

# 7 Polynomklassifikator

Ziel: Optimierung der Unterscheidungsfunktion  $\vec{d}(\vec{c}_k)$  bezüglich der Zielvektoren  $\vec{y}_k$  mit dem Quadratmittelansatz

$$S^2 = E\{(\vec{y} - \vec{d}(\vec{c}))^2\} \rightarrow \min$$

ohne direkte Schätzung von Dichten

- in Abschnitt 6.4 beliebige Funktionen für die Optimierung  
→  $\vec{d}(\vec{c}) = (P(\omega_1 | \vec{c}), \dots)$
- jetzt Beschränkung auf eine Funktionenklasse  
→ Problem der Parameterschätzung
- wünschenswert sind Funktionenklassen, die jede beliebige Funktion annähern können → universeller Approximator

### 7.1 Der Ansatz

Polynome sind ein universeller Approximator wegen des Satzes von Weierstraß:  
Jede stetige Funktion kann beliebig genau durch Polynome approximiert werden, sofern der Polynomgrad groß genug gewählt wird.

Modellierung der Komponenten der Unterscheidungsfunktion  $d_k(\vec{c})$  wie folgt:

$$\begin{aligned}d_k(\vec{c}) &= a_{k0} + a_{k1}c_1 + a_{k2}c_2 + \dots + a_{kM}c_M + \\ &\quad a_{k,(M+1)}c_1^2 + a_{k,(M+2)}c_1c_2 + a_{k,(M+3)}c_1c_3 + \dots + \\ &\quad a_{k,(M+M(M+1)/2+1)}c_1^3 + a_{k,(M+M(M+1)/2+2)}c_1^2c_2 + a_{k,(M+M(M+1)/2+3)}c_1^2c_3 + \dots \\ &= \vec{a}_k^T \vec{x}(\vec{c})\end{aligned}$$

$$\text{mit } \vec{x}(\vec{c}) = (1, c_1, \dots, c_M, c_1^2, c_1c_2, \dots, c_M^2, c_1^3, \dots)^T$$

$$\text{und } \dim(\vec{c}) = M$$

- Unterscheidungsfunktion wird über Polynome in den Komponenten des Merkmalsvektors approximiert
- zu optimierende Parameter:  $\vec{a}_k$

## 7.1 Der Ansatz

---

für die Unterscheidungsfunktion  $\vec{d}(\vec{c})$  gilt damit:

$$\vec{d}(\vec{c}) = \begin{pmatrix} d_1(\vec{c}) \\ \vdots \\ d_K(\vec{c}) \end{pmatrix} = \begin{pmatrix} \vec{a}_1^T \vec{x}(\vec{c}) \\ \vdots \\ \vec{a}_K^T \vec{x}(\vec{c}) \end{pmatrix} = \underline{A}^T \vec{x}(\vec{c})$$

mit  $\underline{A} = (\vec{a}_1, \dots, \vec{a}_K)$

Vor dem Training eines Polynomklassifikators ist festzulegen:

- Polynomgrad  $G$
- Polynomstruktur: z.B. welche quadratischen Terme  $c_i c_k$  verwendet werden

## 7.1 Der Ansatz

---

meist vollständige Polynome bis zum Grad  $G$

**Beachte:** Grad nicht zu groß, da sich bei  $M$ -dimensionalem Merkmalsvektor folgende Dimension für  $\vec{x}(\vec{c})$  ergibt:

$$M = \binom{M + G}{G} = \dim(\vec{x}(\vec{c}))$$

z.B.			$K = 30$
$M = 10$	$G = 2$	$P = 66$	1980
$M = 30$	$G = 2$	$P = 496$	14880
$M = 30$	$G = 3$	$P = 1891$	56730
$M = 60$	$G = 3$	$P = 39711$	1191330

**Bemerkung:** im Prinzip kann man für die  $x_i(\vec{c})$  nicht nur Monome über den  $c_k$  zulassen, sondern beliebige Funktionen verwenden  
→ Unterscheidungsfunktion ist Linearkombination von beliebigen Funktionen  
→ für die Optimierung von  $\underline{A}$  spielt dies keine Rolle.

### 7.2 Lösung des Minimierungsproblems

nun mit Hilfe der Variationsrechnung die optimale Koeffizientenmatrix bestimmen:

Optimierungskriterium :

$$S^2 = E \left\{ \left| \vec{y} - \vec{d}(\vec{c}) \right|^2 \right\} = E \left\{ \left| \vec{y} - \underline{A}^T \vec{x}(\vec{c}) \right|^2 \right\} = S^2(\underline{A}) \rightarrow \min_{\underline{A}}$$

(im weiteren statt  $\vec{x}(\vec{c})$  nur noch  $\vec{x}$  )

sei  $\underline{A}$  die optimale Matrix,

dann verschlechtert jede Abweichung  $\delta \underline{A} \neq 0$  das Optimierungskriterium:

$$\forall \delta \underline{A} \neq 0 : \quad S^2(\underline{A} + \delta \underline{A}) \geq S^2(\underline{A}) \quad (7.1)$$

#### Einschub

- für Vektoren gleicher Dimension gilt:  $\vec{a}^T \vec{b} = \text{spur} \left( \vec{a} \vec{b}^T \right)$
- für quadratische Matrizen gleicher Dimension gilt:  $\text{spur}(\underline{A} \underline{B}^T) = \text{spur}(\underline{B} \underline{A}^T)$

## 7.2 Lösung des Minimierungsproblems

---

Somit ergibt sich für die rechte Seite der vorangehenden Ungleichung:

$$\begin{aligned} S^2(\underline{A}) &= E \left\{ |\vec{y} - \underline{A}^T \vec{x}|^2 \right\} \\ &= E \left\{ [\vec{y} - \underline{A}^T \vec{x}]^T [\vec{y} - \underline{A}^T \vec{x}] \right\} \\ &= E \left\{ \text{spur} \left[ [\vec{y} - \underline{A}^T \vec{x}] [\vec{y} - \underline{A}^T \vec{x}]^T \right] \right\} \\ &= \text{spur} [E \{ \vec{y} \vec{y}^T \}] - \text{spur} [E \{ \vec{y} \vec{x}^T \} \underline{A}] - \text{spur} [\underline{A}^T E \{ \vec{x} \vec{y}^T \}] + \text{spur} [A^T E \{ \vec{x} \vec{x}^T \} \underline{A}] \\ &= \text{spur} [E \{ \vec{y} \vec{y}^T \}] - 2 \cdot \text{spur} [\underline{A}^T E \{ \vec{x} \vec{y}^T \}] + \text{spur} [A^T E \{ \vec{x} \vec{x}^T \} \underline{A}] \end{aligned}$$

analoge Rechnung für die linke Seite:

$$\begin{aligned} S^2(\underline{A} + \delta \underline{A}) &= \text{spur} [E \{ \vec{y} \vec{y}^T \}] - 2 \cdot \text{spur} [\underline{A}^T E \{ \vec{x} \vec{y}^T \}] + \text{spur} [\underline{A}^T E \{ \vec{x} \vec{x}^T \} \underline{A}] \\ &\quad + 2 \cdot \text{spur} [\delta \underline{A}^T (E \{ \vec{x} \vec{y}^T \} - E \{ \vec{x} \vec{x}^T \} \underline{A})] \\ &\quad + \text{spur} [\delta \underline{A}^T E \{ \vec{x} \vec{x}^T \} \delta \underline{A}] \end{aligned}$$

## 7.2 Lösung des Minimierungsproblems

---

Einsetzen in die Ungleichung (7.1) ergibt:

$$S^2(\underline{A} + \delta \underline{A}) \geq S^2(\underline{A}) \Leftrightarrow \\ \text{spur} [\delta \underline{A}^T E \{ \vec{x} \vec{x}^T \} \delta \underline{A}] - 2 \cdot \text{spur} [\delta \underline{A}^T (E \{ \vec{x} \vec{y}^T \} - E \{ \vec{x} \vec{x}^T \} \underline{A})] \geq 0$$

- $\text{spur} [\delta \underline{A}^T E \{ \vec{x} \vec{x}^T \} \delta \underline{A}] \geq 0$ ,  
da  $E \{ \vec{x} \vec{x}^T \}$  als Korrelationsmatrix positiv semi-definit
- obige Ungleichung ist dann notwendigerweise für beliebige  $\delta \underline{A}$  erfüllt, falls  
 $\text{spur} [\delta \underline{A}^T (E \{ \vec{x} \vec{y}^T \} - E \{ \vec{x} \vec{x}^T \} \underline{A})] = 0$ ,
- also wird  $\underline{A}$  optimal, wenn gilt

$$E \{ \vec{x} \vec{y}^T \} - E \{ \vec{x} \vec{x}^T \} \underline{A} = \mathbb{O} \Leftrightarrow \\ \underline{A} = (E \{ \vec{x} \vec{x}^T \})^{-1} E \{ \vec{x} \vec{y}^T \}$$

### 7.3 Berechnung der Koeffizientenmatrix

Es stellen sich zwei Probleme:

- Wie berechnet man die Erwartungswerte  $E \{ \vec{x} \vec{x}^T \}$  und  $E \{ \vec{x} \vec{y}^T \}$ ?
- Was macht man, falls die Inverse von  $E \{ \vec{x} \vec{x}^T \}$  nicht existiert, d.h. es existieren linear abhängige Zeilen (Komponenten von  $\vec{x}$  sind linear abhängig)

**Lösung Problem 1:** Erwartungswert und Kovarianzmatrix haben wir schon geschätzt

analog hier aus der Stichprobe mit  $N$  klassifizierten Paaren  $(\vec{c}_n, \vec{y}_n)$ :

$$\hat{E} \{ \vec{x} \vec{x}^T \} = \frac{1}{N} \sum_{n=1}^N \vec{x}(\vec{c}_n) \vec{x}(\vec{c}_n)^T$$
$$\hat{E} \{ \vec{x} \vec{y}^T \} = \frac{1}{N} \sum_{n=1}^N \vec{x}(\vec{c}_n) \vec{y}_n^T$$



### Lösung Problem 2:

sei  $\vec{z}^T = (\vec{x}^T, \vec{y}^T)$

$$\text{und } \underline{M}_{\vec{z}} = E \{ \vec{z} \vec{z}^T \} = E \left\{ \begin{pmatrix} \vec{x} \\ \vec{y} \end{pmatrix} (\vec{x}^T \ \vec{y}^T) \right\} = \begin{pmatrix} E \{ \vec{x} \vec{x}^T \} & E \{ \vec{x} \vec{y}^T \} \\ E \{ \vec{y} \vec{x}^T \} & E \{ \vec{y} \vec{y}^T \} \end{pmatrix}$$

dabei ist

- $E \{ \vec{x} \vec{x}^T \}$  eine  $M \times M$  Matrix
- $E \{ \vec{x} \vec{y}^T \}$  eine  $M \times K$  Matrix
- $E \{ \vec{y} \vec{x}^T \}$  eine  $K \times M$  Matrix
- $E \{ \vec{y} \vec{y}^T \}$  eine  $K \times K$  Matrix
- mit  $M = \dim(\vec{x})$  und  $K = \dim(\vec{y})$

## 7.3 Berechnung der Koeffizientenmatrix

---

unter der Annahme, daß die Inverse von  $E \{ \vec{x}\vec{x}^T \}$  existiert, definieren wir folgende Matrix:

$$\underline{T} = \begin{pmatrix} [E \{ \vec{x}\vec{x}^T \}]^{-1} & \mathbb{O} \\ -E \{ \vec{y}\vec{x}^T \} [E \{ \vec{x}\vec{x}^T \}]^{-1} & \mathbb{I} \end{pmatrix}$$

dabei ist

- $[E \{ \vec{x}\vec{x}^T \}]^{-1}$  eine  $M \times M$ , Matrix
- $E \{ \vec{y}\vec{x}^T \} [E \{ \vec{x}\vec{x}^T \}]^{-1}$  eine  $[K \times M] \cdot [M \times M] = K \times M$  Matrix
- $\mathbb{O}$  ist eine  $M \times K$  große Nullmatrix
- $\mathbb{I}$  eine  $K \times K$  große Identitätsmatrix.

## 7.3 Berechnung der Koeffizientenmatrix

---

es gilt

$$\begin{aligned}\underline{T} \cdot \underline{M}_{\vec{z}} &= \begin{pmatrix} [E \{ \vec{x} \vec{x}^T \}]^{-1} & \mathbb{O} \\ -E \{ \vec{y} \vec{x}^T \} [E \{ \vec{x} \vec{x}^T \}]^{-1} & \mathbb{I} \end{pmatrix} \cdot \begin{pmatrix} E \{ \vec{x} \vec{x}^T \} & E \{ \vec{x} \vec{y}^T \} \\ E \{ \vec{y} \vec{x}^T \} & E \{ \vec{y} \vec{y}^T \} \end{pmatrix} \\ &= \begin{pmatrix} \mathbb{I} & [E \{ \vec{x} \vec{x}^T \}]^{-1} E \{ \vec{x} \vec{y}^T \} \\ \mathbb{O} & -E \{ \vec{y} \vec{x}^T \} [E \{ \vec{x} \vec{x}^T \}]^{-1} E \{ \vec{x} \vec{y}^T \} + E \{ \vec{y} \vec{y}^T \} \end{pmatrix} \\ &= \begin{pmatrix} \mathbb{I} & \underline{A} \\ \mathbb{O} & E \{ \Delta \vec{d} \Delta \vec{d}^T \} \end{pmatrix}\end{aligned}$$

mit  $\Delta \vec{d} := \vec{y} - \underline{A}^T \vec{x}$ :

## 7.3 Berechnung der Koeffizientenmatrix

da mit  $\Delta \vec{d} := \vec{y} - \underline{A}^T \vec{x}$  gilt:

$$\begin{aligned} E \left\{ \Delta \vec{d} \Delta \vec{d}^T \right\} &= E \left\{ (\vec{y} - \underline{A}^T \vec{x}) (\vec{y} - \underline{A}^T \vec{x})^T \right\} \\ &= E \left\{ \vec{y} \vec{y}^T \right\} - E \left\{ \vec{y} \vec{x}^T \right\} \underline{A} - \underline{A}^T E \left\{ \vec{x} \vec{y}^T \right\} + \underbrace{\underline{A}^T E \left\{ \vec{x} \vec{x}^T \right\} \underline{A}}_{E \left\{ \vec{x} \vec{y}^T \right\}} \\ &= E \left\{ \vec{y} \vec{y}^T \right\} - E \left\{ \vec{y} \vec{x}^T \right\} \underline{A} - \underline{A}^T E \left\{ \vec{x} \vec{y}^T \right\} + \underline{A}^T E \left\{ \vec{x} \vec{y}^T \right\} \\ &= E \left\{ \vec{y} \vec{y}^T \right\} - E \left\{ \vec{y} \vec{x}^T \right\} \left[ E \left\{ \vec{x} \vec{x}^T \right\} \right]^{-1} E \left\{ \vec{x} \vec{y}^T \right\} \end{aligned}$$

$$\text{(beachte: } \underline{A} = (E \left\{ \vec{x} \vec{x}^T \right\})^{-1} E \left\{ \vec{x} \vec{y}^T \right\} \text{ )}$$

zusätzlich gilt (siehe Einschub:)

$$S^2(\underline{A}) = E \left\{ \Delta \vec{d}^T \Delta \vec{d} \right\} = \text{spur}(E \left\{ \Delta \vec{d} \Delta \vec{d}^T \right\})$$

## 7.3 Berechnung der Koeffizientenmatrix


- scheinbar nichts gewonnen, da für  $\underline{T}$  immer noch die inverse von  $E \{ \vec{x}\vec{x}^T \}$  erforderlich:

$$\begin{pmatrix} [E \{ \vec{x}\vec{x}^T \}]^{-1} & \mathbb{O} \\ -E \{ \vec{y}\vec{x}^T \} [E \{ \vec{x}\vec{x}^T \}]^{-1} & \mathbb{I} \end{pmatrix} \begin{pmatrix} E \{ \vec{x}\vec{x}^T \} & E \{ \vec{x}\vec{y}^T \} \\ E \{ \vec{y}\vec{x}^T \} & E \{ \vec{y}\vec{y}^T \} \end{pmatrix} = \begin{pmatrix} \mathbb{I} & \underline{A} \\ \mathbb{O} & E \{ \Delta \vec{d} \Delta \vec{d}^T \} \end{pmatrix}$$

- Linksmultiplikationen von Matrizen entsprechen jedoch elementaren Zeilenumformungen.
- damit reicht es aus, die Matrix  $\underline{M}_{\vec{z}}$  z.B. mit Hilfe des *Gauß-Jordan-Algorithmus* soweit umzuformen,
  - daß die obere linke Teilmatrix  $E \{ \vec{x}\vec{x}^T \}$  zu einer Identitätsmatrix wird
  - die untere linke Teilmatrix  $E \{ \vec{y}\vec{x}^T \}$  zu einer Nullmatrix wird
  - die obere rechte Teilmatrix ist dann  $\underline{A}$
- bei dieser Umformung kann man auch elegant das Problem der linearen Abhängigkeiten der Merkmalskomponenten umgehen (siehe nächsten Abschnitt).

### 7.4 Merkmalsauswahl

- gibt es lineare Abhängigkeiten, kann  $E \{ \vec{x} \vec{x}^T \}$  nicht invertiert werden  
 → Auswahl einer Teilmenge von linear unabhängigen Merkmalen
- hierzu betrachten wir folgende (Zwischen)Situation



$$\vec{x} = \begin{pmatrix} \tilde{x} \\ \vec{u} \end{pmatrix}$$

wobei die Merkmale in  $\tilde{x}$  bereits ausgewählt wurden

## 7.4 Merkmalsauswahl

- wir tun so als wollten wir aus  $\tilde{x}$  jetzt  $\vec{u}\vec{y}$  schätzen  
für die Komponenten aus  $\tilde{x}$  sei die Matrix  $\underline{M}_{\tilde{z}}$  schon richtig umgeformt worden:

$$\underline{M}_{\tilde{z}} \rightsquigarrow \begin{pmatrix} \mathbb{I} & \tilde{A} \\ \mathbb{O} & E \left\{ \Delta \tilde{d} \Delta \tilde{d}^T \right\} \end{pmatrix}$$

- auf der Diagonalen von  $E \left\{ \Delta \tilde{d} \Delta \tilde{d}^T \right\}$  stehen genau die  $\text{Var}\{\Delta u_i\}$ ,  
wobei  $\Delta u_i = \tilde{a}_i^T \tilde{x} - u_i$ , also der mittlere Fehler beim Schätzen von  $u_i$  aus  $\tilde{x}$   
(und ebenso – weiter rechts unten – die  $\text{Var}\{\Delta y_i\}$ )
- es gilt:  $\text{Var}\{\Delta u_i\} = 0 \Leftrightarrow u_i$  und  $\tilde{x}$  sind linear abhängig  
(d.h. die Schätzung ist perfekt)  
 $\Rightarrow$  eliminiere  $u_i$ , falls  $\text{Var}\{\Delta u_i\} < \epsilon$

**Pivot-Strategie** bei der Reihenfolge des Akzeptierens, um möglichst “gute” Merkmale zu erhalten  
(d.h. kleine Anzahl von Merkmalen und kleines  $S^2$ )  
anstatt nur  $u_i$  wie oben zu eliminieren

### 1. maximale lineare Unabhängigkeit

- wähle  $u_i$  mit  $i = \operatorname{argmax}_j \operatorname{Var}\{\Delta u_j\}$ ,

d.h. dasjenige  $u_i$ , das von den bereits ausgewählten  $\tilde{x}$  maximale unabhängig

- wenn  $\operatorname{Var}\{\Delta u_i\} < \epsilon$  dann Abbruch
- gewährleistet gutes numerisches Verhalten, da stets das größte Diagonalelement verwendet wird



## 2. maximale Varianz des Fehlers

- wähle  $u_i$ , das am meisten zum Schätzen von  $\vec{y}$  beiträgt (was wir ja eigentlich wollen)  
o.B.d.A: wähle  $u_1$  (sonst Umsortieren der Matrix)

$$\begin{pmatrix} \text{II} & & & \underline{\tilde{A}} \\ & u_1 & \dots & \boxed{\vec{b}_1^T} \\ & \vdots & & \dots \\ \text{O} & \boxed{\vec{b}_1} & \dots & \boxed{E \left\{ \Delta \vec{d} \Delta \vec{d}^T \right\}} \end{pmatrix} \rightarrow \begin{pmatrix} \text{II} & & & \underline{\tilde{A}} - \tilde{a}_1 \frac{\vec{b}_1^T}{u_1} \\ & 1 & \dots & \boxed{\frac{\vec{b}_1^T}{u_1}} \\ & 0 & & \dots \\ \text{O} & \vdots & & \boxed{E \left\{ \Delta \vec{d} \Delta \vec{d}^T \right\} - \vec{b}_1 \frac{\vec{b}_1^T}{u_1}} \\ & 0 & \dots & \end{pmatrix}$$

- Zeile mit  $u_1$  wird durch  $u_1$  dividiert
- auf die j-te Zeile in  $\vec{b}_1$  wird das  $\frac{b_{1j}}{u_1}$ -fache der Zeile, die  $u_1$  enthält, subtrahiert (analog die anderen Zeilen)

das liefert:

$$\bullet \Delta S^2 = \text{spur} \left( E \left\{ \Delta \vec{d} \Delta \vec{d}^T \right\} \right) - \text{spur} \left( E \left\{ \Delta \vec{d} \Delta \vec{d}^T \right\} - \frac{\vec{b}_1 \vec{b}_1^T}{u_1} \right) = \text{spur} \left( \frac{\vec{b}_1 \vec{b}_1^T}{u_1} \right) = \frac{\vec{b}_1^T \vec{b}_1}{u_1}$$

• d.h. wähle  $u_i$  mit

(a)  $i = \operatorname{argmax}_i \frac{\vec{b}_i^T \vec{b}_i}{u_i}$  und

(b)  $\operatorname{Var}\{\Delta u_i\} < \epsilon$

vertausche für  $u_1$  und  $u_i$  die Zeilen und Spalten

• attraktiv, da direkt mit Schätzfehler verknüpft

• ist natürlich suboptimal, da greedy (wie 1. auch)

### Zusammenfassung

• bei linearen Abhängigkeiten der Elemente aus  $\vec{x}(\vec{c})$  erhalten wir eine (von mehreren) Lösungen

• die gewählten Elemente von  $\vec{x}(\vec{c})$  geben uns ihre “Wichtigkeit”

## 7.5 Eigenschaften der Lösung

<b>/* Berechnung der Matrix <math>\underline{A}</math> für den Polynomklassifikator */</b>	
berechne aus klassif. Stichprobe die Matrix $\underline{M} = \begin{pmatrix} E\{\vec{x}\vec{x}^T\} & E\{\vec{x}\vec{y}^T\} \\ E\{\vec{y}\vec{x}^T\} & E\{\vec{y}\vec{y}^T\} \end{pmatrix}$	
FOR alle Zeilen $i = 1, \dots, \text{Dim}(\vec{x}(\vec{c}))$	
	VListe[i] := i
FOR alle Zeilen $i = 1, \dots, \text{Dim}(\vec{x}(\vec{c}))$	
bestimme unter den Zeilen $i, \dots, \text{Dim}(\vec{x}(\vec{c}))$ diejenige Zeile $k$ mit $Diag[k] > \varepsilon$ und zugleich $\Delta S^2 = (\vec{b}_k^T \vec{b}_k) / Diag[k]$ ist maximal	
vertausche jeweils Zeilen und Spalten $i \leftrightarrow k$	
zwi := VListe[i]; VListe[i] := VListe[k]; VListe[k] := zwi	
dividiere Zeile $i$ durch $Diag[i]$ , d.h. Diagonalelement wird zu 1	
FOR alle Zeilen $k = 1, \dots, \text{Dim}(\underline{M}) \wedge k \neq i$	
normiere alle Elemente der $i$ -ten Spalte zu 0 (außer $Diag[i]$ ), d.h.	
k-te Zeile := k-te Zeile - M[k][i] * normierte i-te Zeile	
IF	$\Delta S^2 < \text{AbbruchSchranke}$ <b>oder</b> keine Zeile wählbar
THEN	STOP: aktuelle Matrix $\underline{A}$ und VListe ausgeben

### 7.5 Eigenschaften der Lösung

- Schätzung von  $\vec{y}(\vec{c})$  ist “unbiased”, d.h.

$$E \left\{ \vec{y} - \vec{d}(\vec{c}) \right\} = 0$$

- $\vec{d}(\vec{c})$  summiert auf 1:

$$\sum d_k(\vec{c}) = 1$$

zur Erinnerung: für uneingeschränkte Form von  $\vec{d}(\vec{c})$  erhalten wir eine Schätzung der a posteriori Wahrscheinlichkeit  $P(\omega_k | \vec{c})$ , die natürlich auf 1 summiert)

wir können also die  $d_k(\vec{c})$  nicht nur zum Klassifizieren verwenden, sondern erhalten auch Konfidenz für die Entscheidung

übrigens im Allgemeinen gilt **nicht**

- $E \left\{ (\vec{y} - \vec{d}(\vec{c}))^2 \right\}$  versus  $E \left\{ (P(\omega_k | \vec{c}) - \vec{d}(\vec{c}))^2 \right\}$  versus

liefert **identische** Lösung  $\underline{A}$

$P(\omega_k | \vec{c})$  wird als “soft labelling” bezeichnet

- für sehr große Stichproben identischer Klassifikator
- für kleine Stichproben u.U. nützlich,  
aber “soft labelling” ist aufwendiger als normales Hand-Klassifizieren

### 7.6 Konfidenzabbildung

- wir erinnern uns, daß wir beim Bayes-Klassifikator als Modifikation mehrere Klassen mit

$$\sum_k P(\omega_k | \vec{c}) \geq \theta$$

als Ergebnis liefern können

- auch beim Polynomklassifikator gilt:  $\sum d_k(\vec{c}) = 1$  , aber  $d_k(\vec{c}) \in \mathbb{R}$
- Clipping auf  $d_k(\vec{c}) \in [0; 1]$ ,  
ist nicht gut, es ist “unklar”, was wir hierbei machen
- daher

$$\vec{c} \rightarrow \boxed{\text{Klassifikator}} \rightarrow \vec{d}(\vec{c}) \rightarrow \boxed{\text{Konfidenzabbildung}} \rightarrow \tilde{\vec{d}}(\vec{c})$$

betrachte jedes  $d_k(\vec{c})$  unabhängig:


$$- d_k(\vec{c}) \text{ approximiert } y_k(\vec{c}) = \begin{cases} 1 & \vec{c} \in \omega_k \\ 0 & \vec{c} \notin \omega_k \end{cases}$$

## 7.6 Konfidenzabbildung

- wir können daher  $d_k(\vec{c})$  als eindimensionalen Merkmal(svektor) auffassen für das zwei Klassenproblem:

$$\vec{c} \in \omega_k \text{ VS. } \vec{c} \notin \omega_k$$

Beispiel:



## 7.6 Konfidenzabbildung

---

- da wir jetzt im eindimensionalen Fall sind, können wir
  - mit relativen Histogramme approximieren wir:

$$P(d_k(\vec{c}) \mid \omega_k) \text{ und } P(d_k(\vec{c}) \mid \neg\omega_k)$$

- durch relative Häufigkeiten schätzen wir:

$$P(\omega_k) \text{ und } P(\neg\omega_k)$$

- damit Konfidenz für  $\omega_k$  aus den absoluten Histogrammen histo:

$$\begin{aligned} \text{cnf}_k(d_k) &= P(\omega_k \mid d_k) = \frac{P(\omega_k, d_k)}{P(\omega_k, d_k) + P(\neg\omega_k, d_k)} \\ &= \frac{P(d_k \mid \omega_k)P(\omega_k)}{P(d_k \mid \omega_k)P(\omega_k) + P(d_k \mid \neg\omega_k)P(\neg\omega_k)} \\ &\sim \frac{\text{histo}_{\omega_k}[d_k] \cdot \hat{P}(\omega_k)}{\text{histo}_{\omega_k}[d_k] \cdot \hat{P}(\omega_k) + \text{histo}_{\neg\omega_k}[d_k] \cdot \hat{P}(\neg\omega_k)} \end{aligned}$$



- **aber** Summation der  $\text{cnf}_k$  auf 1 geht verloren  
unter der Annahme, daß die Merkmale tatsächlich aus (genau) einem stochastischen Prozeß der  $K$  Klassen stammt (*closed world assumption*)  
explizite Normalisierung:

$$\tilde{d}(\vec{c}) = \frac{1}{\sum_{k=1}^K \text{cnf}_k(d_k(\vec{c}))} \begin{pmatrix} \text{cnf}_1(d_1(\vec{c})) \\ \vdots \\ \text{cnf}_K(d_K(\vec{c})) \end{pmatrix}$$

(hierbei müssen die  $d_k(\vec{c})$  durch die entsprechende Diskretisierung der Histogrammbildung ersetzt werden)

- falls ein Muster aus **keiner** der  $K$  Klassen entstammt (d.h. Widerspruch zur *closed world assumption*), kann dies an den Histogrammen/Dichten

$$P(d_k \mid \omega_k), P(d_k \mid \neg\omega_k)$$

für **alle**  $k$  erkannt werden