# CI - Übung   Blind Source Separation (BSS)

Note Title   05.06.2009

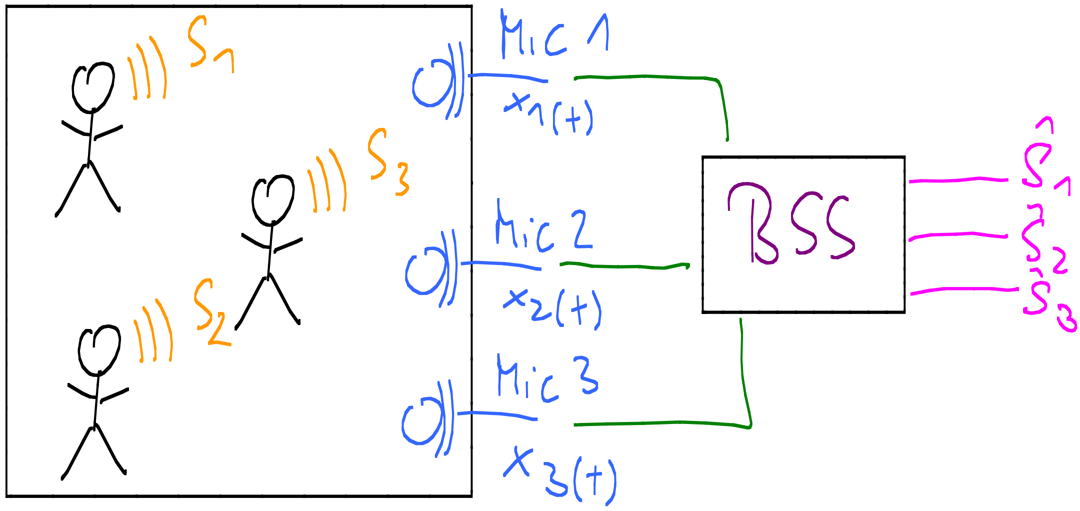


$$\vec{S}_{(t)} = \begin{bmatrix} S_1(t) \\ S_2(t) \\ S_3(t) \end{bmatrix} \qquad \vec{x} = \begin{bmatrix} x_1(t) \\ x_2(t) \\ x_3(t) \end{bmatrix}$$

$$x_1(t) = a_{11} \cdot S_1(t) + a_{12} S_2(t) + a_{13} S_3(t)$$

$\vec{x}_{(t)} = A \cdot \vec{S}_{(t)}$   A ... Mischmatrix

$\hat{S}_{(t)} = W \cdot \vec{x}_{(t)}$   W ... Entmischmatrix

## Annahmen:

- rang(A) $\overset{!}{=}$ d   ⇒ EV(A) muss linear unabhängig sein
- var($S_i$) = 1
- mean($S_i$) = 0
- $N \leq M$   N ... # Sprecher
  M ... # Micros

## Weitere Annahmen

- Vernachlässigbare Randcharakteristik
- $\forall S_i$ sind statistisch unabhängig

$$P(S_i, S_j) = P(S_i | S_j) \cdot P(S_j)$$

$$S_i \perp\!\!\!\perp S_j \Rightarrow P(S_i) P(S_j)$$

$$I(S_i; S_j) = 0$$

## Verwendbare Verfahren:

PCA ... Hauptkomponenten Transformation
(Projektion von $\vec{x}$ auf Orthogonalbasis
$\Rightarrow$ Dekorrelation (diagonale Kovarianz Matrix)

1.) PCA: $\vec{\alpha}_1$ $\quad y_1^i = \vec{\alpha}_1^T \cdot \vec{x}_i \quad var(y_1^i) \overset{!}{=} maximal$

2.) PCA: $\vec{\alpha}_2$ $\quad y_2^i = \vec{\alpha}_2^T \cdot \vec{x}_i \quad var(y_2^i) \overset{!}{=} maximal$

⋮

d.) ...
(für jede Dimension)

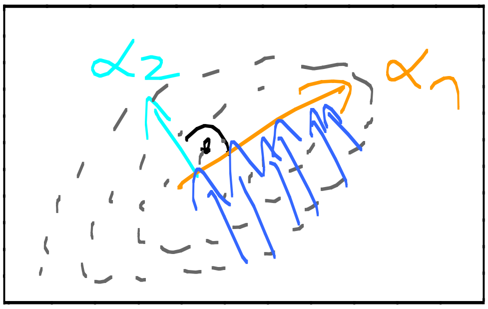


$$\vec{\alpha}_1 \perp \vec{\alpha}_2$$

$$\alpha_1^T \cdot \alpha_2^T = 1$$

Die PCA entspricht einer Eigenvectoren Zerlegung der Kovarianzmatrix

ICA ... Independent Component Analysis
(Projektion von $\vec{x}$ auf Orthogonalbasis
$\Rightarrow$ statistisch unabhängig)

Grundgesetz der Statistik (zentraler Grenzwertsatz)

Summe von vielen statistisch unabhängigen Zufallsvectoren ist näherungsweise normalverteilt.

Gradient descent:
Bewertung der Gaußabhängigkeit mittels
- Kurtosis
- Entropie

Prüfungsfrage: Datenreduktion

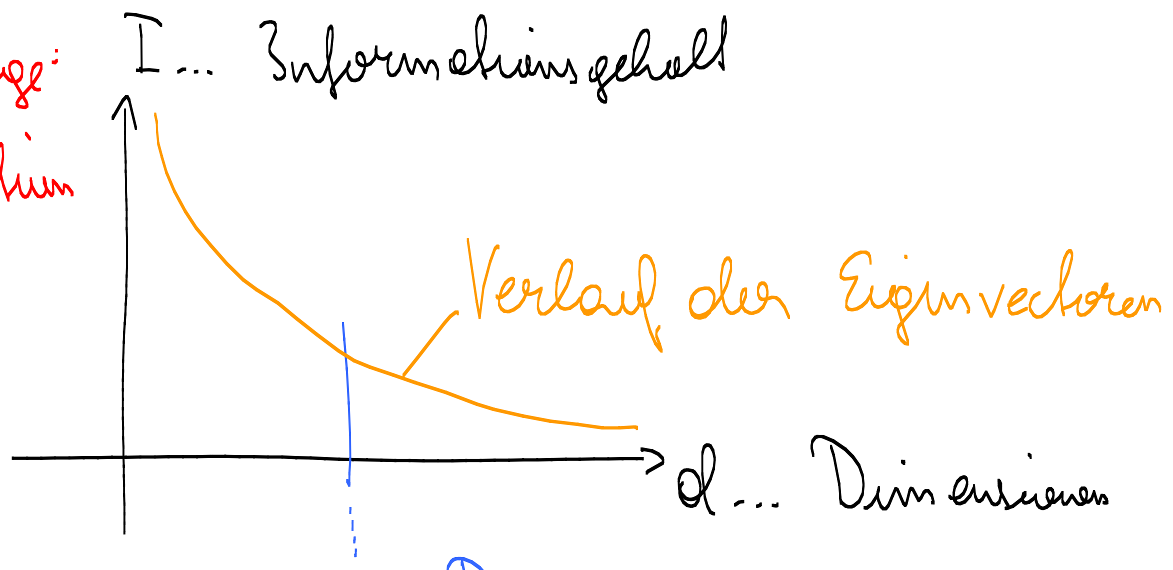


zur Dimensionsreduktion nur EVs mit hohem Infogehalt wählen $\Rightarrow$ Datenkompression

PCA:

Ist die Kovarianzmatrix voll besetzt bedeutet dies das die Daten Korrelieren (d.h. kleiner x wert bedeutet naeherungsweise kleinen y wert)
ist die Kovarianzmatrix diagonalisiert sind die Daten nicht korreliert

Kleiner Eigenwert ... Eigenvector modeliert wenig info, vice verca

Eigenvektoren zeigen in Richtung groesste Varianz; EV1 in die Groesste, EV2 zur 2. Groessten

Bis hier her diehnt es zur Bestimmung der Orthogonalbasis

ICA:

Es kann eine Phasendrehung um 180 Grad passieren
FASTICA von Homepage downloaden