

# Computergrafik 2: Übung 10

Haralicksche Texturmerkmale, Klassifikation

**Organisation**

**KLAUSURANMELDUNG  
(UNIWORX) NICHT  
VERGESSEN!**

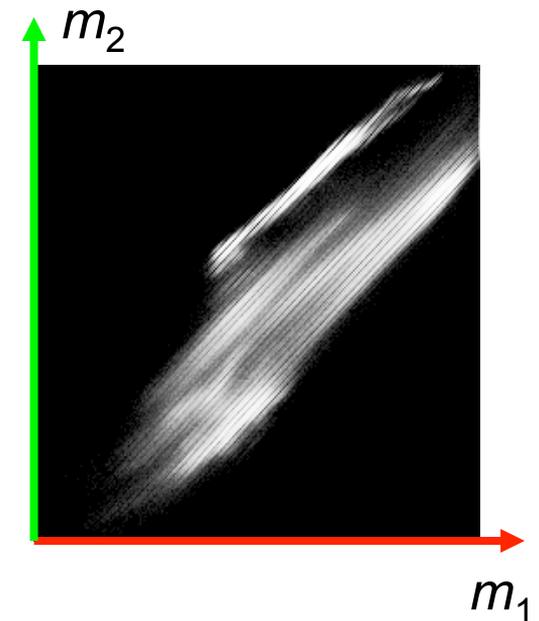
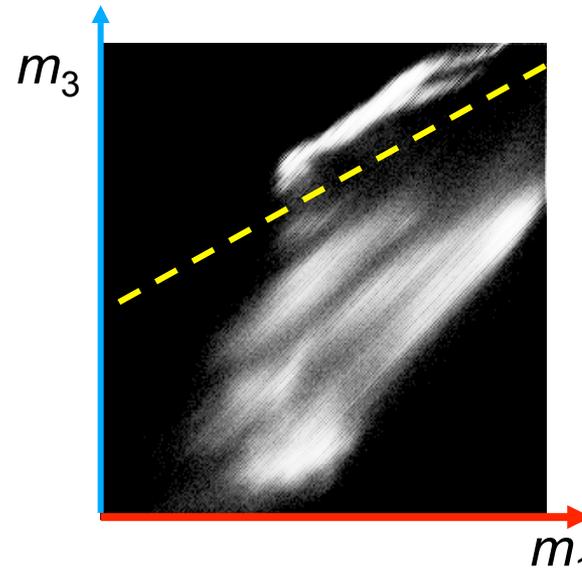
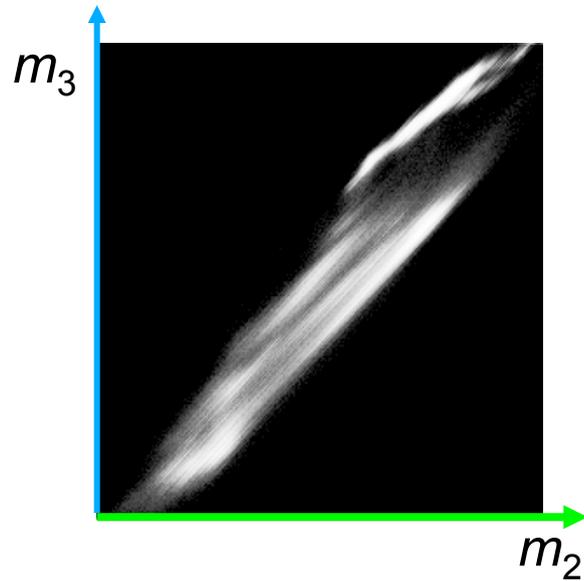
# Besprechung Übung 9

- Anmerkungen?

# Quiz

- Was kann als Klassifikationsmerkmal dienen?
- Was machen Klassifikationsverfahren?
  - Wozu braucht man Klassifikation bei der Bildverarbeitung?
- Arten von Merkmalen?
  - Mehr oder weniger Merkmale verwenden?
  - Auswahlstrategie?
- Wie leitet man geeignete Merkmale ab?
- Klassifikationsverfahren?
  - Wie funktioniert Bayes'sche Klassifikation?
  - Wie funktioniert logistische Regression?

# Mehrdimensionaler Merkmalsraum



Projektionen des dreidimensionalen Merkmalsraums auf

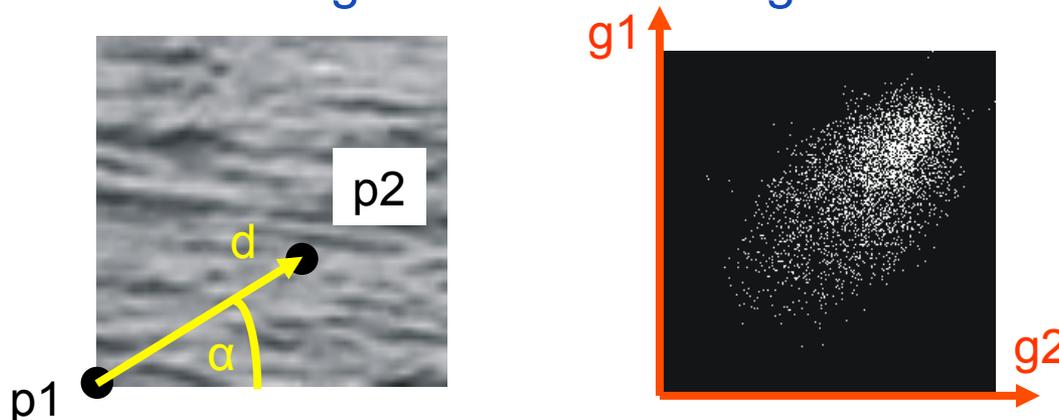
- Blau-Grün-Ebene
- Blau-Rot-Ebene
- Grün-Rot-Ebene

# Haralick'sche Texturmaße

Robert  
Haralick

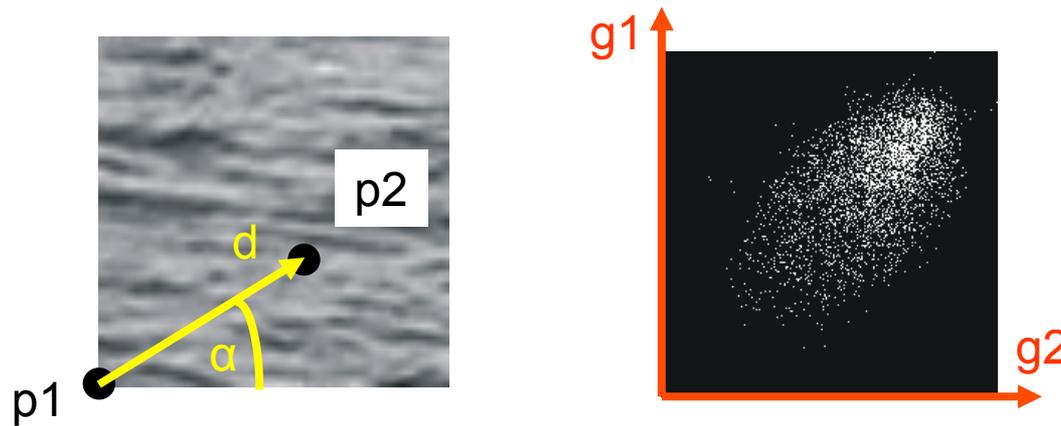


- **Co-Occurrence-Matrix** = 2D-Histogramm für Pixelpaare
  - Pixel  $p_1$  und  $p_2$  sind ein Paar, wenn Abstand  $d$  haben und auf Linie mit Winkel  $\alpha$  zur  $x$ -Achse liegen
- Repräsentiert Korrelation zwischen Pixeln
  - Wahrscheinlichkeit, dass  $p_1$  und  $p_2$  Grauwerte  $g_1$  und  $g_2$  haben
  - Meist sind Pixel nicht über große Entfernungen korreliert, daher  $d=1$  oder  $d=2$  üblich
  - Für Korrelation über größere Entfernung  $\rightarrow$  Multiskalenstrategie

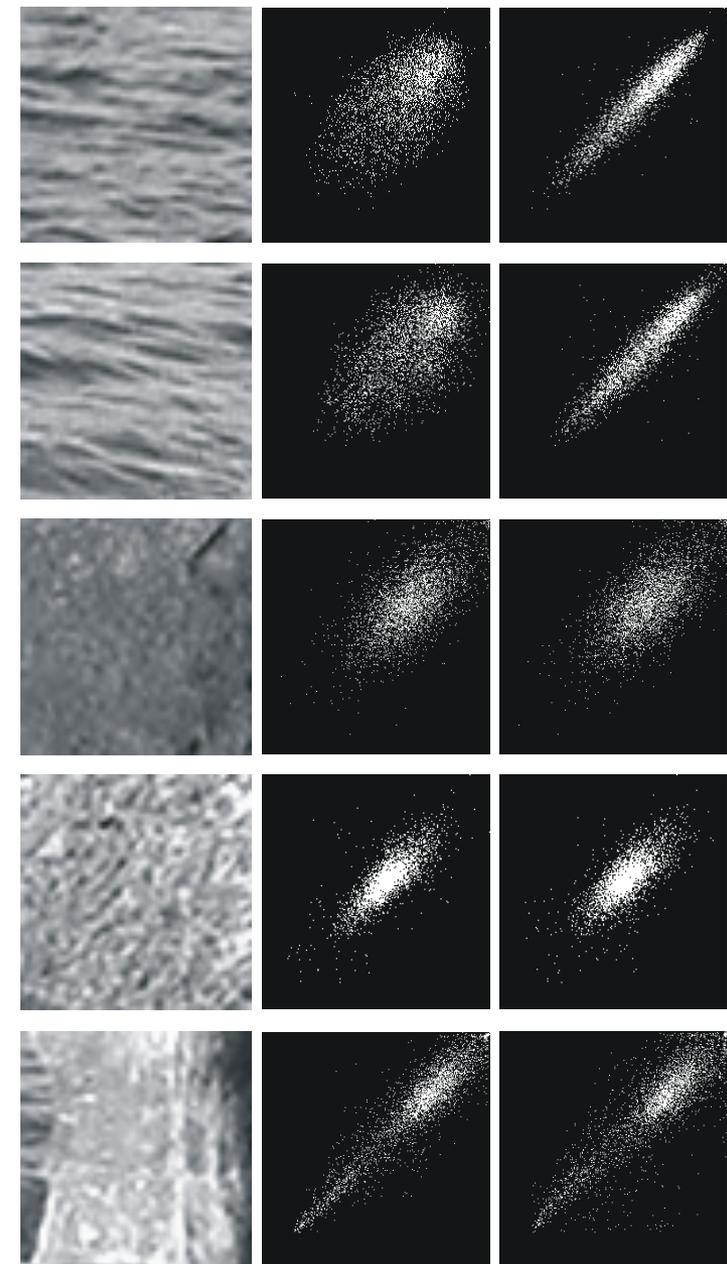
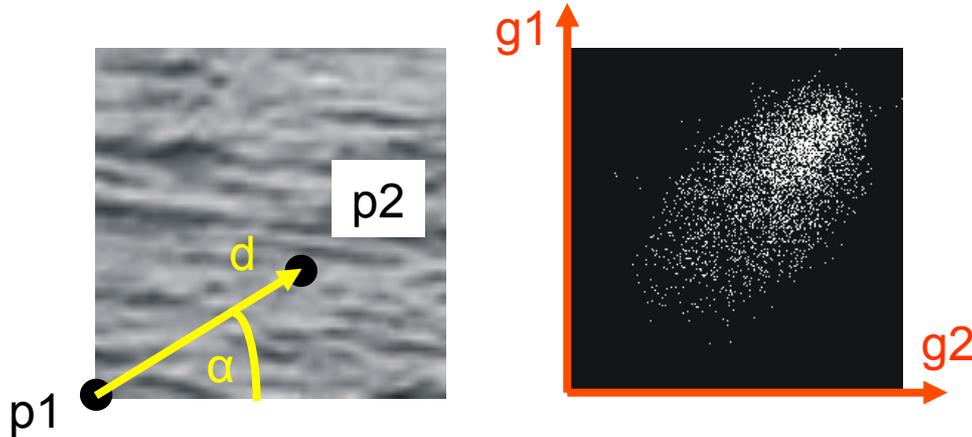
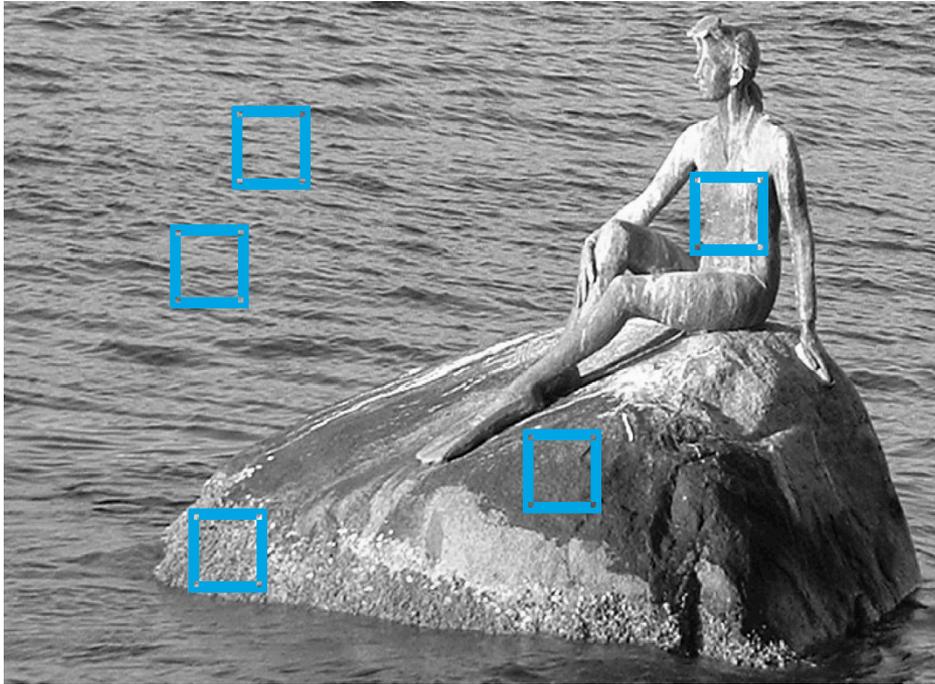


# Haralick'sche Texturmaße

Robert  
Haralick



# Co-Occurrence-Matrix



$d=1, \alpha=90^\circ, \alpha=0^\circ$

# Haralick'sche Texturmaße

zunächst  $P_{\Delta,\alpha}$  normieren:  $P_{\Delta,\alpha} := \frac{1}{s} P_{\Delta,\alpha}$  mit  $s = \sum_{g_1=0}^{K-1} \sum_{g_2=0}^{K-1} P_{\Delta,\alpha}(g_1, g_2)$

Energie / Uniformität  $\sum_{g_1=0}^{K-1} \sum_{g_2=0}^{K-1} P_{\Delta,\alpha}^2(g_1, g_2)$

Kontrast  $\sum_{g_1=0}^{K-1} \sum_{g_2=0}^{K-1} (g_1 - g_2)^2 \cdot P_{\Delta,\alpha}(g_1, g_2)$

Entropie  $-\sum_{g_1=0}^{K-1} \sum_{g_2=0}^{K-1} P_{\Delta,\alpha}(g_1, g_2) \cdot \log_2 [P_{\Delta,\alpha}(g_1, g_2)]$

Homogenität /  
inverse Differenz  $\sum_{g_1=0}^{K-1} \sum_{g_2=0}^{K-1} \frac{P_{\Delta,\alpha}(g_1, g_2)}{1 + |g_1 - g_2|}$

- liefern aussagekräftige Kennwerte für Texturen
- zur Segmentierung
  - Berechnung für  $\Delta = 1$  und  $\alpha = 0^\circ, 45^\circ, 90^\circ, 135^\circ$
  - Merkmalsvektor aus Texturmaßen
  - empfohlene Merkmale zur Texturklassifikation: Entropie, Kontrast, Korrelation

# Haralick'sche Texturmaße (weitere)

zunächst  $P_{\Delta,\alpha}$  normieren:  $P_{\Delta,\alpha} := \frac{1}{s} P_{\Delta,\alpha}$  mit  $s = \sum_{g_1=0}^{K-1} \sum_{g_2=0}^{K-1} P_{\Delta,\alpha}(g_1, g_2)$

$$\text{Korrelation} \quad \sum_{g_1=0}^{K-1} \sum_{g_2=0}^{K-1} \frac{(g_1 - \mu_1) \cdot (g_2 - \mu_2) \cdot P_{\Delta,\alpha}(g_1, g_2)}{\sigma_1 \sigma_2}$$

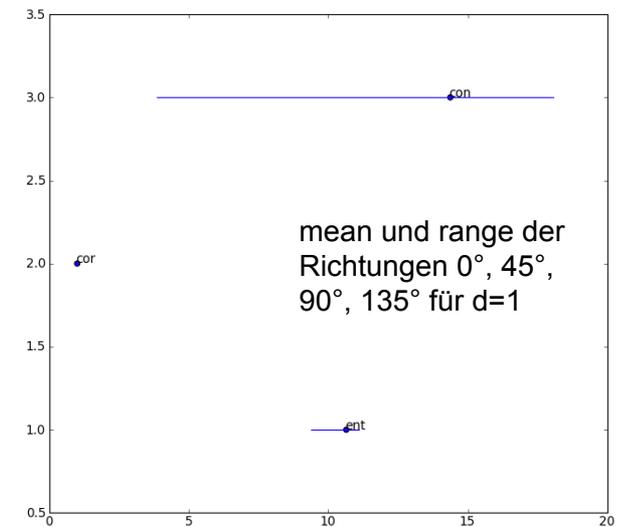
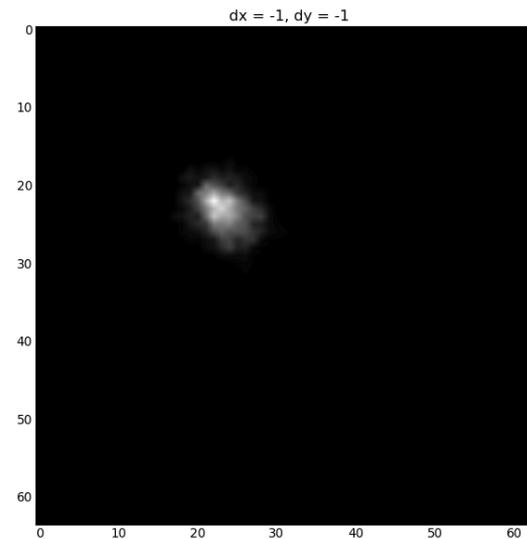
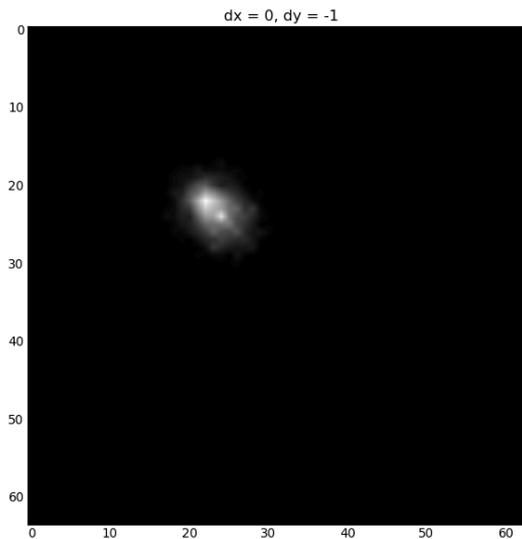
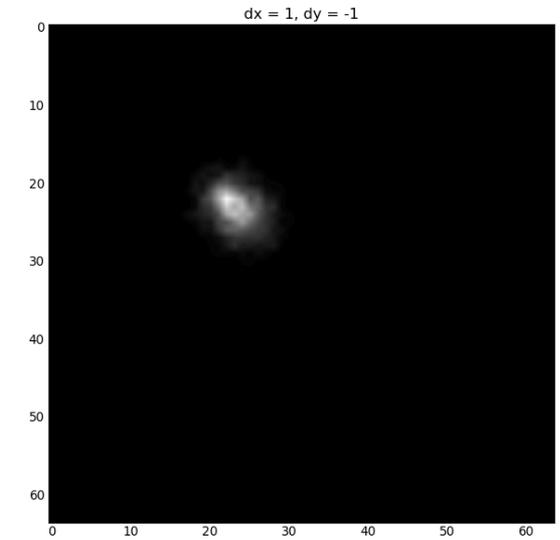
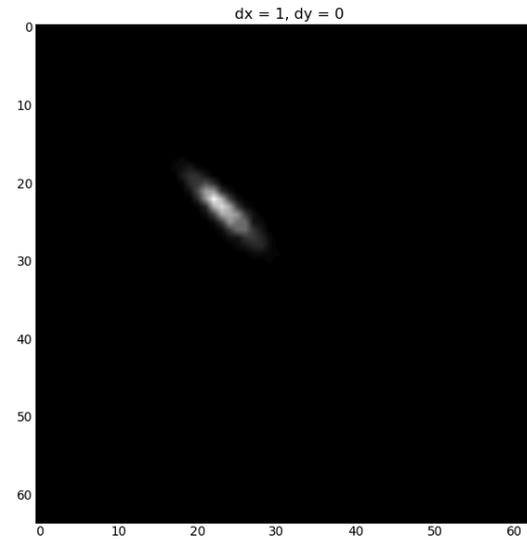
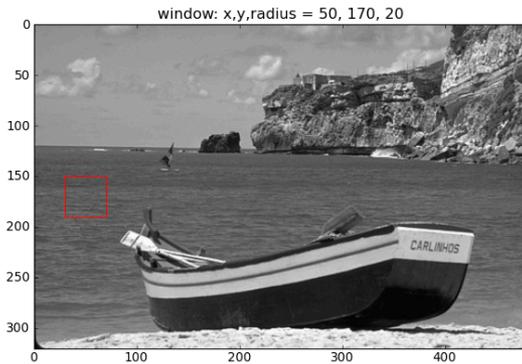
mit

$$\begin{aligned} \mu_1 &= \sum_{g_1=0}^{K-1} g_1 \sum_{g_2=0}^{K-1} P_{\Delta,\alpha}(g_1, g_2) & \sigma_1 &= \sqrt{\sum_{g_1=0}^{K-1} (g_1 - \mu_1)^2 \sum_{g_2=0}^{K-1} P_{\Delta,\alpha}(g_1, g_2)} \\ \mu_2 &= \sum_{g_2=0}^{K-1} g_2 \sum_{g_1=0}^{K-1} P_{\Delta,\alpha}(g_1, g_2) & \sigma_2 &= \sqrt{\sum_{g_2=0}^{K-1} (g_2 - \mu_2)^2 \sum_{g_1=0}^{K-1} P_{\Delta,\alpha}(g_1, g_2)} \end{aligned}$$

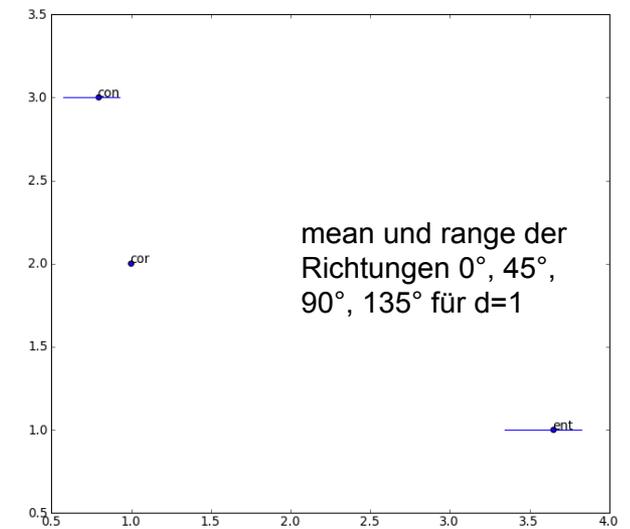
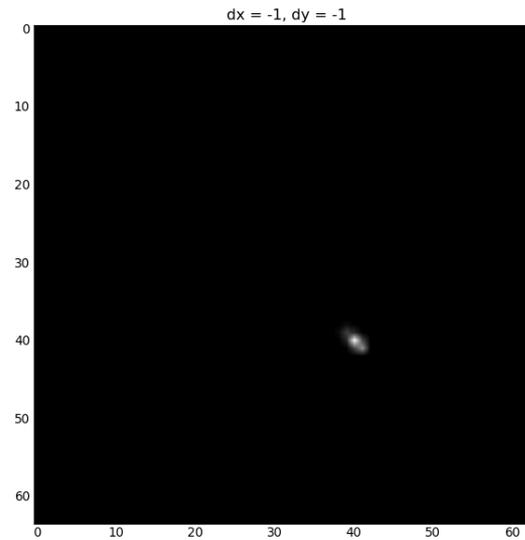
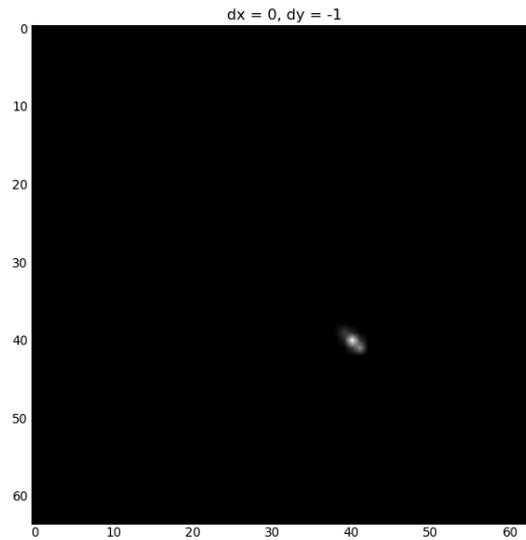
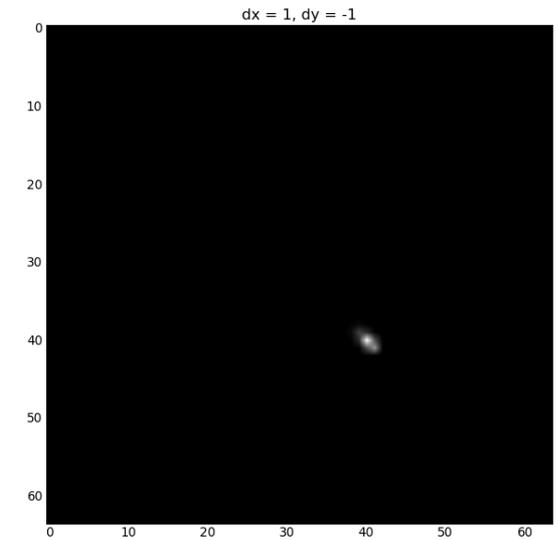
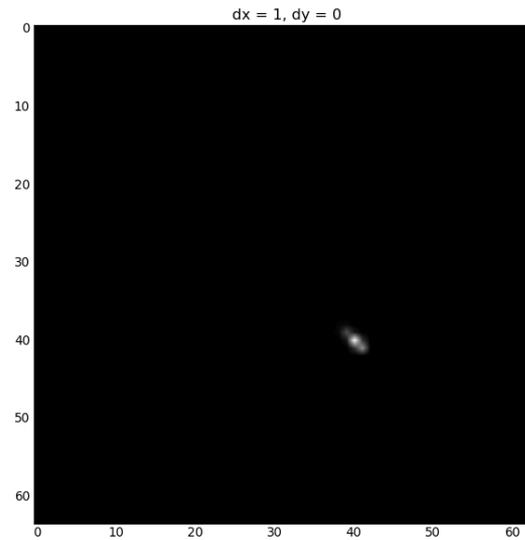
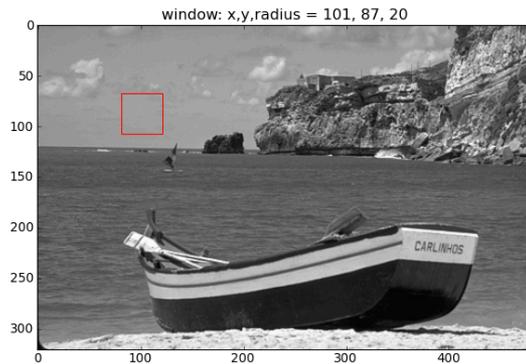
$$\text{inverse difference moment} \quad \sum_{g_1=0}^{K-1} \sum_{g_2=0}^{K-1} \frac{P_{\Delta,\alpha}(g_1, g_2)}{1 + (g_1 - g_2)^2}$$

$$\text{Unähnlichkeit} \quad \sum_{g_1=0}^{K-1} \sum_{g_2=0}^{K-1} P_{\Delta,\alpha}(g_1, g_2) \cdot |g_1 - g_2|$$

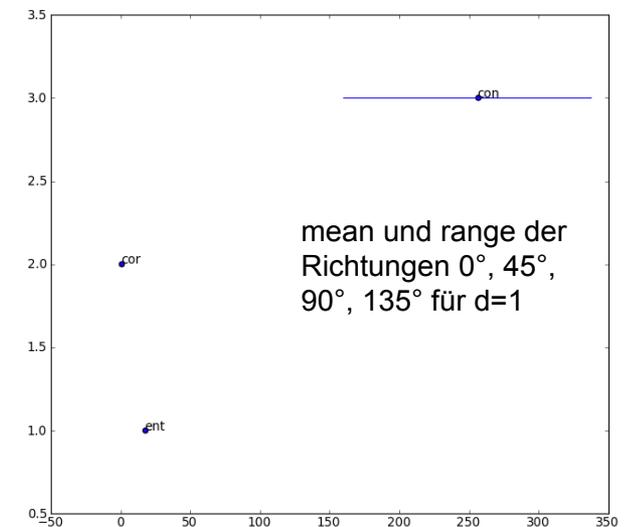
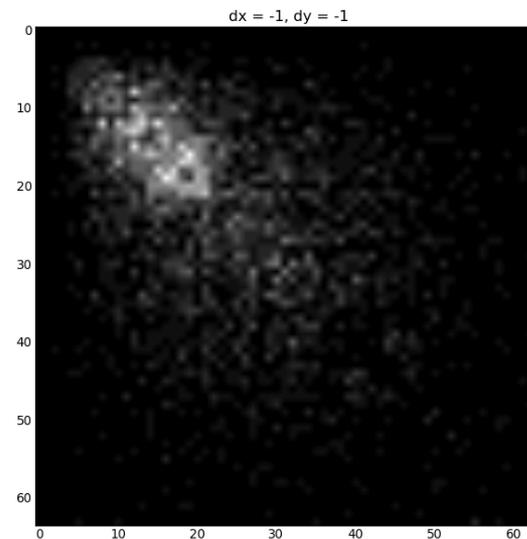
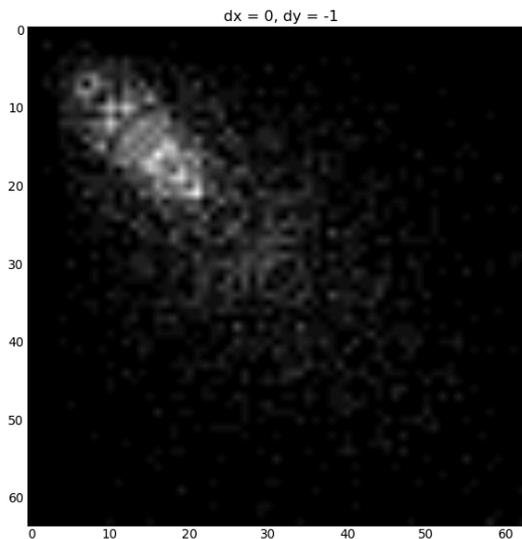
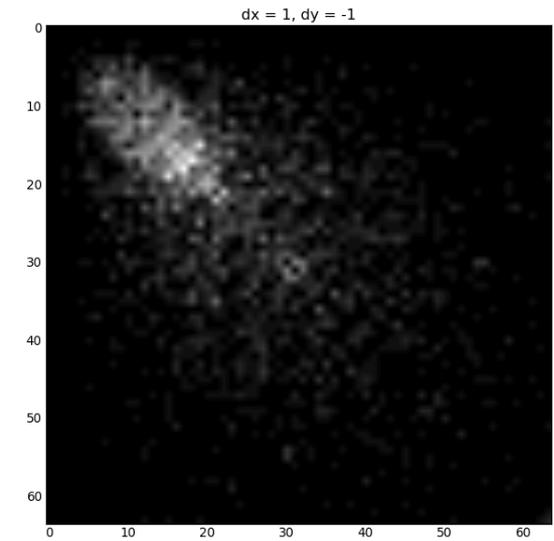
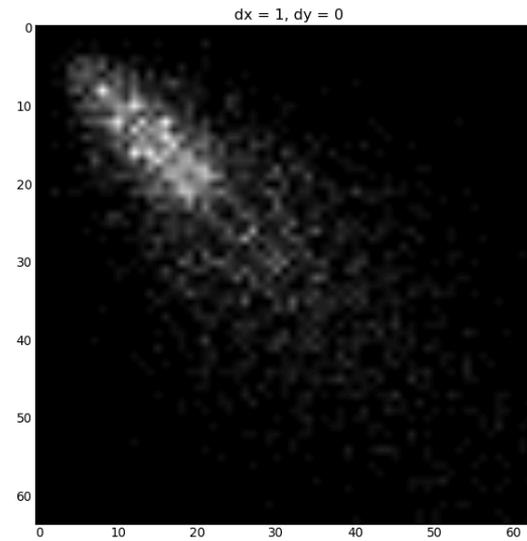
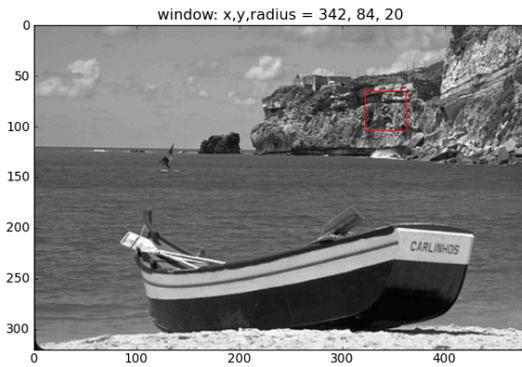
# Co-Occurrence Matrix



# Co-Occurrence Matrix

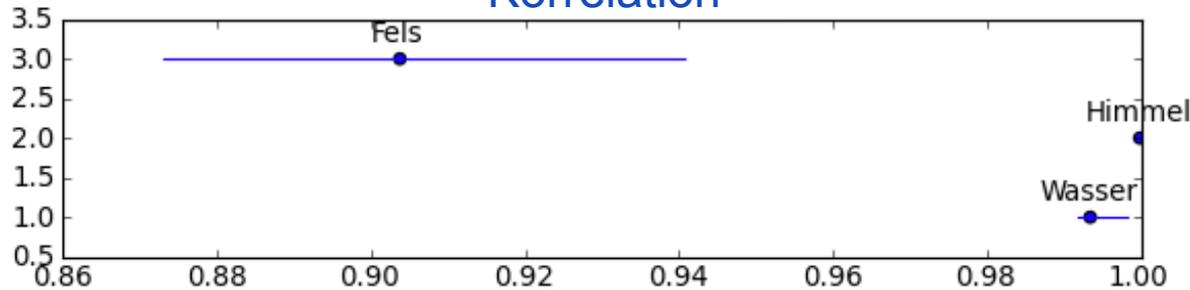


# Co-Occurrence Matrix

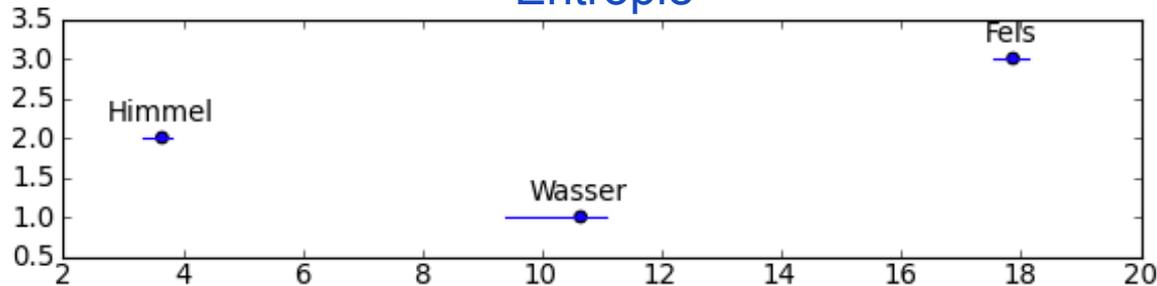


# Korrelation, Entropie, Kontrast

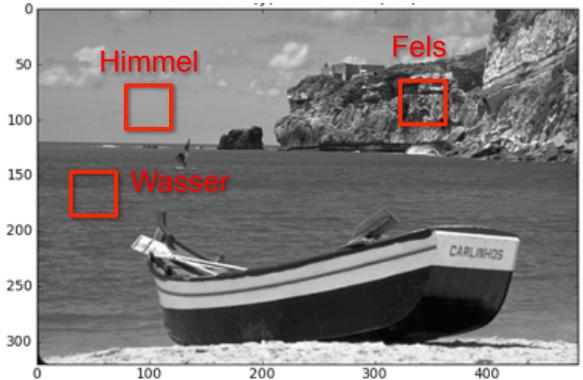
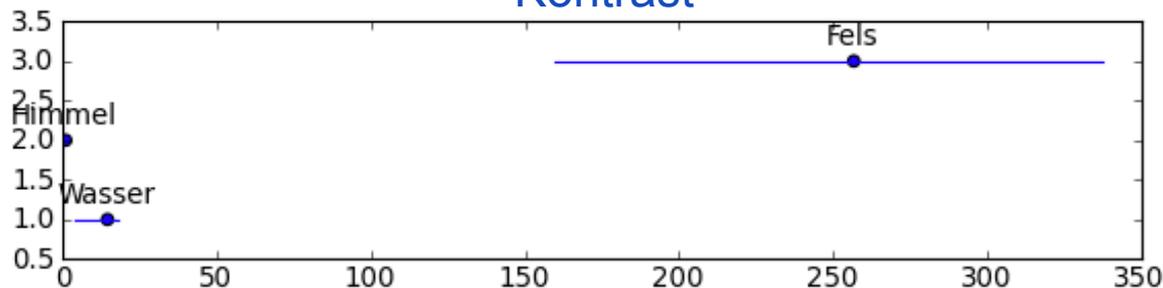
Korrelation



Entropie



Kontrast



mean, min, max berechnet über die Winkel  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$

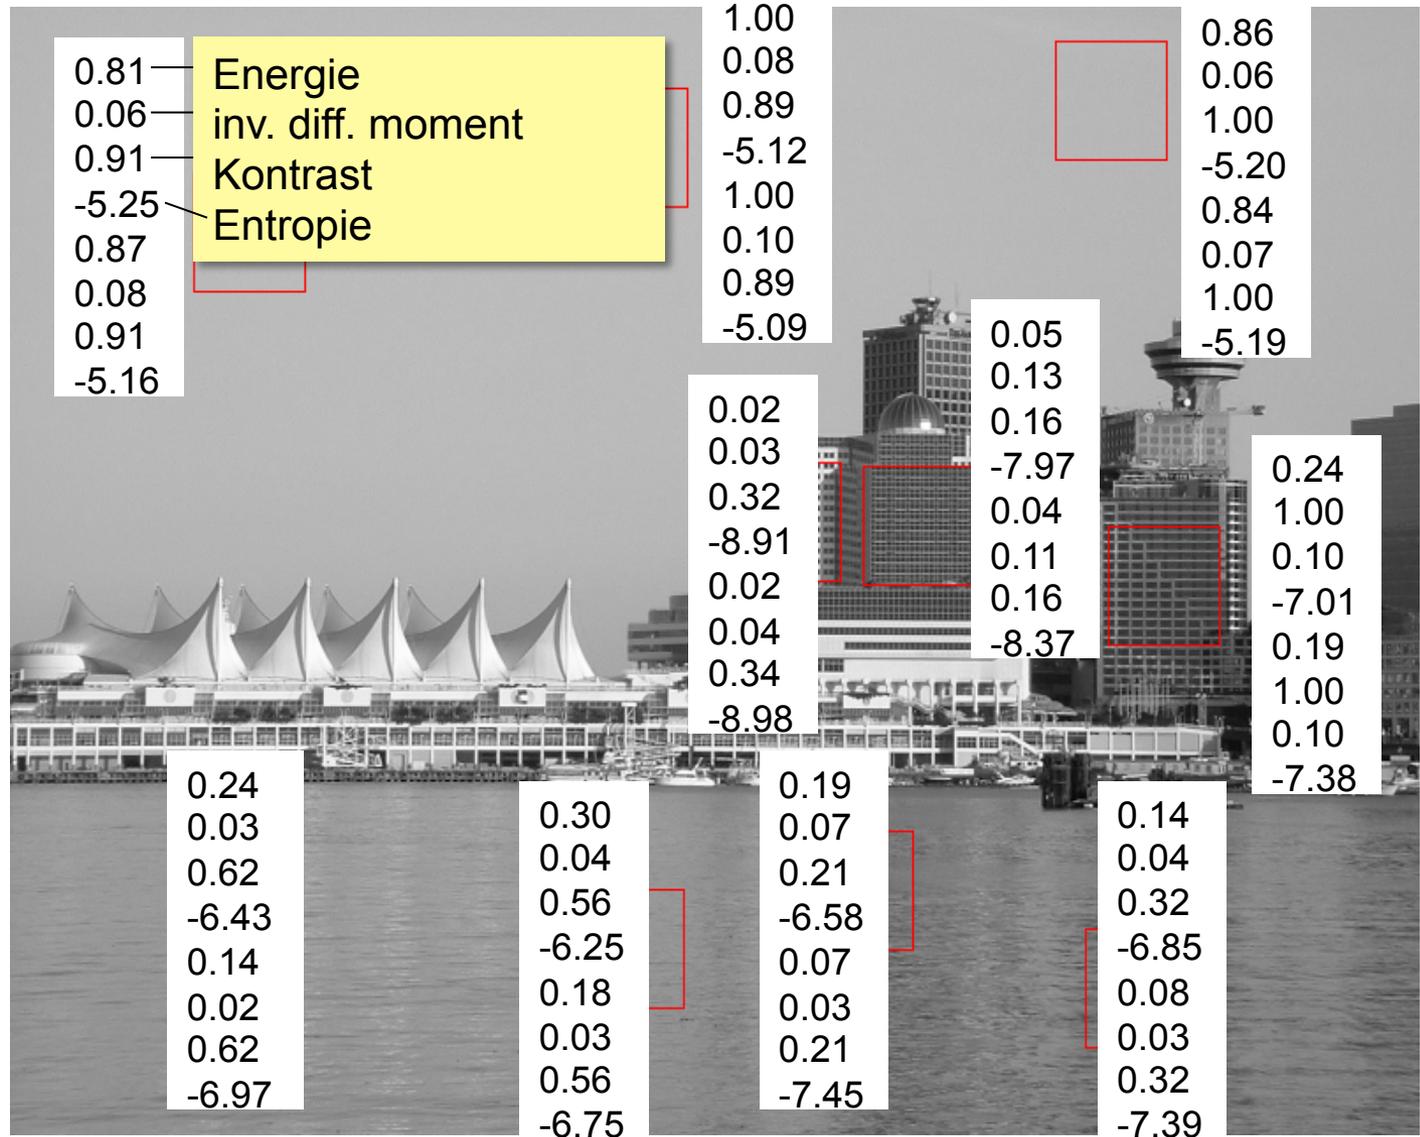
# Zuordnen von Merkmalen zu Klassen

- Methode des geringsten Abstands
- Single Nearest Neighbor
- k Nearest Neighbor (kNN)

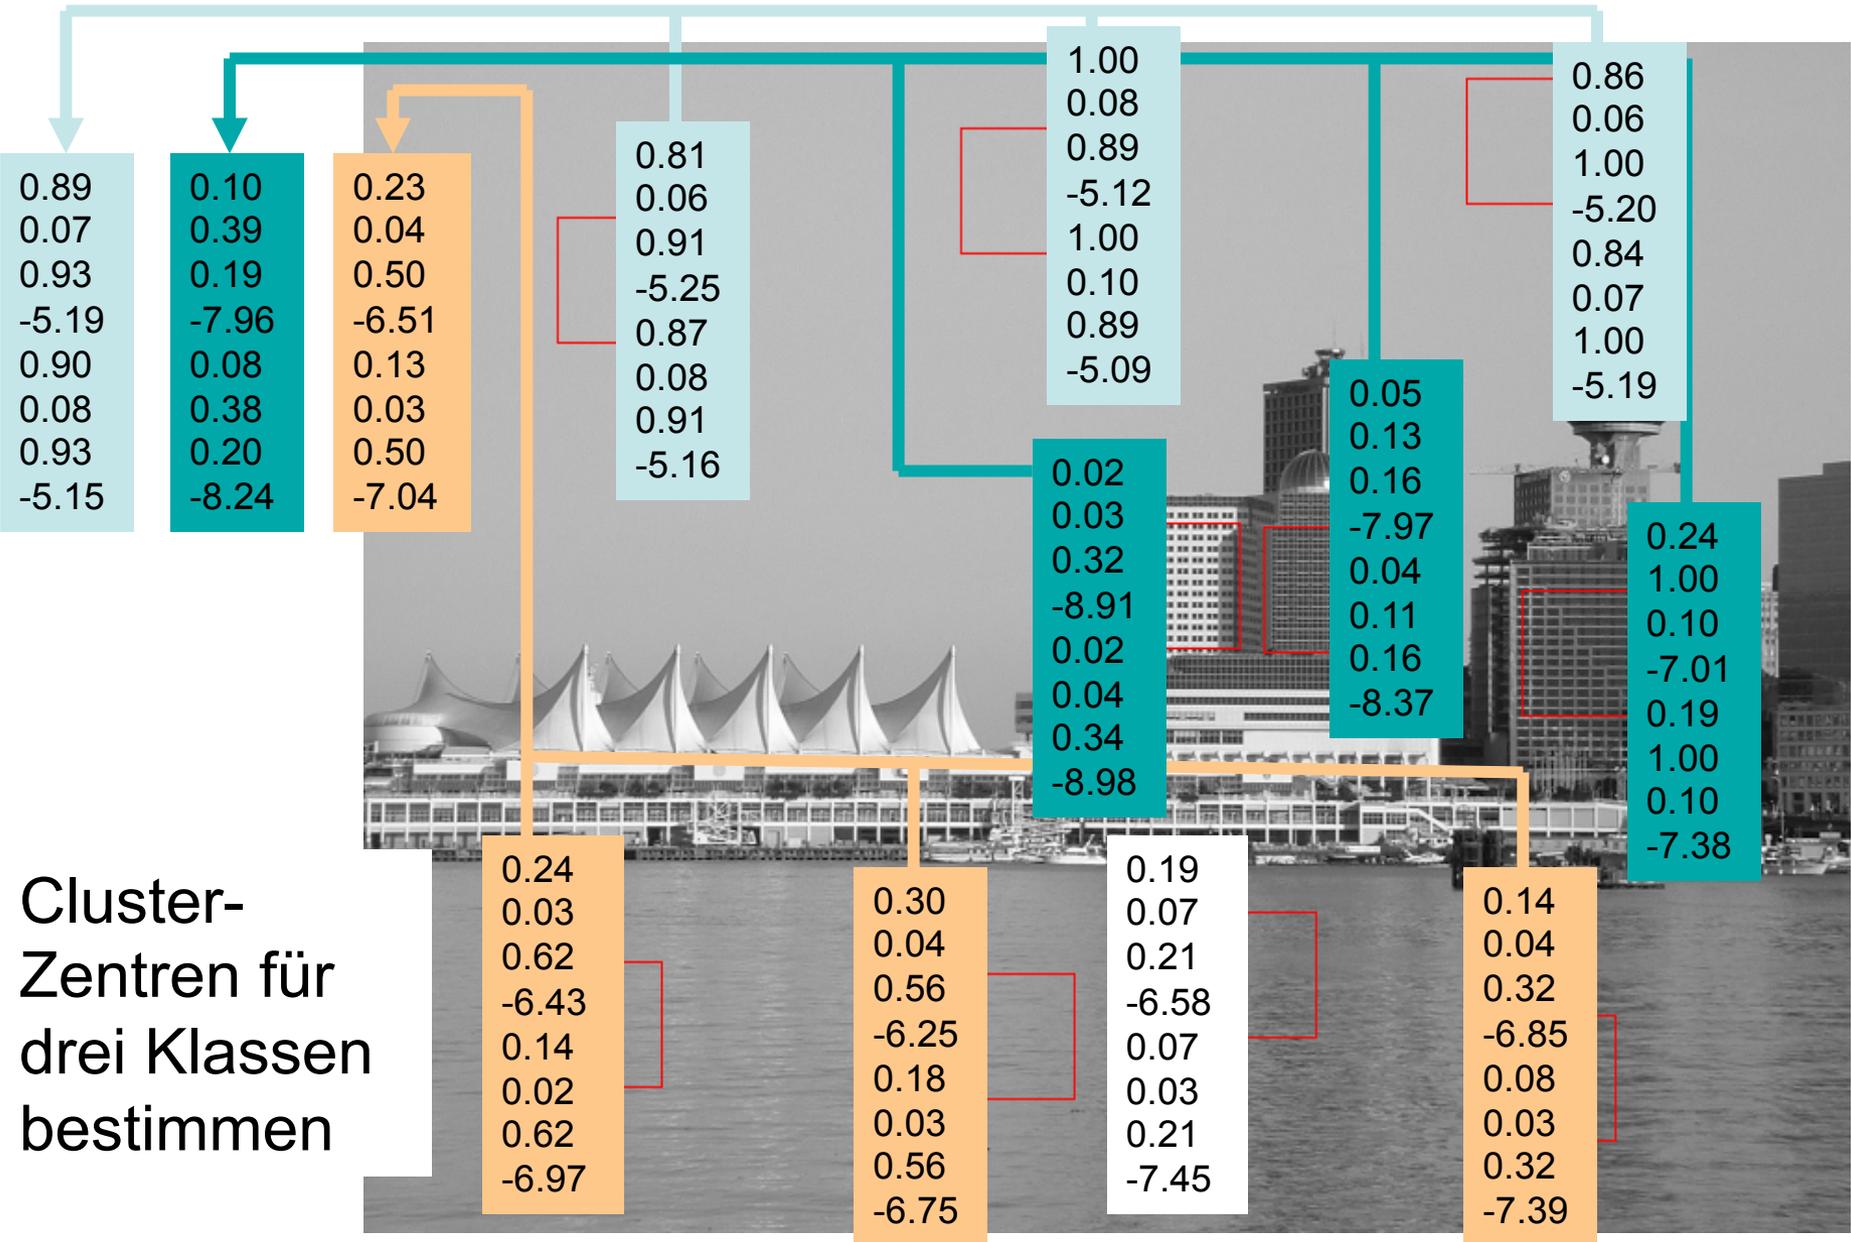
# Methode des geringsten Abstandes

- Für jede der  $n$  Klassen existieren Stichproben
- Aus den Stichproben jeder Klasse wird ein durchschnittlicher Merkmalsvektor der Klasse berechnet (Clusterzentrum)
- Eine unbekannte Stichprobe wird derjenigen Klasse zugeordnet, zu der ihr Abstand am geringsten ist
- Häufige Probleme
  - Anzahl der Stichproben nicht ausreichend
  - Stichproben nicht repräsentativ
  - Unterschiedliche Skalierungen für die Merkmale

# Merkmals- vektoren aus Hara- licksches Textur- maßen



# Cluster-Zentren für drei Klassen bestimmen

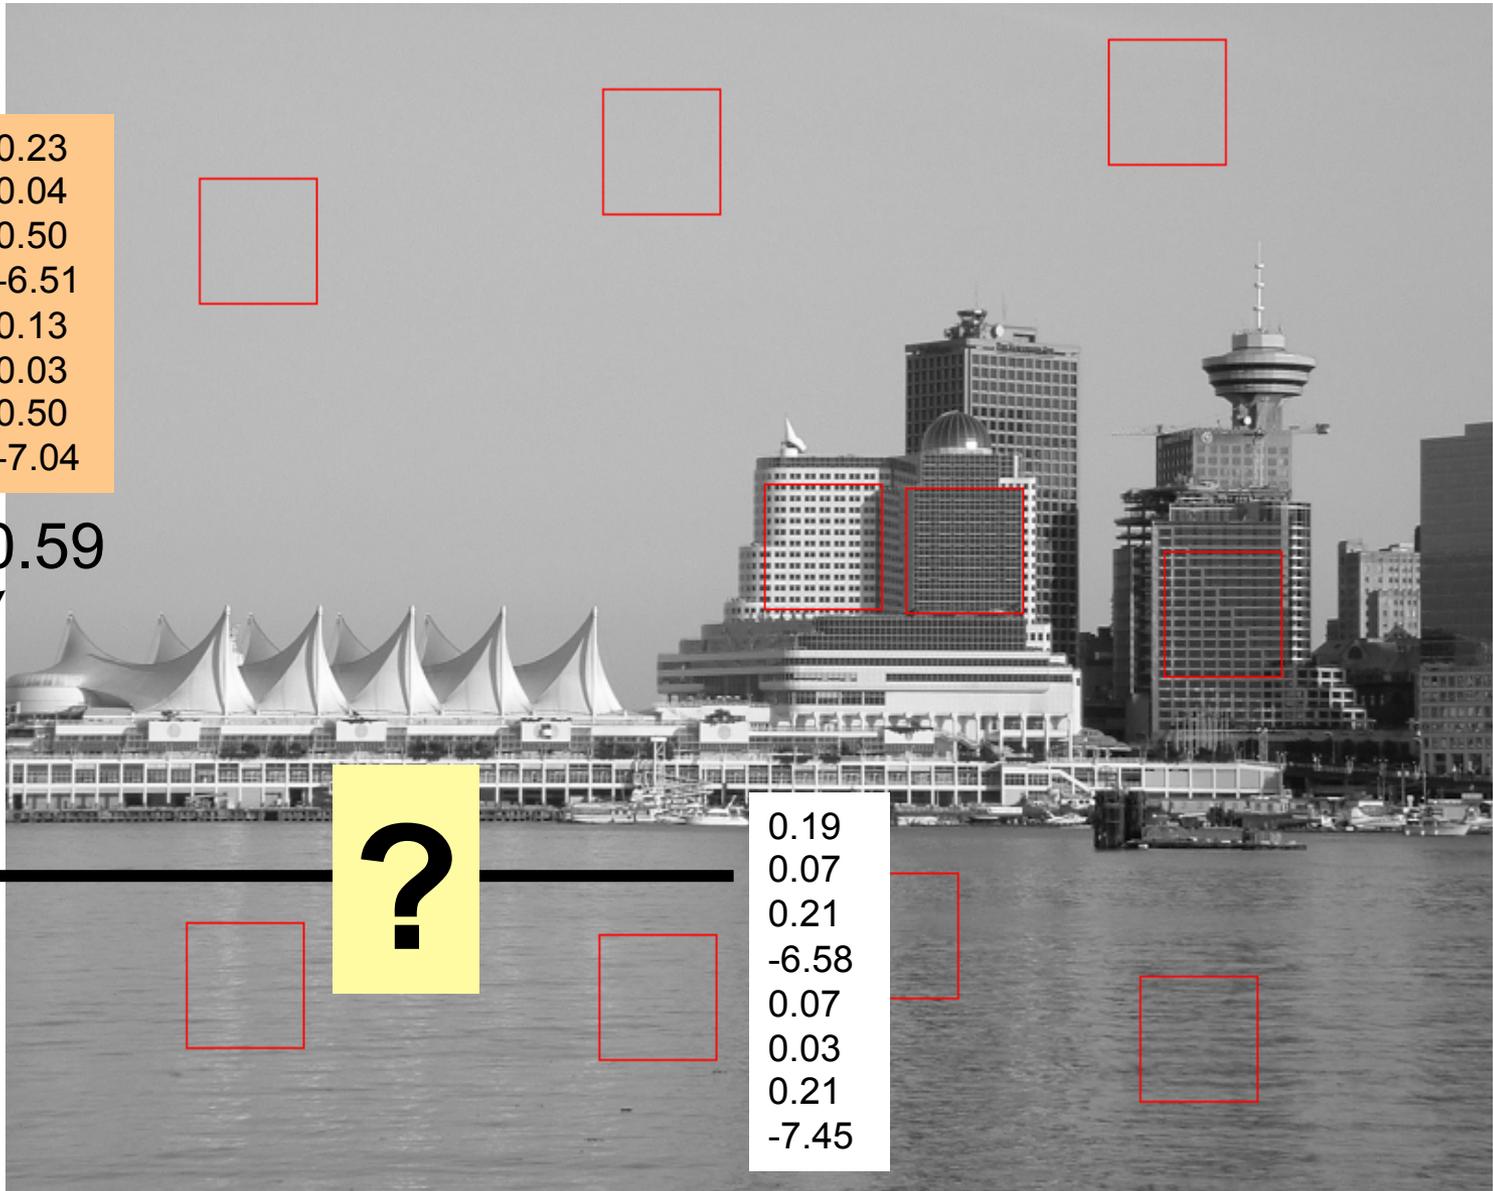


0.89	0.10	0.23
0.07	0.39	0.04
0.93	0.19	0.50
-5.19	-7.96	-6.51
0.90	0.08	0.13
0.08	0.38	0.03
0.93	0.20	0.50
-5.15	-8.24	-7.04

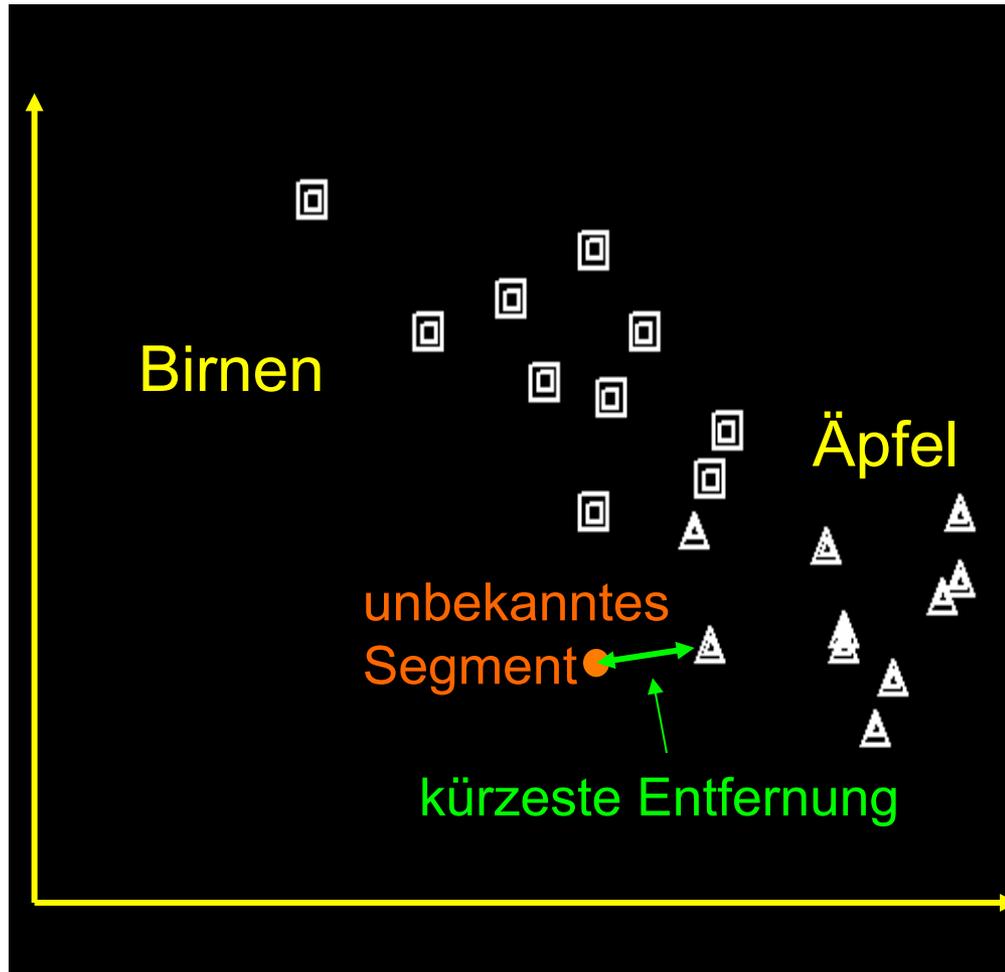
3.07 1.66 0.59

0.19
0.07
0.21
-6.58
0.07
0.03
0.21
-7.45

0.19
0.07
0.21
-6.58
0.07
0.03
0.21
-7.45



# Single Nearest Neighbour



Für die zu bestimmende A-posteriori-Wahrscheinlichkeit wird die Umgebung **gerade so groß** gemacht, dass sie **eine klassifizierte Stichprobe**  $c_k$  umfasst.

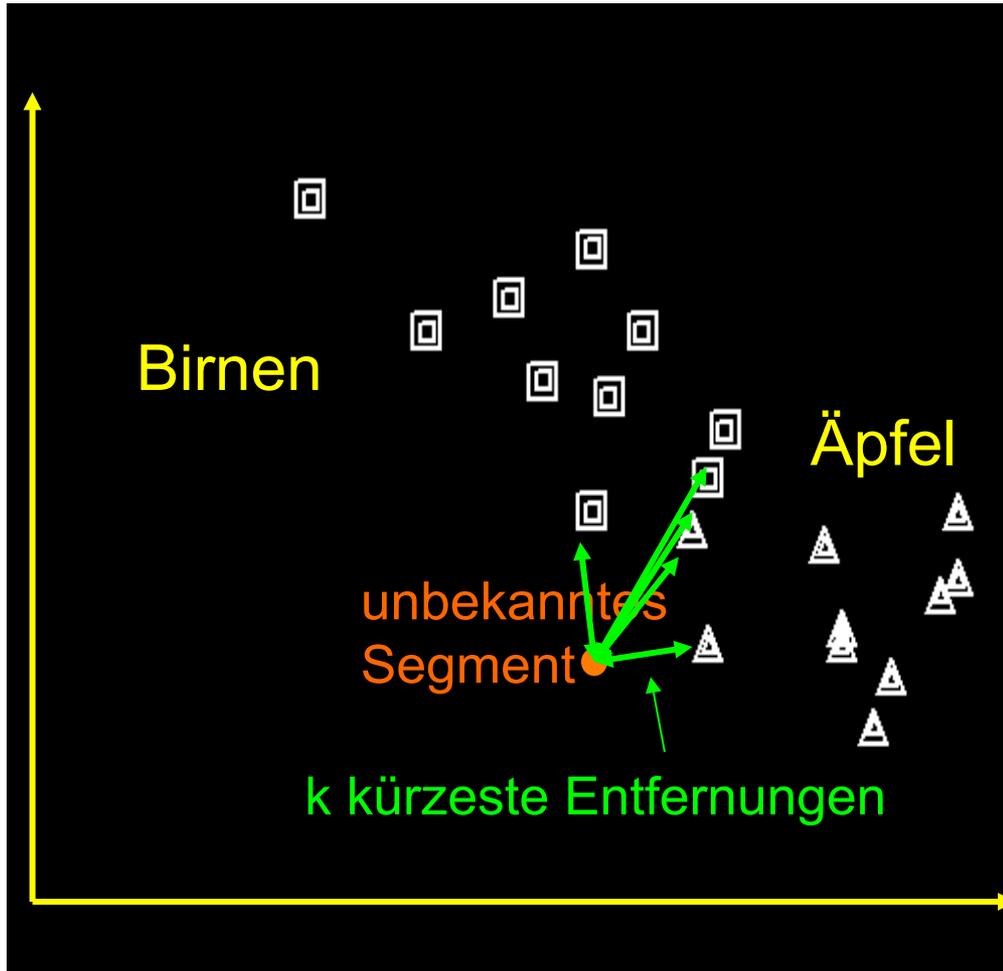
Schätzung von  $P(s=c_i|m(s))$ :

$$P = 1.0 \text{ für } c_i=c_k$$

$$P = 0.0 \text{ sonst}$$

anfällig gegenüber Ausreißern

# k-Nearest-Neighbour (kNN)



Vergrößerung der Umgebung, so dass sie die  $k$  nächsten Nachbarn umfasst.

Schätzung von  $P(s=c_i|m(s))$ :

$$P = k_i/k$$

$k_i$ : Anzahl der Stichproben, die der Klasse  $c_i$  angehören