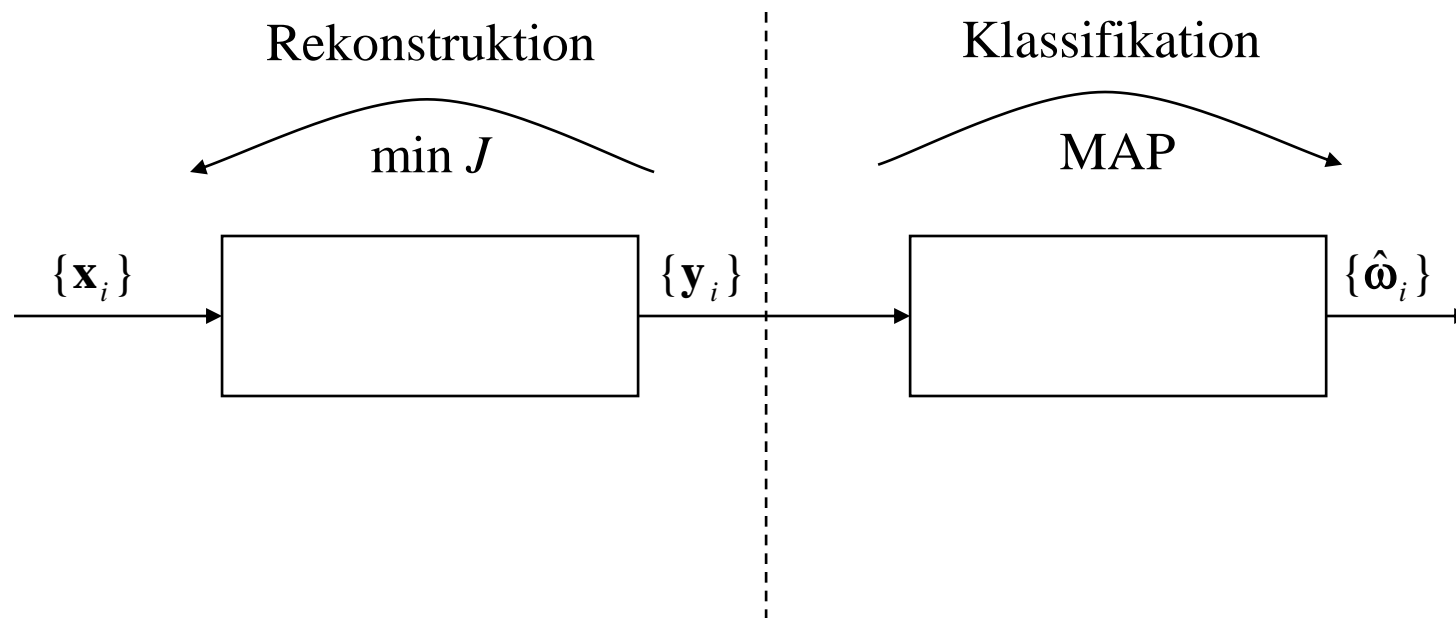


# Unterteilung des Klassifikationsprozesses in eine *Merkmalsselektion* (Approximationsproblem) und eine *Klassifikation im Unterraum*



Anmerkung: Jede Klasse hat i.allg. ihre eigene klassenspezifische Verteilungsdichte. Für die optimale Merkmalsselektion muss die Verteilungsdichte über alle Klassen verwendet werden!


# Beispiel

## Erkennung handgeschriebener Ziffern und Visualisierung der Eigenwertzerlegung

(aus J. Schürmann: „Pattern Classification“, John Wiley 1996)


# Visualisierung der klassenspezifischen *Erwartungswerte* $\{\mu_k\}$ von handgeschriebenen Ziffern

Normalisierung von Lage und Größe (bounding box)




die Originalsamples  $\{x_i\}$  sind schwarz/weiß, Pixelraster:  $16 \times 16$ , die Erwartungswerte nehmen allgemeine Grauwerte an, die Grauwerte verdeutlichen die Erwartungswerte.

Zusätzliche Normalisierung der Scherung



Durch die Normierung werden die klassenspezifischen Streuungen reduziert.


# Darstellung der ersten $M=16$ Eigenvektoren (Eigenbilder/Eigenimages) im Merkmalsraum $\{\mathbf{y}_i\}$

 $\mathbf{e}'_1$  $\mathbf{e}'_2$  $\mathbf{e}'_3$  $\mathbf{e}'_4$  $\mathbf{e}'_5$ 

Die niedrigen Eigenvektoren tragen zu den groben Strukturen bei, die höheren zu den feineren Details

# Schnelle Konvergenz im Eigenvektorraum


Original



Darstellung mit: oben: 1,2,3,4 Mitte: 5,6,8,10,15 unten: 20,25,30,35,40 Eigenbildern.  
Die Originalbilder haben eine Dimension von  $N=16 \times 16=256$ . Schon mit einem Merkmalsvektor der Dimension **40** lässt sich eine sehr gute Repräsentation erzielen.

# Schnelle Konvergenz im Eigenvektorraum


Original



Darstellung mit: oben: 1,2,3,4 Mitte: 5,6,8,10,15 unten: 20,25,30,35,40 Eigenbildern  
Die Originalbilder haben eine Dimension von  $N=16 \times 16=256$ . Schon mit einem Merkmalsvektor der Dimension **40** lässt sich eine sehr gute Repräsentation erzielen.


# Schnelle Konvergenz im Eigenvektorraum

Original



Darstellung mit: oben: 1,2,3,4 Mitte: 5,6,8,10,15 unten: 20,25,30,35,40 Eigenbildern  
Die Originalbilder haben eine Dimension von  $N=16 \times 16=256$ . Schon mit einem Merkmalsvektor der Dimension **40** lässt sich eine sehr gute Repräsentation erzielen.

# Visualisierung der Kovarianzmatrix




Ein Bild der Dimension  $N \times N$   
generiert eine Kovarianzmatrix der  
Dimension  $N^2 \times N^2$ .

$$\text{Kovarianz: } E\{(\mathbf{x}_{i,j} - \bar{\mathbf{x}}_{i,j})(\mathbf{x}_{k,l} - \bar{\mathbf{x}}_{k,l})\}$$

Charakterisiert die statistische  
Abhängigkeit zwischen den  
Pixeln eines Bildes




# Visualisierung der Kovarianzmatrix *einer* handgeschriebenen Zifferklasse “2“




Natürliche Anordnung der Kovarianzmatrix (zeilengestapelt). Das Bild verdeutlicht, dass man es keineswegs mit einem weißen Prozess zu tun hat (dann wären nur Grauwerte entlang der Hauptdiagonalen sichtbar), sondern die Grauwerteverteilungen visualisieren die Korrelationen in die Nachbarschaft.

# Visualisierung der Kovarianzmatrix *einer* handgeschriebenen Zifferklasse “2“




## *Reorganisation der Kovarianzmatrix:*

Die Submatrizen, welche die lokalen Korrelationen repräsentieren, sind an die entsprechenden Pixelpositionen geschoben



# Visualisierung der Kovarianzmatrix *einer* handgeschriebenen Zifferklasse “2“



Interpretation der  
Korrelationen bzw.  
Kovarianzen mit der  
Visualisierung lokaler  
Kovarianzsubmatrizen