

# 5 Merkmalsextraktion

**Wichtig** : anhand der Merkmale eines Musters wird klassifiziert

- Merkmale müssen die *charakteristische* Information von Mustern enthalten (NICHT: gute Approximation oder Rekonstruktion)
- die Klassifikation soll “einfacher” sein
  - weniger Daten
  - kompakt im Merkmalsraum
- heuristische Merkmalsgewinnung
- analytische Merkmalsgewinnung
- nicht in der Vorlesung: Bewertung und Auswahl
- in der VL numerische Merkmale:  $\vec{f} \rightarrow \vec{c} \in \mathcal{R}^n$

### 5.1 Heuristische Merkmale

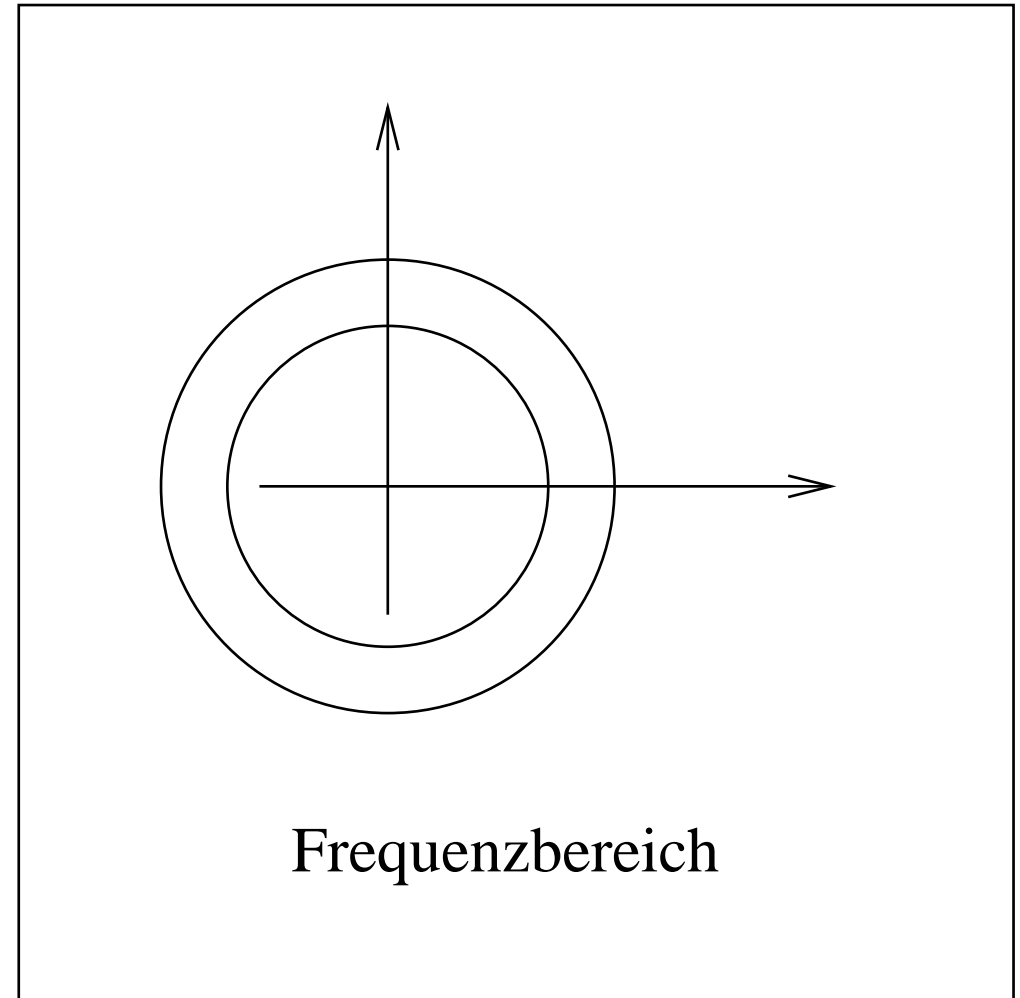
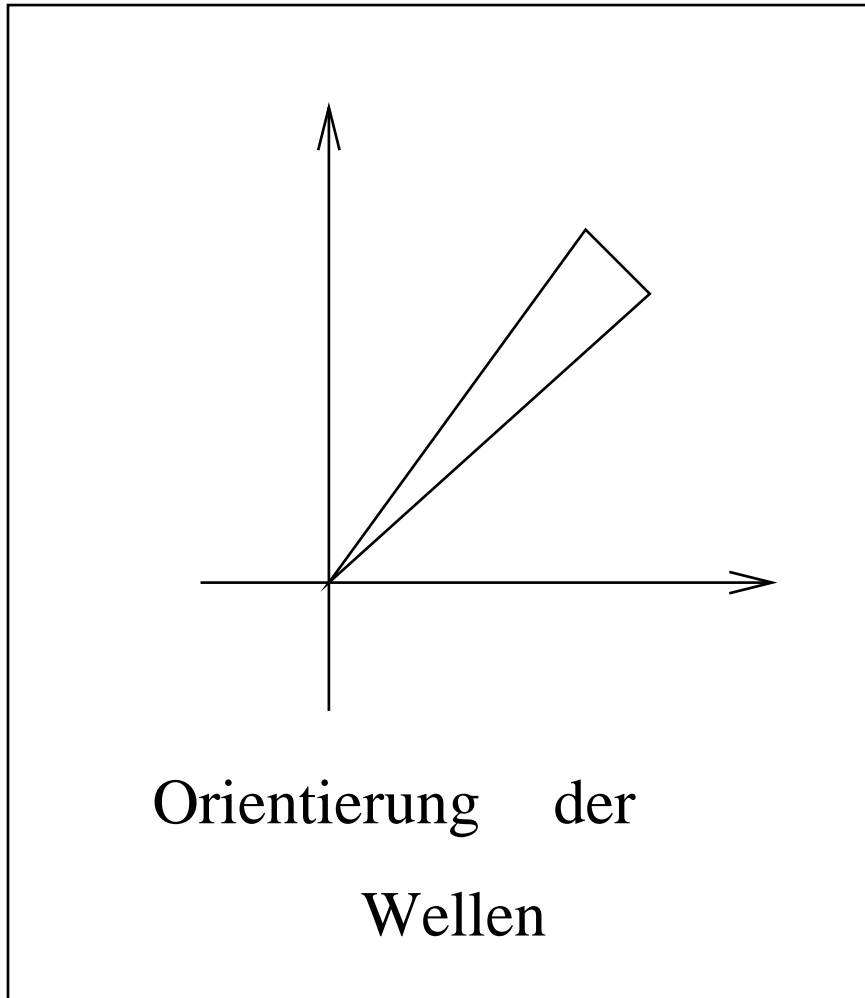
#### 5.1.1 Kennzahlen

s. Abschnitt 2.1

#### 5.1.2 DFT

- DFT ist translationsinvariant wenn nur die Beträge des Spektrums betrachtet werden
- Skalierung- oder Rotationsinvarianz durch geeignete vorherige Transformation z.B. Normierung mit Momenten (nur “Teil” davon)
- Reduktion der Anzahl von Merkmalen:  
Summiere die Koeffizienten der DFT auf gewissen Gebieten im Frequenzraum.  
Dabei entstehen eventuell Invarianzen  
Beispiele: Orientierung der Schwingungen, Frequenzbereich

## 5.1 Heuristische Merkmale




### 5.1.3 Behandlung von Konturen

betrachte Kontur parametrisch als 1D-Funktion in der komplexen Ebene, abgetastet entlang der Kontur mit  $\Delta t$ .

$\Rightarrow$  eine Folge von komplexen Abtastwerten, und wir können DFT zur Merkmalsextraktion verwenden. Diese sind aber abhängig von

- Anfangspunkt  $u(0)$
- Translation
- Rotation
- Skalierung

(Es gibt Normierungen)



### 5.1.4 Lineare Vorhersage

Idee: schätze aus letzten  $m$  Abtastwerten den nächsten Abtastwert als Linearkombination:

$$\hat{f}_n = - \sum_{\mu=1}^m a_{\mu} f_{n-\mu}$$

- damit kann der menschliche Vokaltrakt modelliert werden
- auch Anwendung z.B. für Textur

die  $a_{\mu}$  werden so bestimmt, daß in einem Fenster von  $n_0$  bis  $n_1$  ein minimaler quadratischer Fehler entsteht, wir nehmen also an, daß das System in diesem Fenster annähernd stabil ist.

$$\epsilon = \sum_{n=n_0}^{n_1} (f_n - \hat{f}_n)^2$$

## 5.1 Heuristische Merkmale

---

minimal wird.D.h.:

$$\begin{aligned} 0 &= \frac{\partial \epsilon}{\partial a_\nu} \\ &= 2 \left( \sum_{n=n_0}^{n_1} \left( f_n + \sum_{\mu=1}^m a_\mu f_{n-\mu} \right) f_{n-\nu} \right) \\ \sum_{\mu=1}^m a_\mu \sum_{n=n_0}^n f_{n-\mu} f_{n-\nu} &= - \sum_{n=n_0}^{n_1} f_n f_{n-\nu} \end{aligned}$$

Hinweis: Autokorrelationsmethode zum effizienten Bestimmen der  $a_\nu$

## 5.1 Heuristische Merkmale

---

Für (oft überlappende) Fenster die  $a_\mu$  bestimmen, daraus als Merkmale:

- die  $a_\mu$  direkt, oder
- logarithmisches Modellspektrum als geglättete Form des logarithmischen Spektrums des Musters ( $\log |F_\nu|^2$ )

$$\vec{a} = (1, a_1, \dots, a_m, 0, \dots, 0)$$

wird Fourier-transformiert, dann logarithmieren,  
ergibt geglättetes Spektrum (eben das Modellspektrum)

Sprache typische Werte:  $m = 10 \dots 12$ ,  $n_1 - n_0 \sim 300$

Die Länge  $M$  von  $\vec{a}$  wird so gewählt, daß:

$$M > \frac{f_s}{f_r} = \frac{\text{Abtastfrequenz}}{\text{gewünschte Auflösung des Modellspektrums}}$$

## 5.1 Heuristische Merkmale




Bild 3.6.2: a) Eine Zeitfunktion; es handelt sich um einen Ausschnitt von 20 ms Dauer aus dem Vokal „a“ in dem Wort „Fass“. b) Das mit der DFT berechnete Spektrum, Abtastfrequenz 10kHz. c) Das aus den Koeffizienten der linearen Vorhersage mit  $m = 13$  gewonnene Modellspektrum. Bei den Spektren ist jeweils der Betrag in logarithmischem Maßstab für den Bereich 0–5kHz dargestellt

aus [1]



### 5.1.5 Momente

#### Zentralmomente (mittelwertfrei)

- diskrete Version, Muster der Größe  $M \times M$

$$\mu_{pq} = \sum_{k=0}^{M-1} \sum_{i=0}^{M-1} (x_k - x_s)^p (y_i - y_s)^q \Delta x \Delta y f_{ki}$$

$\Delta x, \Delta y$       Abtastintervalle  
 $(x_s, y_s)$       Schwerpunkt

⇒ translationsinvarianz

#### Rotationsinvarianz

aus den Zentralmomenten, z.B.

$$c_1 = \mu_{20} + \mu_{02}$$

$$c_2 = (\mu_{20} + \mu_{02})^2 + 4\mu_{11}^2$$

### 5.2 Analytische Merkmalsextraktion

- gewinne Merkmale  $c_v$  *systematisch*, so daß (im gewissen Sinn) optimal  
Optimalität von “Problem”, d.h. den gegebenen Daten, abhängig
- wir betrachten lineare und orthonormale Transformationen:  
 $\vec{c} = \Phi \vec{f}$ , wobei i.d.R.  $\dim \vec{c} < \dim \vec{f}$   
Zeilen von  $\Phi$  orthonormal

Problem:

- bestimme Optimalitätskriterium
- bestimme optimale  $\Phi$

Zwei Typen von Kriterien:

1. Leistung des Klassifikators (z.B. Fehlerwahrscheinlichkeit) optimieren  
(gut, aber sehr aufwendig)
2. Postulat 3 (keine Rücksicht auf den Klassifikator, der spielt aufgrund des modularen Aufbaus keine Rolle)

## 5.2 Analytische Merkmalsextraktion

---

Wir suchen  $n$  orthonormale Vektoren  $\vec{\varphi}_\nu$  die eines der folgenden Kriterien erfüllen.

Wir gehen von einer Stichprobe aus

$$\omega = \left\{ {}^1\vec{f}, \dots, {}^N\vec{f} \right\}$$

die Klassifiziert ist:

$$\begin{aligned} \omega &= \omega_1 \dot{\cup} \dots \dot{\cup} \omega_k \\ \omega_\kappa &= \left\{ {}^1\vec{f}_\kappa, \dots, {}^{N_\kappa}\vec{f}_\kappa \right\} \end{aligned}$$

Merkmale:  ${}^i\vec{c}_\kappa$  ist der Merkmalsvektor zu  ${}^i\vec{f}_\kappa$

**Vier Kriterien** (basierend auf euklidischem Abstand)

1. mittlerer quadratischer Abstand aller Merkmale untereinander

$$S_1 = \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N ({}^i\vec{c} - {}^j\vec{c})^T ({}^i\vec{c} - {}^j\vec{c})$$

### 2. Interklassen-Abstand

$$S_2 = \frac{2}{K \cdot (K - 1)} \sum_{\kappa=2}^K \sum_{\lambda=1}^{\kappa-1} \frac{1}{N_{\kappa} N_{\lambda}} \sum_{i=1}^{N_{\kappa}} \sum_{j=1}^{N_{\lambda}} (\vec{c}_{\kappa} - \vec{c}_{\lambda})^T (\vec{c}_{\kappa} - \vec{c}_{\lambda})$$

Mittel über den mittleren quadratischen Abstand der Merkmale aus verschiedenen Klassen

### 3. Intraklassen-Abstand

$$S_3 = \frac{1}{K} \sum_{\kappa=1}^K \frac{1}{N_{\kappa}^2} \sum_{i=1}^{N_{\kappa}} \sum_{j=1}^{N_{\kappa}} (\vec{c}_{\kappa} - \vec{c}_{\kappa})^T (\vec{c}_{\kappa} - \vec{c}_{\kappa})$$

Mittlerer quadratischer Abstand von Merkmalen innerhalb einer Klasse

### 4. Kombination aus $S_2$ , $S_3$ ( $S_2$ groß, $S_3$ klein)

$$S_4 = S_2 - \lambda S_3$$

eine Möglichkeit:

- lege  $\lambda$  fest
- betrachte  $\lambda$  als Lagrange-Multiplikator

Suche  $\vec{\Phi}$ . so daß

- $S_1$ ,  $S_2$  oder  $S_4$  maximal werden oder
- $S_3$  minimal wird

**Satz** die  $\vec{\Phi}^{(l)}$ , die  $S_l$  optimieren, erhalten wir aus Eigenvektoren mit größten (bzw. kleinsten) Eigenwerten zu geeigneten *symmetrischen Kernmatrixen*  $\vec{Q}^{(l)}$

## 5.2 Analytische Merkmalsextraktion

---

$$\vec{Q}^{(1)} = \vec{R} - \vec{m}\vec{m}^T \quad (\text{Kovarianzmatrix})$$

$$\vec{R} = \frac{1}{N} \sum_{j=1}^N j\vec{f} j\vec{f}^T \quad (\text{Korrelationsmatrix})$$

$$\vec{m} = \frac{1}{N} \sum_{j=1}^N j\vec{f} \quad (\text{Mittelwert})$$

$$\vec{Q}^{(2)} = \frac{2}{k} \sum_{\kappa=1}^k \vec{R}_{\kappa} - \frac{2}{k(k-1)} \sum_{\kappa=2}^k \sum_{\lambda=1}^{\kappa-1} (\vec{m}_{\kappa}\vec{m}_{\lambda}^T + \vec{m}_{\lambda}\vec{m}_{\kappa}^T)$$

$$\vec{R}_{\kappa} = \frac{1}{N_{\kappa}} \sum_{j=1}^{N_{\kappa}} j\vec{f}_{\kappa} j\vec{f}_{\kappa}^T$$

$$\vec{m}_{\kappa} = \frac{1}{N_{\kappa}} \sum_{j=1}^{N_{\kappa}} j\vec{f}_{\kappa}$$

$$\vec{Q}^{(3)} = \frac{1}{K} \sum_{\kappa=1}^k \left( \vec{R}_{\kappa} - \vec{m}_{\kappa}\vec{m}_{\kappa}^T \right)$$

$$\vec{Q}^{(4)} = \vec{Q}^{(2)} - \lambda\vec{Q}^{(3)}$$

### Einschub

1. für beliebige quadratische Matrix  $\vec{B}$  gilt

(a)  $\vec{x}^T \vec{B} \vec{y} = \text{SP} \left( \vec{B} \vec{y} \vec{x}^T \right)$ , mit  $\text{SP} \left( \vec{B} \right) = \text{Summe über die Diagonale}$

(b)  $\vec{x}^T \vec{B} \vec{y} = \text{SP} \left( \vec{y} \vec{x}^T \vec{B}^T \right)$

(c) für  $M \times n$  Matrix  $\vec{A}^T$ ,  $\vec{A}^T = (\vec{a}_1, \dots, \vec{a}_n)$ , gilt  $\vec{A}^T \vec{A} = \sum_{\nu=1}^n \vec{a}_\nu^T \vec{a}_\nu$

(d)  $\sum_{\nu=1}^n \vec{a}_\nu^T \vec{B} \vec{a}_\nu = \text{SP} \left( \vec{A}^T \vec{A} \vec{B}^T \right)$

2.(a) sei  $\vec{A}$  eine reelle, symmetrische, positiv definite Matrix,  
(d.h.  $\forall \vec{x} \neq 0 : \vec{x}^T \vec{A} \vec{x} > 0$ )

dann gilt:

- $\vec{A}$  hat reelle Eigenwerte  $> 0$
- die Eigenvektoren sind orthogonal,  
bzw. können bei mehrfachen Eigenwerten orthogonalisiert werden
- $\vec{x}^T \vec{A} \vec{x}$  wird maximal für  $\vec{x} =$  Eigenvektor zum größten Eigenwert von  $\vec{A}$   
am zweit größten, für den Eigenvektor zum nächst kleineren Eigenwert, ...
- entsprechend bekommen wir die kleinsten Werte für die kleinsten  
Eigenwerte
- die Kernmatrizen sind reelle, symmetrische, positiv semi-definite Matrizen  
(positiv semi-definit aber nicht positiv definit, wenn die Mustervektoren  
nicht den gesamten Raum aufspannen)

damit **Beweis** für  $S_2$



### Zusammenfassung des Vorgehens

1. bestimme  $Q^{(l)}$
2. bestimme die Eigenvektoren zu  $Q^{(l)}$   
(Wenn  $Q^{(l)}$  vollen Rang hat, ist sie positiv definit und besitzt  $M$  orthogonale Eigenvektoren)
3. wähle die  $n$ -Eigenvektoren zu den
  - größten ( $S_1, S_2, S_4$ )
  - kleinsten ( $S_3$ )Eigenwerten. Diese bilden die Matrix  $\vec{\Phi}$

### Bemerkungen:

1. diese Entwicklung heißt problemabhängig, da sie von der Stichprobe abhängt
  - die gewonnenen Merkmale enthalten in der Regel für die Klassifikation bessere Information als heuristische
2. die Transformation, die  $S_1$  maximiert heißt *Hauptachsentransformation* oder *Karhunen-Loeve-Transformation* oder principal component analysis (PCA)

### Eigenschaften der Hauptachsen Transformation:

- der mittlere quadratische Approximationsfehler wird minimal  
(bei fester Anzahl  $\dim \vec{c}$  Koeffizienten,  
wir können die Transformation in  $\dim \vec{c}$  dimensionale Unterraum auffassen!)
- die  $\vec{\varphi}_\nu$  geben die Hauptachsen der Stichprobe, d.h. die Achsen "größter Ausdehnung"
- die  $c_\nu$  sind maximal dekorreliert