


Minimalität und Orthogonalität **innerhalb eines** Medienobjekts  
(Fourier und Wavelet-Transformation)

Karhunen-Loeve-Transformation (KLT) für Minimalität und  
Orthogonalität bzgl. **mehrerer** Medienobjekten

Analyse der Verteilung der Feature-Werte **mehrerer**  
Medienobjekte

Erkennung linearer Abhängigkeit anhand erkannter *Achsen*  
andere Bezeichnung für KLT: Hauptachsentransformation  
(HAT), principal component analysis (PCA)

# Lineare Abhängigkeit: 10 Beispielpunkte



lineare Abhängigkeit bedeutet Redundanz  
→ Verletzung der Forderung nach Minimalität

Problem: Achsen oft nicht achsenparallel im Feature-Raum

Idee der KLT: Verschiebung und Rotation des Feature-Raums  
→ Achsen entsprechen Feature-Dimensionen  
→ Erwartungswert ist Koordinatenursprung

Entfernen von Achsen mit geringer Steuerung

Berechnung Kovarianzmatrix aus  
 $m$ -dimensionalen Feature-Vektoren

$m \times m$ -Kovarianzmatrix  $\{S_{kl}^2\}$ :

Kovarianz zwischen Dimensionen  $k$  und  $l$  :

- ◆ 0 → keine lineare Abhängigkeit
- ◆  $>0$  → positive lineare Abhängigkeit
- ◆  $<0$  → negative lineare Abhängigkeit

Diagonalwerte entsprechen Varianzwerten einzelner Dimensionen

Kovarianzmatrix ist symmetrisch

→ Zerlegung in  $U * L * U^T$  durch Lösen des Eigenwertproblems möglich

$$\text{Kovarianzmatrix} = U * L * U^T$$


$U^T$  enthält orthonormale Eigenvektoren (Achsen)

→ Transformation in Eigenraum

$U$  entspricht Rücktransformation

$L$  ist Diagonalmatrix: Diagonalwerte sind  
Eigenwerte/Varianzwerte

→ achsenparallele Skalierung im Eigenraum




Transformation der Feature-Vektoren erzeugt achsenparallele Abhängigkeits-achsen (Translation um negierten Mittelwertsvektor und Multiplikation mit  $U^T$ )

Sortieren der Achsen nach Varianzwert

Entfernen von Achsen mit geringer Varianz (unterhalb best. Schwellwert)

Rücktransformation bedeutet Entfernen linearer Abhängigkeiten (Multiplikation mit  $U$  und Translation um Mittelwertsvektor)

Reduktionsfehler abhängig von Eigenwerten der entfernten Achsen  
→ Distanzen bleiben weitgehend erhalten



## Vorteile der KLT

### Orthogonalisierung:

- lineare Abhängigkeiten werden entfernt
- Werte der Achsendimensionen (inhärente Feature Dimension) isoliert manipulierbar  
→ Trennung wesentlicher von unwesentlichen Dimensionen möglich

### **Vorteile der KLT (Forts.)**

Minimierung: Entfernung unnötiger Dimensionen im Eigenraum  
→ minimaler Reduktionsfehler

Invarianzen: isolierte Analyse von linear wirkenden Invarianzen  
möglich

### Probleme der KLT

Berechnung auf **Menge** von Feature-Vektoren


- ◆ Problem bei dynamischer Menge
- ◆ Lösungsansatz: Verwendung statischer repräsentativer Untermenge

### **Probleme der KLT (Forts.)**

nicht-lineare Abhängigkeiten nicht erkennbar

orthogonale Achsen: nicht immer erwünscht

Ausweg: ICA (independent component analysis)



Ausgangspunkt ist Menge von  $n$   
 $m$ -dimensionalen Feature-Vektoren  
→  $m \times n$  Feature-Matrix

Beispiel:  $F = \{f_{ij}\} \in \mathbb{R}^{m \times n}$

$$F = \begin{pmatrix} 2,5 & 2,5 & 4 & 4 & 5,5 & 7,5 & 8,5 & 8,5 & 9,5 & 10 \\ 1,5 & 3 & 3,5 & 2,5 & 3 & 4,5 & 4,5 & 3,5 & 5 & 4,5 \end{pmatrix}$$

Mittelwertvektor:

Beispiel: 
$$\begin{pmatrix} \bar{f}_{1*} \\ \vdots \\ \bar{f}_{m*} \end{pmatrix} \text{ mit } \bar{f}_{i*} = \frac{1}{n} \sum_{j=1}^n f_{ij}$$

$$\begin{pmatrix} \bar{f}_{1*} \\ \bar{f}_{2*} \end{pmatrix} = \begin{pmatrix} 6,25 \\ 3,55 \end{pmatrix}$$

Kovarianzmatrix:  $S^2 = \{s_{kl}^2\} \in \mathbb{R}^{m \times m}$

Beispiel: 
$$s_{kl}^2 = \frac{1}{n-1} \sum_{i=1}^n (f_{ki} - \bar{f}_{k*})(f_{li} - \bar{f}_{l*})$$

$$S^2 = \begin{pmatrix} 8,3472 & 2,6806 \\ 2,6806 & 1,1917 \end{pmatrix}$$

$$S^2 = U * L * U^T$$

da symmetrisch, Zerlegung anhand Eigenvektoren möglich:

$L$  enthält Eigenwerte  $\lambda_1, \lambda_2, \dots, \lambda_m$

$U$  ist orthonormal und Spaltenvektoren entsprechen den Achsen

Durchführung Permutation der drei Matrizen, damit  
gilt  $\lambda_i \geq \lambda_{i+1}$

Beispiel:

$$U = \begin{pmatrix} 0,9488 & -0,316 \\ 0,316 & 0,9488 \end{pmatrix}$$

$$L = \begin{pmatrix} 9,24 & 0 \\ 0 & 0,2989 \end{pmatrix}$$

Transformation von Feature-Vektor  $f_{*j}$

Beispiel: 
$$f'_{*j} = U^T * \begin{pmatrix} f_{1j} - \bar{f}_{1*} \\ f_{2j} - \bar{f}_{2*} \\ \vdots \\ f_{mj} - \bar{f}_{m*} \end{pmatrix}$$

$$F' = \begin{pmatrix} -4,2 & -3,7 & -2,1 & -2,5 & -0,9 & 1,5 & 2,4 & 2,1 & 3,5 & 3,8 \\ -0,8 & 0,7 & 0,7 & -0,3 & -0,3 & 0,5 & 0,2 & -0,7 & 0,3 & -0,3 \end{pmatrix}$$

$$f_{*j} = U * f'_{*j} + \begin{pmatrix} \bar{f}_{1*} \\ \bar{f}_{2*} \\ \vdots \\ \bar{f}_{m*} \end{pmatrix}$$

Entfernen von Achsendimensionen mit geringer Varianz  
Abschätzung über Anteil an Gesamtvarianz:

$$\text{Anteil}_i = \frac{\lambda_i}{\sum_{j=1}^m \lambda_j}$$

Beispiel: 1. Achse hat 97 Prozent und zweite Achse 3 Prozent  
→ Weglassen der zweiten Achsendimension

$f''_{*j}$  sei Ergebnis der Reduktion von  $f'_{*j}$

Rücktransformation von  $f''_{*j}$  erzeugt

$$\tilde{f}_{*j} \neq f_{*j}$$

Erhalt nur der  $p$  ersten Achsendimensionen  
Erwartungswert des quadrierten Fehlers:

$$R^2 = E\{\|\tilde{f}_{*j} - f_{*j}\|^2\}$$

es gilt:

$$R^2 = \sum_{i=p+1}^m \lambda_i$$