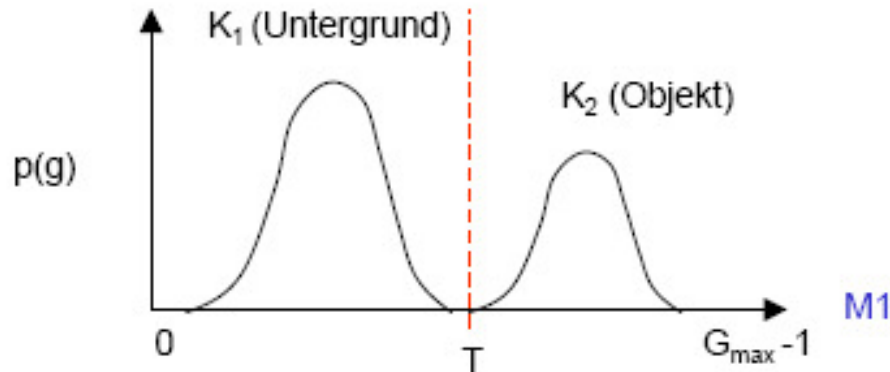
Klassifikation: Beispiele



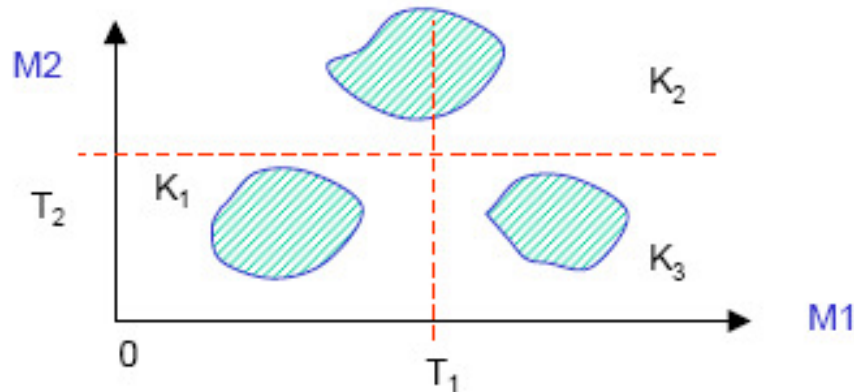
Merkmal: Form

(1-dim. Merkmalsraum)


Klassifikation: Beispiele




Trennung von Objekt (K2) und Hintergrund (K1)



Trennung von 3 verschiedenen Objekten (K1 .. K3)



1 Merkmal → 1D-Merkmalraum



2 Merkmale → 2D-Merkmalraum!

Klassifikation: weiteres Beispiel

- siehe Vorlesungsschwerpunkt Merkmalsextraktion (Blutanalyse)

3.4 Klassentrennung / Merkmalsgüte


Merkmalsgüte

- Merkmalsgüte entscheidend für Klassifikationsgüte
- Gesucht ist eine Maßzahl für die Merkmalsgüte
- Beispiel:

Gegeben sind zwei Klassen K_1 und K_2 die das Merkmal C_v (Merkmalsindex) besitzen.
Die Klassen besitzen

- den klassenbedingten Mittelwert \bar{m}_{k_v}

- die klassenbedingte Varianz $\sigma^2_{k_v}$



Intuitiv einleuchtend:

- Gute Klassentrennung, wenn:
- große Differenz der Mittelwerte
 - kleine Streuungen

Gütemaß


- Definition:

$$G_V = \frac{\left(\bar{m}_{1V} - \bar{m}_{2V} \right)^2}{\sigma_{1V}^2 + \sigma_{2V}^2}$$

mit

$$\bar{m} = \frac{1}{n} \sum_{i=1}^n f_i \quad \text{Mittelwert}$$

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (f_i - \bar{m})^2 \quad \text{Varianz}$$

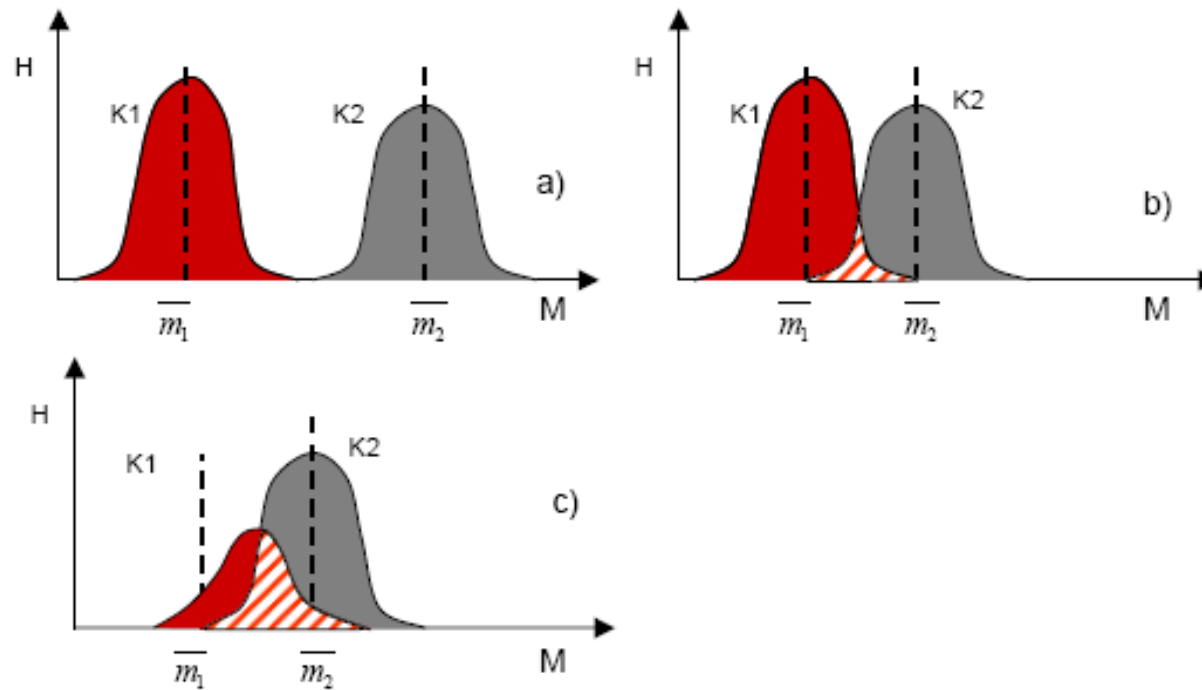


Ziel:

$$\bar{m}_{1V} - \bar{m}_{2V} \quad (\text{Differenzen der Mittelwerte}) \Rightarrow \text{Max}$$

$$\sigma_{1V}^2 + \sigma_{2V}^2 \quad (\text{Summe der Varianzen}) \Rightarrow \text{Min}$$

Beispiele:



Fälle für Klassentrennung:

- a) eindeutige Trennung
- b) c) bedingt trennbar (z. B. Bayes)

3.5 Klassifikatoren: Übersicht / Zielstellungen

Klassifikatoren / Übersicht (Auswahl)

- Parallel-Epiped-Klassifikator (Rechteck-, Quader-, Hyperquader-Klassifikator,
 - Hauptachsentransformation (Hilfsmittel zur Vereinfachung bei Anwendung von Parallel-Epiped-Klassifikatoren)
- Nearest-Neighbour-Klassifikator
- k-Nearest-Neighbour-Klassifikator
- Minimum-Distanz-Klassifikator
- Statistische Klassifikatoren: Maximum-Likelihood-Klassifikator und Bayes-Klassifikator
- Klassifikation mittels LUT,
- Klassifikation mittels Neuronaler Netze oder Fuzzy-Logic

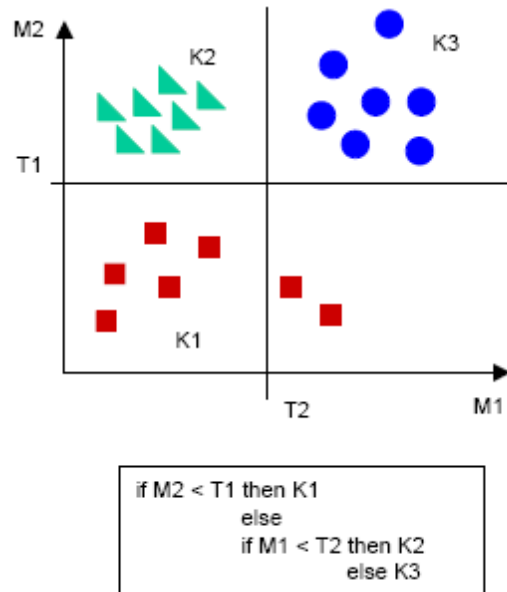
Zielstellungen bei der Merkmalsauswahl

- Dimensionalität des Merkmalsraumes ↓
- Merkmalsanzahl ↓
- Relevanz des Merkmals ↑
- Bedingung: Unkorreliertheit der Merkmale

- hohe Merkmalsrelevanz → hohe Merkmalsgüte

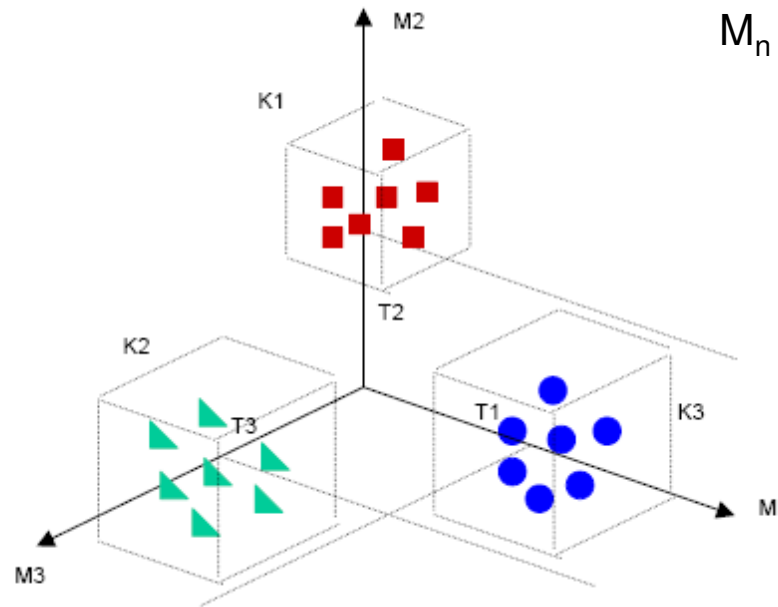
3.6 Ausgewählte Klassifikatoren (Beispiele)

3.6.1 Parallel-Epiped-Klassifikatoren



K_m – Cluster

M_n – Merkmale



Zweidimensional
Rechteck-Klassifikator

Dreidimensional
Quader-Klassifikator



n-dimensional
Hyperquader-Klassifikator

Parallel-Epiped-Klassifikatoren: Vor- und Nachteile

- geringer Rechenaufwand
- Bei Clusterüberlappungen ist nicht immer eine eindeutige Klassifikation möglich

Parallel-Epiped-Klassifikatoren

eignen sich vor Allem bei unkorrelierten (orthogonalen) Merkmalen




Hauptachsentransformation (Bei der Anwendung von Parallelepipet-Klassifikatoren)

Beispiel

Aufgabe: Eine Erntemaschine soll Kartoffeln und Steine voneinander trennen.
Mit dem Merkmal Form ist kein Unterschied in Klassen möglich.

Betrachtet man die Merkmale: M1 (Volumen) und
M2 (Gewicht) so bekommt man zu folgenden Verteilungen:



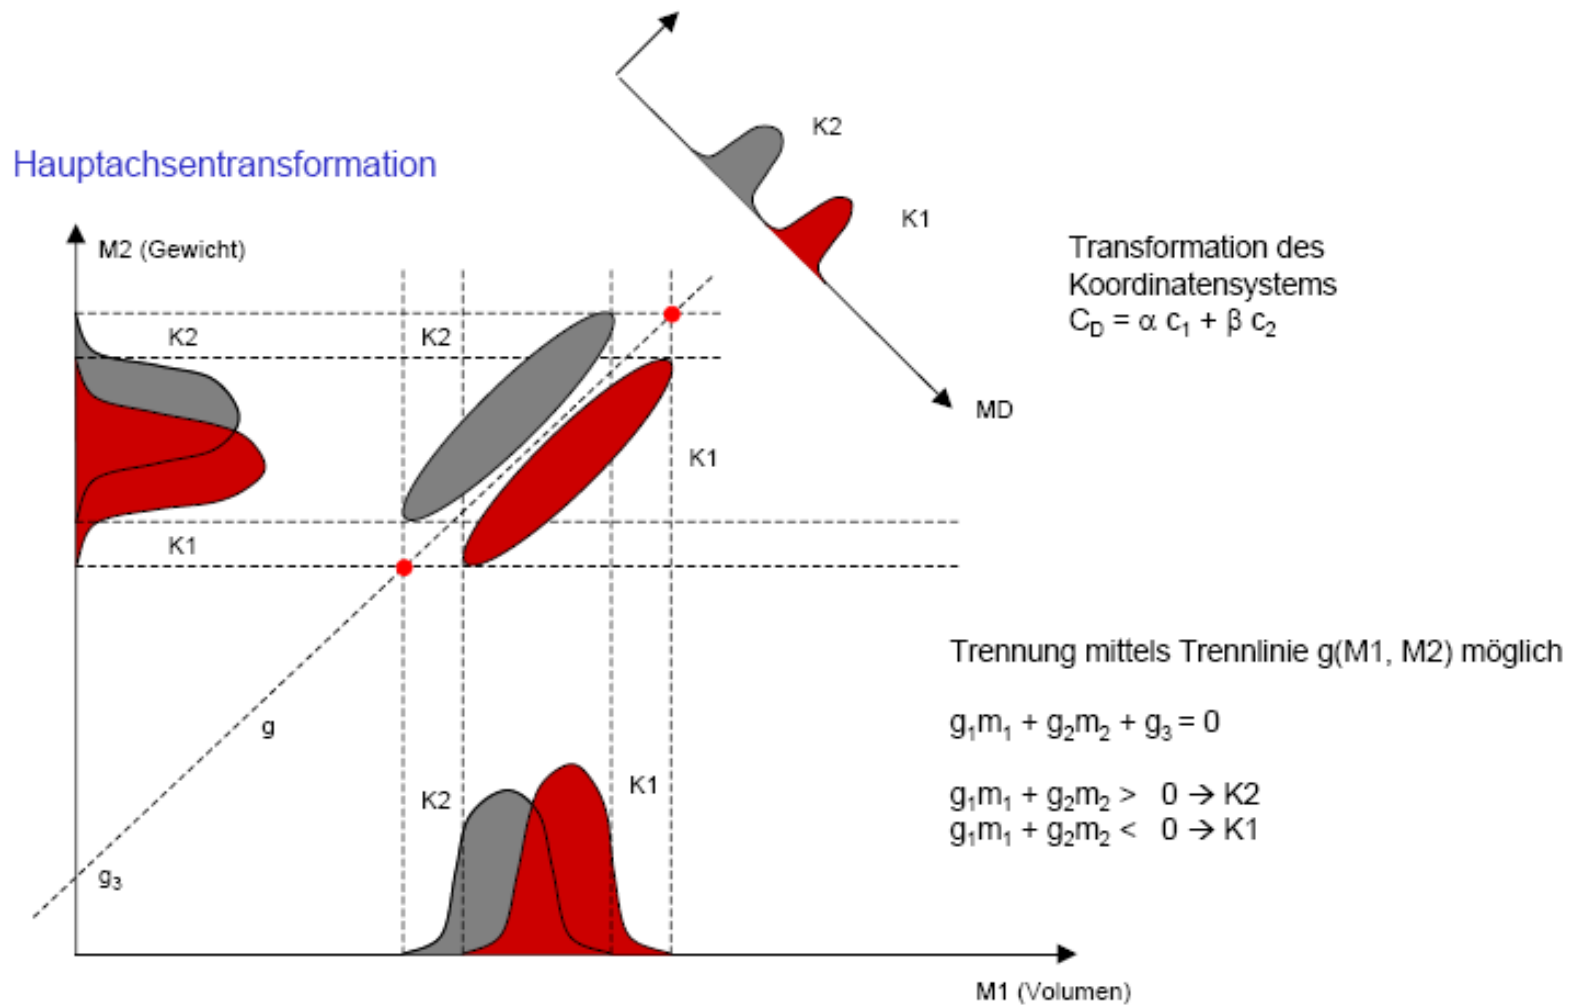
Man kann erkennen, dass sich diese Objekte auch in diesen Parametern nicht eindeutig unterscheiden.

Betrachtet man jedoch Volumen und Gewicht gemeinsam in einem 2D-Histogramm:


Volumen (M1) → X-Achse,

Gewicht (M2) → Y-Achse → erhält man folgende Cluster:

Hauptachsentransformation (Bei der Anwendung von Parallelepipet-Klassifikatoren)




3.6.2 Nearest-Neighbour-Klassifikator



Zuweisung zur Klasse des Objektes mit dem kleinsten euklidischen Abstand zum neuen Objekt

- **geeignet für überlappende Cluster**
- **Gefahr der Falschzuweisung**

3.6.3 K-Nearest-Neighbour-Klassifikator



Beispiel: $k=6$

Untersuchung der k Objekte mit den kleinsten Abständen zum zu klassifizierenden Objekt; Zuordnung zur am häufigsten auftretenden Klasse dieser Objekte

- **geeignet für überlappende Cluster**
- **etwas stabiler gegenüber Falschzuweisungen**


3.6.4 Minimum-Distanz-Klassifikator

(eignet sich auch bei korrelierten Merkmalen)

d) Minimum-Distanz-Klassifikator

Vorgehensweise:

1. Bestimmung Flächenschwerpunkt C_i (M_1, M_2) aller Cluster.
2. Bestimmung Abstand des akt. Merkmalsvektors V_j (M_1, M_2) zu allen Flächenschwerpunkten.
3. Min. Abstand entspricht der Klassenzugehörigkeit.



Voraussetzung: Merkmale besitzen Normalverteilungen

Als Abstandmaß gilt der Euklidische Abstand

$$d_e = \sqrt{(M_{1C_i} - M_{1V_j})^2 + (M_{2C_i} - M_{2V_j})^2}$$

Merkmal 1 (x-Koord. Flächenschwerp.) Cluster i		Merkmal2 (y-Koord. Flächenschwerp.) Cluster i	
Merkmal1 (x-Koord.) Vektor		Merkmal2 (y-Koord.) Vektor	

Minimum-Distanz-Klassifikator

Aufgabe: In einem 2D-Merkmalraum (d.h. 2 Merkmale) werden 3 Cluster festgestellt mit folgenden Klassen-Flächenschwerpunkten:

$$C1: \quad M_{1_{c_1}} = 52 \quad M_{2_{c_1}} = 60$$

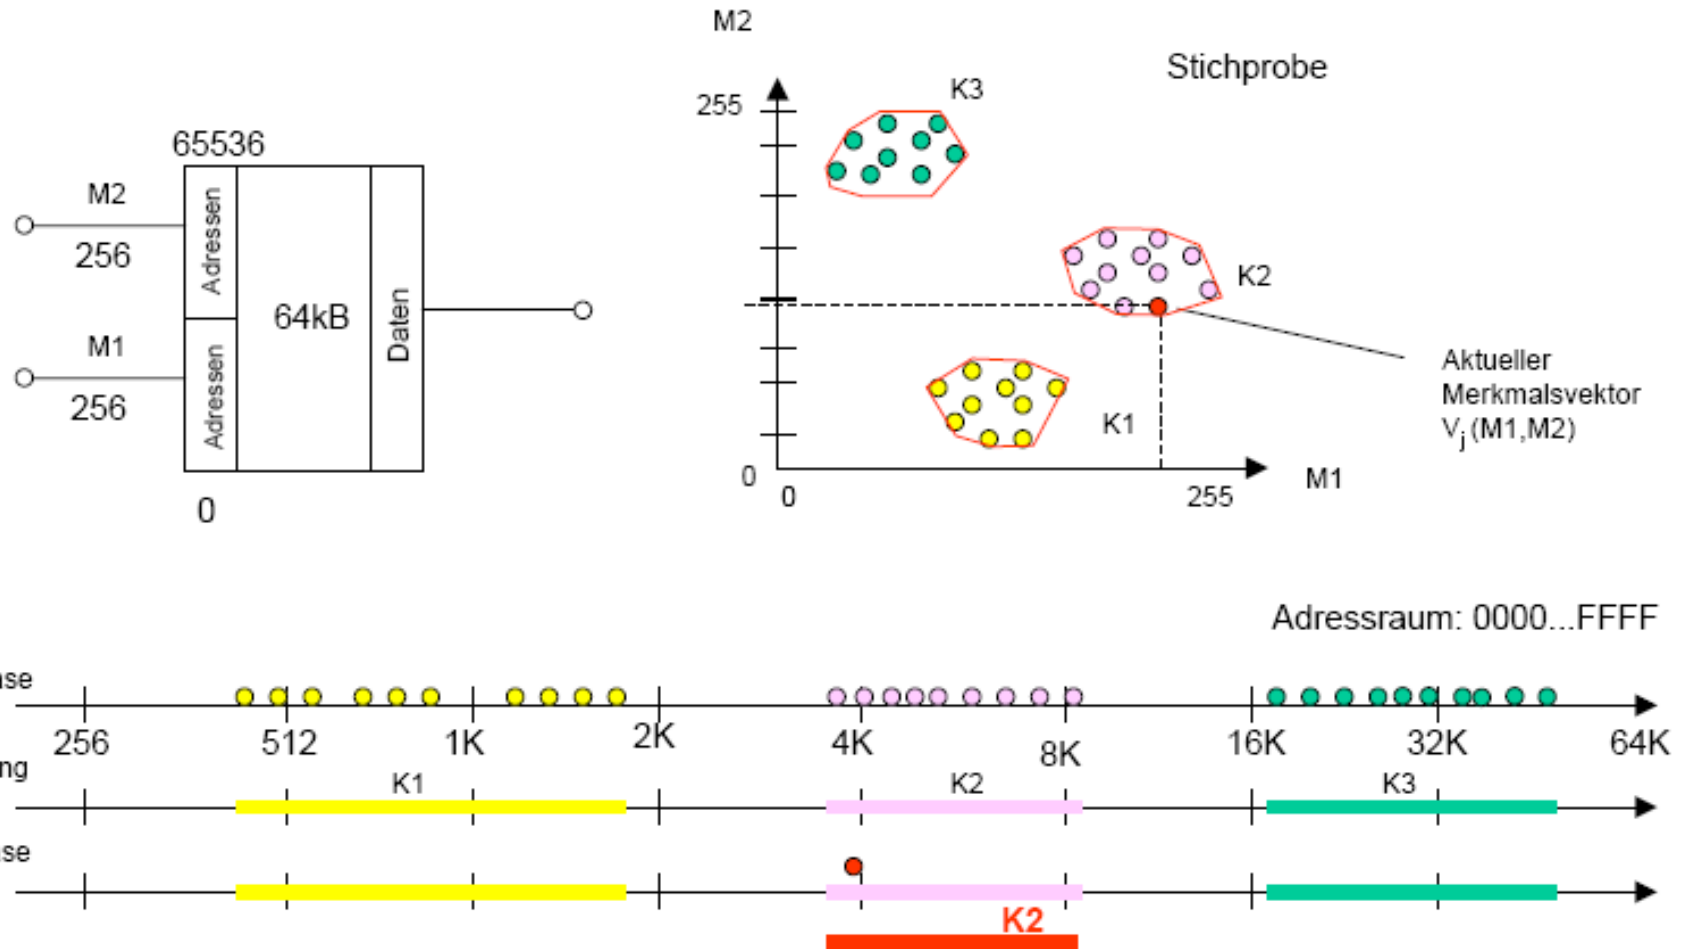
$$C2: \quad M_{1_{c_2}} = 28 \quad M_{2_{c_2}} = 38$$

$$C3: \quad M_{1_{c_3}} = 68 \quad M_{2_{c_3}} = 34$$

Neuer Merkmalsvektor: $M_{1_{v_1}} = 58 \quad M_{2_{v_1}} = 25$

Frage: Zu welchem Cluster (Klasse) gehört V_j ?

3.6.5 Klassifikation mittels LUT



Klassifikation mittels LUT / Veranschaulichung

Matrixspeicher:

Durch Anlegen der 2-dim. Adresse (Merkmalsvektor) erhält man mit dem Inhalt der Speicherzelle sofort die zugehörige Klasse

	0	1	2	3	4	...	250	251	252	253	254	255
0						:						
1		3	3	3		:						
2		3	3	3		:						
3		3	3	3		:						
4						:						
:	:	:	:	:	:	...	:	:	:	:	:	:
252						:			2	2	2	
253						:			2	2	2	
254						:			2	2	2	
255						:						

Beispiel:

der Merkmalsvektor [252;253] gehört zur Klasse 2

45

Klassifikation mittels LUT / Veranschaulichung

Realisierung

- Entweder mittels Hardware (z.B. xy-adressierbarer Speicher)
- Oder per Software mittels ein- oder mehrdimensionaler Arrays

Klassifikation mittels LUT / Programmierbeispiel in C

Beispiel: siehe vorige Seite

```
void main()
```

```
:
```

```
:
```

```
int k, M[255][255];           Definition Klassenvariable k und Matrixspeicher M
```

```
:
```

```
k = M[252][253];
```

```
:
```

```
end.
```