

# 6 Klassifikation

## 6.1 Musterklassifikation als mathematische Abbildung

Objekte und Ereignisse werden für die Klassifikation als Merkmalsvektoren  $\vec{c}$  beschrieben.

Klassifikation ist die Konstruktion einer Abbildung, die den Merkmalsvektor  $\vec{c}$  in ein bestimmtes Symbol aus  $\Omega$  abbildet, d.h. gesucht wird Klassifikationsfunktion

$$g : C \mapsto \Omega \quad |\Omega| = K$$

## 6.1 Musterklassifikation als mathematische Abbildung

---

Oft ist es sinnvoll, die gewünschte Klasse  $\omega_i$  als **Zielvektor**  $\vec{y}_i, i = 1, \dots, K$ , zu repräsentieren

$$\vec{y}_i = \begin{pmatrix} 0 \\ \vdots \\ 0 \\ 1 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \leftarrow i - \text{te Komponente enthält } 1$$

Gehört ein Merkmalsvektor  $\vec{c}$  zur Klasse  $\omega_i$ , so wird der zugehörige Zielvektor mit  $\vec{y}$  bezeichnet.

In der Stichprobe haben wir  $N$  Muster(paare)  $(\vec{c}_n, \omega_n)$  bzw.  $(\vec{c}_n, \vec{y}_n)$

## 6.2 Statistische Grundlagen

### 6.2.1 Mustererzeugende Prozesse

Muster sind Wertepaare  $(\vec{c}, \omega)$ , die

- die Erscheinungsform, repräsentiert durch den Merkmalsvektor  $\vec{c} \in \mathcal{R}^M$
- mit der Bedeutung des Musters, repräsentiert durch die Klasse  $\omega \in \Omega$

verbinden.

Oft bezeichnen wir auch  $\vec{c}$  alleine als das Muster, die Klasse ist unbekannt.

Der mustererzeugende Prozeß (MEP) wird als stochastischer Prozeß modelliert, der mit der Wahrscheinlichkeit  $P(\vec{c}, \omega)$  zufällig aber nicht regellos Muster generiert.

Voraussetzungen für die automatische Klassifikation:

1. Die statistischen Eigenschaften des MEP sind stationär.
2. Statistische Eigenschaften in der Lernphase müssen sich auf die Arbeitsphase übertragen lassen, also wird eine repräsentative Stichprobe benötigt.

### 6.2.2 Wahrscheinlichkeiten und Wahrscheinlichkeitsdichten

Einer diskreten Zufallsvariable  $X$  wird die Wahrscheinlichkeiten  $P(X = x)$  zugeordnet.

Beispiel: - Augenzahl eines Würfels  $P(X = 1) = P(X = 2) = \dots = P(X = 6) = \frac{1}{6}$   
- die Klassenzugehörigkeit

Eine kontinuierlichen Zufallsvariable  $X$  wird durch Wahrscheinlichkeitsdichte  $P(X)$  beschrieben.

Beispiel: Lebensalter von Menschen

$$P(67 \leq X \leq 68) = \int_{67}^{68} P(X = x) dx$$

## 6.2 Statistische Grundlagen

---

Die Funktion  $F_X(x) = P(X \leq x)$  heißt **Verteilungsfunktion** der ZV  $X$ .

Beispiel: Augen eines Würfels:  $F_X(2,5) = P(X \leq 2,5) = P(1) + P(2) = \frac{1}{3}$

Beispiel Lebensalter:  $F_X(67,5) = P(X \leq 67,5) = \int_0^{67,5} P(x)dx$

Der **Erwartungswert** einer Zufallsvariablen  $X$  oder einer Funktion  $f(X)$  der Zufallsvariablen ist definiert als:

$$E_{P(X)}[f(X)] = \sum_x P(X = x) f(x) \quad \text{bzw.}$$
$$E_{P(X)}[f(X)] = \int_x P(x) f(x) dx$$

Die **Varianz** gibt die erwartete quadratische Abweichung vom Mittelwert

$$Var[f(X)] = E[(f(X) - E[f(X)])^2] = E[(f(X))^2] - (E[f(X)])^2$$

Die **Kovarianz** eines Vectors  $\vec{X}$  von Zufallsvariablen ist

$$Cov[\vec{X}] = E[(\vec{X} - E[\vec{X}])(\vec{X} - E[\vec{X}])^T]$$

## 6.2 Statistische Grundlagen

---

wie erwähnt, wird der MEP vollständig durch die Dichte  $P(\vec{c}, \omega)$  beschrieben.

Daraus lassen sich folgende Dichten und Wahrscheinlichkeiten (WK) ableiten (Randdichten):

- $P(\omega) = \int_{\vec{c}} P(\vec{c}, \omega) d\vec{c}$       a priori WK der Klasse  $\omega$
- $P(\vec{c}) = \sum_{\omega} P(\vec{c}, \omega)$       Dichte der Merkmale (unabhängig von der Bedeutung)

*Bedingte* Wahrscheinlichkeit und *bedingte* Dichte:

- *Klassenspezifische Dichte, likelihood*:  $P(\vec{c} | \omega)$
- *A posteriori-Wahrscheinlichkeit oder Rückschlußwahrscheinlichkeit*:  $P(\omega | \vec{c})$

Nach dem **Gesetz von Bayes** gilt:

$$P(\vec{c}, \omega) = P(\vec{c} | \omega)P(\omega) = P(\omega | \vec{c})P(\vec{c})$$

### 6.3 Minimierung des Klassifikationsrisikos

#### 6.3.1 Allgemeiner Ansatz

- für Klassifikationssysteme (KS) ist nur  $\vec{c}$ , nicht aber  $\omega$  sichtbar
- wir benötigen also eine Klassifikationsfunktion  $g(\vec{c})$  die jedem Merkmalsvektor eine Klasse aus  $\{\omega_1, \dots, \omega_K\}$  zuordnet oder als nicht gültig zurückweist.
- es kann durchaus vorkommen, daß die ermittelte Klasse  $g(\vec{c})$  nicht der tatsächlich vorliegenden Klasse  $\omega_{\text{soll}}$  entspricht
- eine solche (Fehl-)Klassifikation verursacht Kosten:  
Um diese Kosten näher zu bestimmen, stellt man eine Verlustmatrix  $V(\omega_{\text{soll}}, \omega_{\text{ist}})$  auf.  
Hierbei ist  $V(\omega_{\text{soll}}, \omega_{\text{ist}})$  der Verlust, der entsteht, wenn man sich für  $\omega_{\text{ist}}$  entscheidet, obwohl  $\omega_{\text{soll}}$  vorliegt.  
 $V$  ist abhängig von der Anwendung und muß per Hand bestimmt werden.



## 6.3 Minimierung des Klassifikationsrisikos

---

- Ziel ist es, den durchschnittlichen Verlust (das *Risiko*) zu minimieren, d.h. minimiere  $R = E[V] = E[V(\omega, g(\vec{c}))]$ .
- Zur Bestimmung von  $g(\vec{c})$  setzen wir eine klassifizierte Stichprobe ein.

## 6.3 Minimierung des Klassifikationsrisikos

Zunächst aber Berechnung des Risikos unter der Annahme, wir kennen die Verteilung des MEP.

$$\begin{aligned} R &= E\{V(\omega, g(\vec{c}))\} = \int_{\vec{c}} \sum_{\omega} V(\omega, g(\vec{c})) \cdot P(\vec{c}, \omega) d\vec{c} \\ \text{nach Bayes} &= \int_{\vec{c}} \sum_{\omega} V(\omega, g(\vec{c})) \cdot P(\omega | \vec{c}) \cdot P(\vec{c}) d\vec{c} \\ &= \int_{\vec{c}} \underbrace{\left( \sum_{\omega} V(\omega, g(\vec{c})) \cdot P(\omega | \vec{c}) \right)}_{R_{\vec{c}}(g(\vec{c})) = \text{Risiko für } \vec{c} \text{ oder lokales Risiko}} \cdot P(\vec{c}) d\vec{c} \\ &= \int_{\vec{c}} R_{\vec{c}}(g(\vec{c})) \cdot P(\vec{c}) d\vec{c} \end{aligned}$$

Das Gesamtrisiko ist natürlich minimal, falls  $R_{\vec{c}}(g(\vec{c}))$  minimal für jedes  $\vec{c}$  ist.

Da wir  $g(\vec{c})$  für jedes  $\vec{c}$  unabhängig wählen dürfen (wir haben keine Einschränkungen bezüglich der Funktion  $g$  gemacht), klappt das in diesem Fall.

## 6.3 Minimierung des Klassifikationsrisikos

---

Wir betrachten den allgemeinen Fall, dass eine Rückweisung zugelassen ist, d.h.

$$g(\vec{c}) \in \{\omega_0, \omega_1, \dots, \omega_K\}.$$

Es wird nun also das Minimum des lokalen Risikos

$$R_{\vec{c}}(g(\vec{c})) = \sum_{\omega} V(\omega, g(\vec{c})) \cdot P(\omega \mid \vec{c}) \quad (6.1)$$

gesucht.

Folgende Werte werden dazu benötigt:

- $V(\omega_{\text{soll}}, \omega_{\text{ist}})$ : Diese sind für jede Anwendung von Hand zu bestimmen.
- $P(\omega \mid \vec{c})$ : Diese Wahrscheinlichkeiten werden üblicherweise aus einer repräsentativen und klassifizierten Stichprobe geschätzt:

$$\hat{P}(\omega_i \mid \vec{c}) \propto \hat{P}(\vec{c} \mid \omega_i) \cdot \hat{P}(\omega_i)$$

(mehr dazu später)

### 6.3.2 Bayes-Klassifikator

Der Bayes-Klassifikator hat eine spezielle, symmetrische Kostenfunktion:

$$V(\omega_{\text{soll}}, \omega_{\text{ist}}) = \begin{cases} 0, & \text{falls } \omega_{\text{ist}} = \omega_{\text{soll}} \\ V_f, & \text{falls } \omega_{\text{ist}} \neq \omega_{\text{soll}} \wedge \omega_{\text{ist}} \neq \omega_0 \\ V_r, & \text{falls } \omega_{\text{ist}} = \omega_0 \end{cases}$$

## 6.3 Minimierung des Klassifikationsrisikos

---

Setzt man dies nun in Gleichung (6.1) ein, so erhält man für das lokale Risiko bei einer Fehlentscheidung (beachte:  $\omega_{\text{ist}} = g(\vec{c})$ ):

$$\begin{aligned} R_{\vec{c}}(\omega_{\text{ist}} \neq \omega_0) &= \sum_{\omega} V(\omega, \omega_{\text{ist}}) P(\omega \mid \vec{c}) \\ &= 0 \cdot P(\omega_{\text{ist}} \mid \vec{c}) + \sum_{\omega_i \neq \omega_{\text{ist}}} V_f P(\omega_i \mid \vec{c}) \\ &= V_f \sum_{\omega_i \neq \omega_{\text{ist}}} P(\omega_i \mid \vec{c}) \\ &= V_f (1 - P(\omega_{\text{ist}} \mid \vec{c})) \end{aligned}$$

und bei einer Rückweisung:

$$\begin{aligned} R_{\vec{c}}(\omega_{\text{ist}} = \omega_0) &= \sum_{\omega} V(\omega, \omega_{\text{ist}}) P(\omega \mid \vec{c}) \\ &= V_r \sum_{\omega} P(\omega \mid \vec{c}) \\ &= V_r \end{aligned}$$

## 6.3 Minimierung des Klassifikationsrisikos

---

durch Umformung erhalten wir äquivalent:  $\vec{d}(\vec{c}) = \begin{pmatrix} \frac{V_f - V_r}{V_f} \\ P(\omega_1 | \vec{c}) \\ \vdots \\ P(\omega_i | \vec{c}) \\ \vdots \\ P(\omega_K | \vec{c}) \end{pmatrix},$

das Risiko wird minimiert, falls man folgende Entscheidungsregel  $e$  anwendet:

$$g(\vec{c}) = e(\vec{d}(\vec{c})) = \omega_l, \quad \text{falls } l \text{ maximale Komponente von } \vec{d}(\vec{c}) \quad (6.2)$$

### 6.3.3 Maximum Likelihood Klassifikator

Beim Bayes-Klassifikator werden seltene Klassen „benachteiligt“.

$$P(\omega|\vec{c}) = \frac{P(\vec{c}|\omega)P(\omega)}{P(\vec{c})} \propto P(\vec{c}|\omega)P(\omega)$$

Um dies zu vermeiden verändert man die Kostenfunktion:

$$V(\omega_{\text{soll}}, \omega_{\text{ist}}) = \begin{cases} 0, & \text{falls } \omega_{\text{ist}} = \omega_{\text{soll}} \\ \frac{V_f}{P(\omega_{\text{soll}})}, & \text{falls } \omega_{\text{ist}} \neq \omega_{\text{soll}} \wedge \omega_{\text{ist}} \neq \omega_0 \\ V_r, & \text{falls } \omega_{\text{ist}} = \omega_0 \end{cases}$$

## 6.3 Minimierung des Klassifikationsrisikos

---

Setzt man dies nun in Gleichung (6.1) ein, so erhält man für das lokale Risiko bei einer Fehlentscheidung:

$$\begin{aligned} R_{\vec{c}}(\omega_{\text{ist}} \neq \omega_0) &= \sum_{\omega} V(\omega, \omega_{\text{ist}}) P(\omega \mid \vec{c}) \\ &= 0 \cdot P(\omega_{\text{ist}} \mid \vec{c}) + \sum_{\omega \neq \omega_{\text{ist}}} \frac{V_f}{P(\omega)} P(\omega \mid \vec{c}) \\ &= V_f \sum_{\omega \neq \omega_{\text{ist}}} \frac{1}{P(\omega)} \cdot \frac{P(\vec{c} \mid \omega) P(\omega)}{P(\vec{c})} \\ &= \frac{V_f}{P(\vec{c})} \left[ \left( \sum_{\omega} P(\vec{c} \mid \omega) \right) - P(\vec{c} \mid \omega_{\text{ist}}) \right] \end{aligned}$$

und bei einer Rückweisung:

$$\begin{aligned} R_{\vec{c}}(\omega_{\text{ist}} = \omega_0) &= \sum_{\omega} V(\omega, \omega_{\text{ist}}) P(\omega \mid \vec{c}) \\ &= V_r \sum_{\omega} P(\omega \mid \vec{c}) \\ &= V_r \end{aligned}$$



## 6.3 Minimierung des Klassifikationsrisikos

---

$$\text{Setzt man } \vec{d}(\vec{c}) = \begin{pmatrix} \sum_{\omega_i} P(\vec{c} | \omega_i) - \frac{V_r P(\vec{c})}{V_f} \\ P(\vec{c} | \omega_1) \\ \vdots \\ P(\vec{c} | \omega_i) \\ \vdots \\ P(\vec{c} | \omega_K) \end{pmatrix},$$

so wird das Risiko minimiert, falls man folgende Entscheidungsregel anwendet:

$$g(\vec{c}) = e(\vec{d}(\vec{c})) = \omega_l, \quad \text{falls } l \text{ maximale Komponente von } \vec{d}(\vec{c}) \quad (6.3)$$

### 6.4 Verteilungsfreie Klassifikatoren

Wir wollen jetzt die Klassifikation als Funktionsapproximation betrachten.

Gesucht ist eine Funktion  $\vec{d}(\vec{c})$ , eine sogenannte **Diskriminatorfunktion**, die jeden Merkmalsvektor eindeutig einer Klasse zuordnet:

- im allgemeinen Fall soll der Zielvektor  $\vec{y}$  approximiert werden
- im 2-Klassenfall oft stattdessen 0 für  $\omega_1$  und 1 für  $\omega_2$

#### 6.4.1 Quadratmittelansatz

- In Abschnitt 6.3 war die Optimierung ausgerichtet auf die Minimierung des Klassifikationsrisikos  $E\{V\}$ , und wir haben die statistischen Eigenschaften des MEP explizit betrachtet.

- jetzt wird der euklidische Abstand
  - der Diskriminatorfunktion  $\vec{d}(\vec{c})$  und
  - dem zum Zielvektor  $\vec{y}$minimiert
- genauer: minimiere den erwarteten quadratischen Fehler
$$S^2 = E_{P(\vec{c}, \vec{y})} [(\vec{y} - \vec{d}(\vec{c}))^2]$$
für Muster(paare)  $(\vec{c}, \vec{y})$

### 6.4.2 Lösung über Variationsrechnung

Unter Annahme, die optimale Lösung  $\vec{d}(\vec{c})$  sei bekannt, verschlechtert sich das Optimierungskriterium  $S^2$  durch jede Abweichung  $\delta\vec{d}(\vec{c})$ , das heißt, daß

$$S^2 \left( \vec{d}(\vec{c}) + \delta\vec{d}(\vec{c}) \right) \geq S^2 \left( \vec{d}(\vec{c}) \right) \quad \forall \delta \in \mathbb{R} \setminus \{0\} \quad (6.4)$$

(Im weiteren wird  $\vec{d}$  anstelle von  $\vec{d}(\vec{c})$  geschrieben.)

Mit  $S^2(\vec{d}) = E \left\{ (\vec{y} - \vec{d})^2 \right\} = E \left\{ (\vec{y} - \vec{d})^T (\vec{y} - \vec{d}) \right\}$  gilt:

$$\begin{aligned} S^2(\vec{d} + \delta\vec{d}) &= E \left\{ (\vec{y} - \vec{d} - \delta\vec{d})^T (\vec{y} - \vec{d} - \delta\vec{d}) \right\} \\ &= E \left\{ \underbrace{\vec{y}^T \vec{y}} - \underbrace{\vec{y}^T \vec{d}} - \underbrace{\vec{y}^T \delta\vec{d}} - \underbrace{\vec{d}^T \vec{y}} + \underbrace{\vec{d}^T \vec{d}} + \underbrace{\vec{d}^T \delta\vec{d}} - \underbrace{\delta\vec{d}^T \vec{y}} + \underbrace{\delta\vec{d}^T \vec{d}} + \delta\vec{d}^T \delta\vec{d} \right\} \\ &= \underbrace{E \left\{ (\vec{y} - \vec{d})^2 \right\}}_{S^2(\vec{d})} - 2 \underbrace{E \left\{ \delta\vec{d}^T (\vec{y} - \vec{d}) \right\}} + E \left\{ (\delta\vec{d})^2 \right\} \end{aligned}$$

## 6.4 Verteilungsfreie Klassifikatoren

---

Setzt man nun die erhaltenen Werte von  $S^2(d)$  und  $S^2(d + \delta d)$  in die Ungleichung (6.4) ein, so ergibt sich

$$\begin{aligned} E \left\{ (\vec{y} - \vec{d})^2 \right\} - 2E \left\{ \delta \vec{d}^T (\vec{y} - \vec{d}) \right\} + E \left\{ (\delta \vec{d})^2 \right\} &\geq E \left\{ (\vec{y} - \vec{d})^2 \right\} \quad \Leftrightarrow \\ \underbrace{E \left\{ (\delta \vec{d})^2 \right\} - 2E \left\{ \delta \vec{d}^T (\vec{y} - \vec{d}) \right\}}_{>0} &\geq 0 \end{aligned}$$

Diese Ungleichung ist auf jeden Fall erfüllt, falls  $E \left\{ \delta \vec{d}^T (\vec{y} - \vec{d}) \right\} = \vec{0}$  ist .

(Beachte: wir müssen diesen Term auch Null werden lassen, da  $\delta$  beliebig klein werden darf)

## 6.4 Verteilungsfreie Klassifikatoren

---

$$\begin{aligned} E \left\{ \delta \vec{d}^T (\vec{y} - \vec{d}) \right\} &= \int_{\vec{c}} \sum_{\vec{y}} \delta \vec{d}^T (\vec{y} - \vec{d}) \cdot P(\vec{c}, \vec{y}) d\vec{c} \quad (\text{nach Def}) \\ &= \int_{\vec{c}} \sum_{\vec{y}} \delta \vec{d}^T (\vec{y} - \vec{d}) \cdot P(\vec{y} | \vec{c}) \cdot P(\vec{c}) d\vec{c} \\ &= \int_{\vec{c}} \delta \vec{d}^T \left[ \sum_{\vec{y}} (\vec{y} - \vec{d}) P(\vec{y} | \vec{c}) \right] P(\vec{c}) d\vec{c} \stackrel{!}{=} \vec{0} \end{aligned}$$

## 6.4 Verteilungsfreie Klassifikatoren

---

Dies ist nur dann für beliebige  $\delta \vec{d}$  erfüllt, falls gilt:

$$\begin{aligned}\sum_{\vec{y}} (\vec{y} - \vec{d}) P(\vec{y} | \vec{c}) &= \vec{0} \Leftrightarrow \\ \sum_{\vec{y}} (\vec{y} \cdot P(\vec{y} | \vec{c})) - \sum_{\vec{y}} (\vec{d} \cdot P(\vec{y} | \vec{c})) &= \vec{0} \Leftrightarrow \\ \sum_{\vec{y}} (\vec{y} \cdot P(\vec{y} | \vec{c})) - \vec{d} \underbrace{\sum_{\vec{y}} P(\vec{y} | \vec{c})}_{=1} &= \vec{0} \Leftrightarrow \\ \sum_{\vec{y}} (\vec{y} \cdot P(\vec{y} | \vec{c})) &= \vec{d} \Rightarrow\end{aligned}$$

$$\begin{aligned}\vec{d}(\vec{c}) &= \begin{pmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{pmatrix} P(\omega_1 | \vec{c}) + \begin{pmatrix} 0 \\ 1 \\ \vdots \\ 0 \end{pmatrix} P(\omega_2 | \vec{c}) + \dots + \begin{pmatrix} 0 \\ \vdots \\ 0 \\ 1 \end{pmatrix} P(\omega_K | \vec{c}) \\ &= \begin{pmatrix} P(\omega_1 | \vec{c}) \\ P(\omega_2 | \vec{c}) \\ \vdots \\ P(\omega_K | \vec{c}) \end{pmatrix}\end{aligned}$$

Die Optimierung des Quadratmittelansatzes entspricht also der des Bayes-Klassifikators ohne Rückweisung!



### 6.5 Zusammenfassung

wir haben – nach den abstandsmessenden Klassifikatoren – zwei prinzipielle Wege zur Konstruktion eines Klassifikators kennengelernt:

#### 1. Minimieren des Risikos

hierzu benötigen wir die a posteriori Klassenwahrscheinlichkeit  $P(\omega|\vec{c})$   
wir können

(a)  $P(\vec{c}, \omega)$  oder äquivalent  $P(\vec{c}|\omega)$  und  $P(\omega)$  schätzen

(dies wird das Schätzen eines generativen Modells genannt, da es uns das sampeln, d.h. ziehen, von Mustern des MEP erlaubt;  
wir erhalten damit auch eine Schätzung der statistischen Eigenschaften des MEP)

(b)  $P(\omega|\vec{c})$  direkt schätzen

(diese werden auch diskriminative Modelle genannt)

#### 2. verteilungsfrei eine Diskriminatorfunktion bestimmen

### 6.6 Schätzung der klassenspezifischen Dichten

#### 6.6.1 Normalverteilung


Um die Verteilung einer Zufallsvariable  $X$  zu modellieren, geht man oft davon aus, daß sie *normalverteilt* ist, d.h.

$$P(X = x) = \mathcal{N}_x(\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

- $\mu = E\{X\}$  Erwartungswert von  $X$   
bestimmt das Zentrum der Normalverteilung
- $\sigma^2 = E\{(X - \mu)^2\}$  Varianz  
bestimmt Breite und Höhe der Kurve
- Ist die Näherung durch eine einfache Normalverteilung nicht geeignet, so lassen sich in den allermeisten Fällen durch einfache Überlagerung mehrerer Normalverteilungen gute Ergebnisse erzielen.

## 6.6 Schätzung der klassenspezifischen Dichten

---



Beispiel zweier Normalverteilungen im  $\mathbb{R}^1$

## 6.6 Schätzung der klassenspezifischen Dichten

---


Ist die Zufallsvariable ein  $M$ -dimensionaler Vektor  $\vec{X}$ , so gilt

$$P(\vec{X}) = \mathcal{N}_{\vec{X}}(\vec{\mu}, \underline{K}) = \frac{1}{\sqrt{(2\pi)^N \det \underline{K}}} e^{-\frac{1}{2}(\vec{X} - \vec{\mu})^T \underline{K}^{-1}(\vec{X} - \vec{\mu})}$$

- $\vec{\mu} = E\{\vec{X}\}$  Erwartungswert von  $\vec{X}$
- $\underline{K} = E\left\{(\vec{X} - \vec{\mu})(\vec{X} - \vec{\mu})^T\right\}$  die Kovarianzmatrix.
- Zentrum der Normalverteilung ist — wie im  $\mathbb{R}^1$  — durch den Erwartungswert  $\vec{\mu}$  gegeben
- im  $\mathbb{R}^2$  haben Normalverteilungen eine Glockenform  
horizontale Schnitte durch diese Glocke sind entweder kreis- oder ellipsenförmig
- $(\vec{X} - \vec{\mu})^T \underline{K}^{-1} (\vec{X} - \vec{\mu})$  heißt Mahalanobis-Distanz

## 6.6 Schätzung der klassenspezifischen Dichten

---



Beispiel einer zweidimensionalen Normalverteilung

### 6.6.2 Parameterschätzung

schätze Mittelwert  $\vec{\mu}$  und Kovarianzmatrix  $\underline{K}$  als Maximum-Likelihood-Schätzwert (ML-Schätzer) aus einer Stichprobe der Größe  $N$  (für **eine** Klasse):

Definition: der ML-Schätzer  $\hat{\theta}_{ML}$  für den Parameter  $\theta$  bezüglich einer Stichprobe  $\vec{c}_1, \dots, \vec{c}_N$  ist definiert als:

$$\hat{\theta}_{ML} = \operatorname{argmax}_{\theta} P(\vec{c}_1, \dots, \vec{c}_N | \theta)$$

Satz: die ML-Schätzer für eine Normalverteilung sind:

$$\hat{\vec{\mu}}_{ML} = \frac{1}{N} \sum_{n=1}^N \vec{c}_n$$

$$\hat{\underline{K}}_{ML} = \frac{1}{N} \sum_{n=1}^N (\vec{c}_n - \hat{\vec{\mu}})(\vec{c}_n - \hat{\vec{\mu}})^T$$

## 6.6 Schätzung der klassenspezifischen Dichten

---

Definition: ein Schätzer  $\hat{\theta}$  eines Parameters  $\theta$  heißt erwartungstreu, gdw:

$$E[\hat{\theta}] = \theta$$

Satz:  $\hat{\vec{\mu}}_{ML}$  ist erwartungstreu.

Satz:  $\frac{1}{N-1} \sum_{n=1}^N (\vec{c}_n - \hat{\vec{\mu}})(\vec{c}_n - \hat{\vec{\mu}})^T$  ist ein erwartungstreuer Schätzer der Kovarianzmatrix einer Normalverteilung

### Rekursive Berechnung

Es kommt häufig vor, daß die Menge der Trainingsmuster erweitert werden soll:

- neues klassifiziertes Trainingsmaterial vorhanden
- durchführen von entscheidungsüberwachtem Lernen

Da es für umfangreiche Stichproben sehr aufwendig ist, bei jeder Erweiterung die Parameter  $\hat{\mu}$  und  $\hat{K}$  vollständig neu zu berechnen, ist eine rekursive Formel für die Schätzwerte von großem Vorteil.



## 6.6 Schätzung der klassenspezifischen Dichten

---

Formel für die rekursive Berechnung des Erwartungswertes:

$$\begin{aligned}\widehat{\vec{\mu}}_N &= \frac{1}{N} \sum_{n=1}^N \vec{c}_n \\ &= \frac{1}{N} \left( \sum_{n=1}^{N-1} \vec{c}_n \right) + \frac{1}{N} \vec{c}_N \\ &= \frac{1(N-1)}{N(N-1)} \left( \sum_{n=1}^{N-1} \vec{c}_n \right) + \frac{1}{N} \vec{c}_N \\ &= \frac{N-1}{N} \cdot \left( \frac{1}{N-1} \sum_{n=1}^{N-1} \vec{c}_n \right) + \frac{1}{N} \vec{c}_N \\ &= \left( 1 - \frac{1}{N} \right) \cdot \widehat{\vec{\mu}}_{N-1} + \frac{1}{N} \vec{c}_N\end{aligned}$$

## 6.6 Schätzung der klassenspezifischen Dichten

---

Ähnlich läßt sich die Formel für die Kovarianzmatrix herleiten:

$$\underline{\hat{K}}_N = \left(1 - \frac{1}{N}\right) \left[\underline{\hat{K}}_{N-1} + \frac{1}{N} (\vec{c}_N - \hat{\vec{\mu}}_{N-1})(\vec{c}_N - \hat{\vec{\mu}}_{N-1})^T\right]$$

Sogar für die Inverse der Kovarianzmatrix gibt es eine inverse Formel:

$$\underline{\hat{K}}_N^{-1} = \frac{N}{N-1} \left[ \underline{\hat{K}}_{N-1}^{-1} - \frac{1}{N} \frac{\underline{\hat{K}}_{N-1}^{-1} (\vec{c}_N - \hat{\vec{\mu}}_{N-1})(\vec{c}_N - \hat{\vec{\mu}}_{N-1})^T \underline{\hat{K}}_{N-1}^{-1}}{1 + \frac{1}{N} (\vec{c}_N - \hat{\vec{\mu}}_{N-1})^T \underline{\hat{K}}_{N-1}^{-1} (\vec{c}_N - \hat{\vec{\mu}}_{N-1})} \right]$$

### 6.6.3 Bayes-Normalverteilungsklassifikator

**Annahme:**  $P(\vec{c} | \omega_i) = \mathcal{N}_{\vec{c}}(\vec{\mu}_i, \underline{K}_i)$

- schätze klassenspezifischen Mittelwerte  $\vec{\mu}_i$  und Kovarianzmatrizen  $\underline{K}_i$  aus klassifizierter Stichprobe  
für Schätzung von  $\vec{\mu}_i$  und  $\underline{K}_i$  verwende nur die Merkmalsvektoren  $\vec{c}_n$ , die aus der Klasse  $\omega_i$  stammen
- schätze a priori Wahrscheinlichkeiten als relative Häufigkeit jeder Klasse in der Stichprobe
- für die Diskriminatorfunktion des Bayes-Klassifikators benötigt man jedoch die Wahrscheinlichkeiten  $P(\omega_i | \vec{c})$   
gemäß dem Gesetz von Bayes und Randdichten gilt jedoch:

$$P(\omega_i | \vec{c}) = \frac{P(\vec{c} | \omega_i)P(\omega_i)}{P(\vec{c})} = \frac{P(\vec{c} | \omega_i)P(\omega_i)}{\sum_{l=1}^K P(\vec{c}, \omega_l)} = \frac{P(\vec{c} | \omega_i)P(\omega_i)}{\sum_{l=1}^K P(\vec{c} | \omega_l)P(\omega_l)}$$

## 6.6 Schätzung der klassenspezifischen Dichten

- verwendet man den Bayes-Klassifikator ohne Rückweisung, so reduziert sich der Rechenaufwand deutlich:

$P(\vec{c})$  kann als Konstante vernachlässigt werden, damit ergibt sich:

Die  $i$ -te Komponente  $d_i(\vec{c})$  der Diskriminatorfunktion  $\vec{d}(\vec{c})$  hat dann die Form

$$d_i(\vec{c}) = P(\vec{c} | \omega) \cdot P(\omega_i) = \frac{P(\omega_i)}{\sqrt{(2\pi)^N \det(\underline{K}_i)}} e^{-\frac{1}{2}(\vec{c} - \vec{\mu}_i)^T \underline{K}_i^{-1} (\vec{c} - \vec{\mu}_i)}$$

- die Rangordnung der Ergebnisse der Diskriminatorfunktion ändert sich nicht (bzw. dreht sich um), wenn
  - man sie mit positiven (negativen) Konstanten multipliziert
  - oder Konstanten addiert
  - oder logarithmiert

damit:

$$d'_i(\vec{c}) = \underbrace{-2 \ln(P(\omega_i)) + \ln(\det(\underline{K}_i))}_{\text{Konstante } b_{0i}} + \underbrace{(\vec{c} - \vec{\mu}_i)^T \underline{K}_i^{-1} (\vec{c} - \vec{\mu}_i)}_{\text{je Klass. zu berechnen}}$$

## 6.6 Schätzung der klassenspezifischen Dichten

- Bayesklassifikator für normalverteilte Klassen ist also ein *quadratischer* Klassifikator (Aufwand  $O(N^2)$  mit  $N = \dim(\vec{c})$ )
- mit der Diskriminatorfunktion

$$\vec{d}(\vec{c}) = \begin{pmatrix} b_{01} + (\vec{c} - \vec{\mu}_1)^T \underline{K}_1^{-1} (\vec{c} - \vec{\mu}_1) \\ \vdots \\ b_{0i} + (\vec{c} - \vec{\mu}_i)^T \underline{K}_i^{-1} (\vec{c} - \vec{\mu}_i) \\ \vdots \\ b_{0K} + (\vec{c} - \vec{\mu}_K)^T \underline{K}_K^{-1} (\vec{c} - \vec{\mu}_K) \end{pmatrix}$$

wird das Risiko mit folgender Entscheidungsregel minimiert:

$$g(\vec{c}) = \hat{\omega} = e(\vec{d}(\vec{c})) = \omega_l, \quad \text{falls } l \text{ minimale Komponente von } \vec{d}(\vec{c})$$

- Berechtigung der Annahme normalverteilter Klassen:
  - statistische Tests
  - Annahme anhand des Klassifikationsergebnisses auf einer Teststichprobe evaluieren  
(diese liefert aber in keinem Fall eine Aussage über die Korrektheit der Normalverteilungs-Annahme)

### 6.6.4 Vereinfachung durch identische Kovarianzmatrizen

**Annahme:** die Kovarianzmatrizen aller Klassen sind  $\omega_i$  identisch

(diese gemeinsame Kovarianzmatrix wird aus der gesamten Stichprobe geschätzt)

- dann vereinfacht sich  $d'_i(\vec{c})$  weiter, da  $\ln(\det(\underline{K}))$  nun konstant:

$$\begin{aligned}d'_i(\vec{c}) &= -2 \ln(P(\omega_i)) + (\vec{c} - \vec{\mu}_i)^T \underline{K}^{-1} (\vec{c} - \vec{\mu}_i) \\ &= -2 \ln(P(\omega_i)) + \vec{c}^T \underline{K}^{-1} \vec{c} - 2 \vec{\mu}_i^T \underline{K}^{-1} \vec{c} + \vec{\mu}_i^T \underline{K}^{-1} \vec{\mu}_i\end{aligned}$$

- Der Term  $\vec{c}^T \underline{K}^{-1} \vec{c}$  kann ebenfalls vernachlässigt werden:

$$d'_i(\vec{c}) = \underbrace{-2 \ln(P(\omega_i)) + \vec{\mu}_i^T \underline{K}^{-1} \vec{\mu}_i}_{b_{1i}} - \underbrace{2 \vec{\mu}_i^T \underline{K}^{-1} \vec{c}}_{b_{2i}}$$

- mit der Diskriminatorfunktion

$$\vec{d}''(\vec{c}) = \begin{pmatrix} b_{11} - b_{21}\vec{c} \\ \vdots \\ b_{1i} - b_{2i}\vec{c} \\ \vdots \\ b_{1K} - b_{2K}\vec{c} \end{pmatrix}$$

so wird das Risiko minimiert, falls man folgende Entscheidungsregel anwendet:

$$g(\vec{c}) = \hat{\omega} = e(\vec{d}''(\vec{c})) = \omega_l, \quad \text{falls } l \text{ minimale Komponente von } \vec{d}(\vec{c})$$

- Bayesklassifikator für normalverteilte Klassen mit identischer Kovarianzmatrix ist also ein *linearer* Klassifikator (Aufwand  $O(N)$  mit  $N = \dim(\vec{c})$ )  
 $\Rightarrow$  oft deutliche Rechenzeiterparnis, da Merkmalsvektoren mit 10 bis 100 Dimensionen nicht selten

### 6.6.5 Klassengrenzen

- ein Merkmalsvektor  $\vec{c}$  liegt auf einer Klassengrenze, falls mehrere Komponenten der Diskriminatorfunktion  $\vec{d}(\vec{c})$  den gleichen (maximalen bzw. minimalen) Wert annehmen:

$$\begin{aligned}d_{\kappa}(\vec{c}) &= d_{\lambda}(\vec{c}) \Leftrightarrow \\d_{\kappa}(\vec{c}) - d_{\lambda}(\vec{c}) &= 0\end{aligned}$$

- Einsetzen für Bayesklassifikators mit Normalverteilungen ergibt:

$$d_{\kappa}(\vec{c}) - d_{\lambda}(\vec{c}) = b_{0\kappa} + (\vec{c} - \vec{\mu}_{\kappa})^T \underline{K}_{\kappa}^{-1}(\vec{c} - \vec{\mu}_{\kappa}) - b_{0\lambda} - (\vec{c} - \vec{\mu}_{\lambda})^T \underline{K}_{\lambda}^{-1}(\vec{c} - \vec{\mu}_{\lambda}) = 0$$

- läßt sich durch geeignete Transformationen zu einem einzigen quadratischen Ausdruck umformen  
 $\Rightarrow$  alle Klassengrenzen sind Ellipsen (Ellipsoide), Parabel (Paraboloide) oder Hyperbeln (Hyperboloide)



## 6.6 Schätzung der klassenspezifischen Dichten

---

- Bayesklassifikator für Normalverteilungen mit identischen Kovarianzmatrizen:

$$d_{\kappa}(\vec{c}) - d_{\lambda}(\vec{c}) = b_{1\kappa} - \vec{b}_{2\kappa}^T \vec{c} - b_{1\lambda} + \vec{b}_{2\lambda}^T \vec{c}$$

diese Gleichung ist linear

⇒ Klassengrenzen sind durch Geraden, Flächen oder Hyperflächen gegeben

### 6.6.6 Mischverteilungen

- Verteilung wird durch Linearkombination von verschiedenen (Normal)verteilungen beschrieben:

$$P(\vec{c} \mid \omega_i) = \sum_{l=1}^L a_l \cdot \mathcal{N}_{\vec{c}}(\vec{\mu}_l, \underline{K}_l) \quad \text{mit} \quad \sum_{l=1}^L a_l = 1 \quad \text{und} \quad a_l \geq 0$$

wobei  $\vec{\theta} = (a_1, \vec{\mu}_1, \underline{K}_1, \dots, a_L, \vec{\mu}_L, \underline{K}_L)$

die Mischverteilung (hier der Klasse  $\omega_i$ ) beschreibt

- Schätzen im Prinzip wie k-means, wobei nun jedes Gebiet  $R_l$  bzw. jede l-te Normalverteilung (nicht **Klasse**)
  - nicht mehr alleine durch  $\vec{\mu}_l$ , sondern
  - durch Parameter  $\vec{\mu}_l$  und  $\underline{K}_l$  einer hochdimensionalen Normalverteilung  $\mathcal{N}_{\vec{c}}(\vec{\mu}_l, \underline{K}_l)$  bestimmt ist,
  - $P(\vec{c} \mid R_l) = \mathcal{N}_{\vec{c}}(\vec{\mu}_l, \underline{K}_l)$
  - $P(R_l) = a_l$

### Harte Vektorquantisierung (k-means, classifying EM)

- ordne innerhalb jeder Iteration jeden Merkmalsvektor  $\vec{c}_n$  einem Gebiet **hart** zu
- Verfahren zur Optimierung von  $L$  Gebieten

## 6.6 Schätzung der klassenspezifischen Dichten

wähle aufgrund von Vorwissen oder zufällig initiale Parameter $a_l = P(R_l), \vec{\mu}_l, \underline{K}_l$ ; (z.B. $P(R_l) = 1/L, \vec{\mu}_l = l$ -ter Vektor der Stichprobe, $\underline{K}_l = \mathcal{I}$ )
$H^0 := -\infty$ (Wert der Likelihood-Funktion in der Iteration 0)
$t := 0$ (Iterationszähler)
$t := t + 1, \quad H^{(t)} := 0$
FOR alle Gebiete $R_l, l = 1, \dots, L$
$N_l := 0; \quad \hat{\vec{\mu}}_l := \vec{0}, \quad \hat{\underline{M}}_l := O$
FOR alle Vektoren $\vec{c}_n$ der Stichprobe
bestimme $R_l$ mit maximalem $P(R_l   \vec{c}_n)$
$H^{(t)} := H^{(t)} + \ln(P(R_l) P(\vec{c}   R_l))$
berechne neue Schätzwerte für den Mittelwert und die Momentenmatrix, d.h.
$\hat{\vec{\mu}}_l := \hat{\vec{\mu}}_l + \vec{c}_n \quad \hat{\underline{M}}_l := \hat{\underline{M}}_l + \vec{c}_n \vec{c}_n^T$
$N_l := N_l + 1$
$H^{(t)} := H^{(t)} / N$
FOR alle Gebiete $R_l, l = 1, \dots, L$
$P(R_l) = \frac{N_l}{N}, \quad \vec{\mu}_l := \hat{\vec{\mu}}_l / N_l; \quad \underline{K}_l := \hat{\underline{M}}_l / N_l - \vec{\mu}_l \vec{\mu}_l^T$
UNTIL $(H^{(t)} - H^{(t-1)}) /  H^{(t)}  \leq \varepsilon$

### Weiche Vektorquantisierung, EM-Algorithmus

- ordne jeden Merkmalsvektor  $\vec{c}_n$  mit dem Gewicht seiner a-posteriori-Wahrscheinlichkeit  $P(R_l | \vec{c}_n)$  **allen** Gebieten  $R_l$  **weich** zu

(beachte:  $\sum_{l=1}^L P(R_l | \vec{c}_n) = 1$ )

- Ziel: Maximierung (der logarithmierten) Wahrscheinlichkeit  $H$  der Produktion der Stichprobe in Abhängigkeit der Mischverteilung (normiert bzgl. der Stichprobengröße  $N$ ):

$$H = \frac{1}{N} \ln P(\{\vec{c}_1, \dots, \vec{c}_N\} | \vec{\theta}) = \frac{1}{N} \ln \prod_{n=1}^N P(\vec{c}_n | \vec{\theta}) = \frac{1}{N} \sum_{n=1}^N \ln P(\vec{c}_n | \vec{\theta}) =$$
$$\frac{1}{N} \sum_{n=1}^N \ln \sum_{l=1}^L P(R_l) p(\vec{c}_n | R_l)$$

## 6.6 Schätzung der klassenspezifischen Dichten

---

- zur Berechnung von  $P(R_l | \vec{c}_n)$  folgende Umformungen (Bayes-Gesetzes):

$$\begin{aligned}P(R_l | \vec{c}_n) &= \frac{P(R_l)P(\vec{c}_n | R_l)}{P(\vec{c}_n)} \\P(\vec{c}_n) &= \sum_{k=1}^L P(\vec{c}_n, R_k) \\&= \sum_{k=1}^L P(R_k)P(\vec{c}_n | R_k) \\ \Rightarrow P(R_l | \vec{c}_n) &= \frac{P(R_l)P(\vec{c}_n | R_l)}{\sum_{k=1}^L P(R_k)P(\vec{c}_n | R_k)}\end{aligned}$$

- Verfahren zur Optimierung von  $L$  Gebieten

## 6.6 Schätzung der klassenspezifischen Dichten

wähle aufgrund von Vorwissen oder zufällig initiale Parameter $P(R_l), \vec{\mu}_l, \underline{K}_l$ (z.B. $P(R_l) = 1/L, \vec{\mu}_l = l$ -ter Vektor der Stichprobe, $\underline{K}_l = \mathcal{I}$ )
$H^0 := -\infty$ (Wert der Likelihood-Funktion in der Iteration 0)
$t := 0$ (Iterationszähler)
$t := t + 1, \quad H^{(t)} := 0$
FOR alle Gebiete $R_l, l = 1, \dots, L$
$N_l := 0; \quad \hat{\vec{\mu}}_l := \vec{0}, \quad \hat{\underline{M}}_l := O$
FOR alle Vektoren $\vec{c}_n$ der Stichprobe
berechne $P(R_l   \vec{c}_n)$ mittels $P(\vec{c}   R_l) = \mathcal{N}_{\vec{c}}(\vec{\mu}_l, \underline{K}_l)$ und $P(R_l)$ für alle Gebiete $R_l$
$H^{(t)} := H^{(t)} + \ln\left(\sum_{l=1}^L P(R_l) P(\vec{c}   R_l)\right)$
FOR alle Gebiete $R_l, l = 1, \dots, L$
berechne neue Schätzwerte für den Mittelwert und die Momentenmatrix, d.h.
$\hat{\vec{\mu}}_l := \hat{\vec{\mu}}_l + \vec{c}_n \cdot P(R_l   \vec{c}_n) \quad \hat{\underline{M}}_l := \hat{\underline{M}}_l + \vec{c}_n \vec{c}_n^T \cdot P(R_l   \vec{c}_n)$
$N_l := N_l + P(R_l   \vec{c}_n)$
$H^{(t)} := H^{(t)} / N$
FOR alle Gebiete $R_l, l = 1, \dots, L$
$P(R_l) = \frac{N_l}{N}, \quad \vec{\mu}_l := \hat{\vec{\mu}}_l / N_l; \quad \underline{K}_l := \hat{\underline{M}}_l / N_l - \vec{\mu}_l \vec{\mu}_l^T$
UNTIL $(H^{(t)} - H^{(t-1)}) /  H^{(t)}  \leq \varepsilon$

### Klassenabhängige Dichten

- zerlege **klassifizierte** Stichprobe in  $K$  Stichproben  $S_k$ ,  $k = 1, \dots, K$ , die jeweils nur Vektoren aus der Klasse  $\omega_k$  enthalten
- wende gesondert auf jede dieser Stichproben die Vector Quantization an. Man erhält  $L_k$  Dichten mit den Parametern  $\mathcal{N}(\vec{\mu}_l^k, \underline{K}_l^k)$
- bestimme aus der klassifizierten Stichprobe die Gewichte wie folgt:

$$a_l^k = \frac{1}{N^k} \sum_{\vec{c}_n \in \omega_k \wedge \vec{c}_n \in R_l^k} 1 \quad (\text{harte VQ})$$

$$a_l^k = \frac{1}{N^k} \sum_{\vec{c}_n \in \omega_k} P(R_l^k \mid \vec{c}_n) \quad (\text{weiche VQ})$$

- die Komponenten der Diskriminatorfunktion ergeben sich nun zu:

$$P(\vec{c} \mid \omega_k) = \sum_{l=1}^{L_k} a_l^k \cdot \mathcal{N}(\vec{\mu}_l^k, \underline{K}_l^k)$$



### Klassenunabhängige Dichten

- schätze auf einer **unklassifizierten** Stichprobe (weiche oder harte VQ)  
⇒  $L$  Normalverteilungen  $\mathcal{N}(\vec{\mu}_l, \underline{K}_l)$
- bestimme die Gewichtsparemeter der obigen Dichten für die Klasse  $\omega_k$  aus einer (evtl. kleineren) **klassifizierten** Stichprobe wie folgt:

$$a_l^k = \frac{1}{N^k} \sum_{\vec{c}_n \in \omega_k \wedge \vec{c}_n \in R_l} 1 \quad (\text{harte VQ})$$

$$a_l^k = \frac{1}{N^k} \sum_{\vec{c}_n \in \omega_k} P(R_l \mid \vec{c}_n) \quad (\text{weiche VQ})$$

•

$$P(\vec{c} \mid \omega_k) = \sum_{l=1}^L a_l^k \mathcal{N}(\vec{\mu}_l, \underline{K}_l)$$

- dieses Vorgehen ist u.U. günstiger, das sich mehrere Klassen eine Normalverteilung “teilen” können

### 6.6.7 Andere Verteilungen

#### Statistische Unabhängigkeit

- **Annahme** statistischer Unabhängigkeit der Merkmale  
(die allerdings in der Regel nicht, höchstens approximativ gegeben ist)

- 

$$P(\vec{c} \mid \omega_i) = \prod_{m=1}^M P(c_m \mid \omega_i)$$

- die  $P(c_m \mid \omega_i)$  können
  - mit eindimensionalen parametrischen Dichte geschätzt werden  
(größere Auswahl als im höherdimensionalen Fall)
  - nach Diskretisierung der Werte  $c_m$ :  
durch Histogramm als relative Häufigkeiten tabelliert werden

### Parzenschätzung $\sim$ radiale Basisfunktionen

- **Motivation:** für höhere Dimensionen ist Diskretisierung des Merkmalsraums schwierig (curse of dimensionality): “fast alle” Zellen bleiben leer
- $\Rightarrow$  “verschmiere” jeden Beitrag der Stichprobe um seine Position
- Approximation der Dichte durch Überlagerung von Normalverteilungen, (oder auch andere Fensterfunktionen, z.B. Rechteck)

$$P(\vec{c} \mid \omega_k) = \frac{1}{N} \sum_{n=1}^N \mathcal{N}(\vec{c}_n, K)$$

wobei  $K = \sigma^2 \mathcal{I}$ , und  $\sigma$  die Breite des Fensters (des “Verschmierens”) bestimmt

### 6.7 Alternative Klassifikationsergebnisse

bis jetzt: genau **eine** Klasse oder Rückweisung

Erweiterung      weniger endgültige Entscheidung des Klassifikators,  
um nachfolgenden Prozesss die Entscheidung zu überlassen  
(wobei dieser weitere Evidenzen eingehen lassen kann)  
⇒ *principle of least commitment*

Idee

- ordne die Klassen  $\omega_i$  gemäß abfallendem  $P(\omega_i | \vec{c})$
- wähle **Konfidenzschwelle**  $\theta \in [\frac{1}{K}; 1]$
- Ergebniss der Klassifikation sind die ersten Klassen, sodass bei minimaler Anzahl an Klassen gilt:

$$\sum_i P(\omega_i | \vec{c}) \geq \theta$$

## 6.7 Alternative Klassifikationsergebnisse

---

Bemerkungen durch die Wahl von  $\theta$  kann die Anzahl an Alternativen gewählt werden:

- $\theta = \frac{1}{K}$ : nur beste Klasse, wie bisher
- $\theta = 1$ : alle Klassen