

7 Polynomklassifikator

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

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

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 $d_i(\vec{c})$ wie folgt:

$$\begin{aligned}d_i(\vec{c}) &= a_{i0} + a_{i1}c_1 + a_{i2}c_2 + \dots + a_{iN}c_N + \\ &\quad a_{i,(N+1)}c_1^2 + a_{i,(N+2)}c_1c_2 + a_{i,(N+3)}c_1c_3 + \dots + \\ &\quad a_{i,(N+N(N+1)/2+1)}c_1^3 + a_{i,(N+N(N+1)/2+2)}c_1^2c_2 + a_{i,(N+N(N+1)/2+3)}c_1^2c_3 + \dots \\ &= \vec{a}_i^T \vec{x}(\vec{c})\end{aligned}$$

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

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

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

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 N -dimensionalem Merkmalsvektor folgende Dimension für $\vec{x}(\vec{c})$ ergibt:

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

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

Bemerkung: im Prinzip kann man für die $x_i(\vec{c})$ nicht nur Monome über den c_i 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 :

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

(im weiteren statt $\vec{x}(\vec{c})$ und $\vec{y}(\vec{c})$ nur noch \vec{x} bzw. \vec{y})

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: $\vec{a}^T \vec{b} = \text{spur}(\vec{a} \vec{b}^T)$
- 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 I klassifizierten Paaren $(\vec{c}_i, \vec{y}(\vec{c}_i))$:

$$\hat{E} \{ \vec{x} \vec{x}^T \} = \frac{1}{I} \sum_{i=1}^I \vec{x}(\vec{c}_i) \vec{x}(\vec{c}_i)^T$$
$$\hat{E} \{ \vec{x} \vec{y}^T \} = \frac{1}{I} \sum_{i=1}^I \vec{x}(\vec{c}_i) \vec{y}(\vec{c}_i)^T$$

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

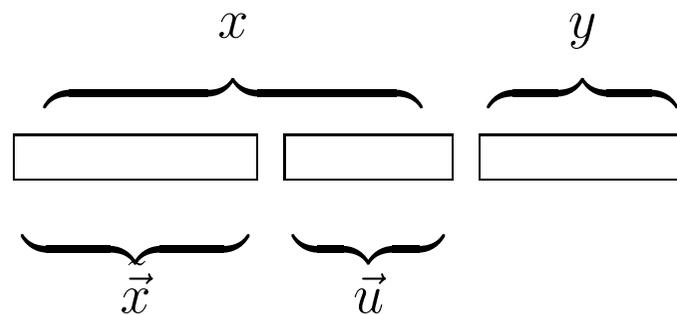
- scheinbar nichts gewonnen, da für \underline{T} immer noch die inverse von $E \{ \vec{x}\vec{x}^T \}$ erforderlich:

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

- 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



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

wobei die Merkmale in \vec{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) $i = \operatorname{argmax}_{u_i} \frac{\vec{b}_i^T \vec{b}_i}{u_i}$ 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

/* Berechnung der Matrix \underline{A} für den Polynomklassifikator */	
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	$\Delta S^2 < \text{AbbruchSchranke}$ oder 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.

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

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

$$\sum d_{\kappa}(\vec{c}) = 1$$

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

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

übrigens im Allgemeinen gilt **nicht**

$$0 \leq d_{\kappa}(\vec{c}) \leq 1$$

- $E \left\{ (\vec{y}(\vec{c}) - \vec{d}(\vec{c}))^2 \right\}$ versus $E \left\{ (\vec{p}(\vec{c}) - \vec{d}(\vec{c}))^2 \right\}$ versus
mit $p_\kappa(\vec{c}) = P(\omega_\kappa \mid \vec{c})$

liefert **identische** Lösung A

$P(\omega_\kappa \mid \vec{c})$ 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