


Segmentierung


FH OÖ Studiengänge • Hagenberg • Linz • Steyr • Wels



Inhalt



- Segmentierung
 - Definition der Segmentierung
 - Kantenbasierte Segmentierung
 - Regionenbasierte Segmentierung
 - Globaler Schwellenwert (*threshold*)
 - Adaptiver Schwellenwert
 - Region Growing
 - Segmentierung von Farbbildern
 - K-means Clustering




Segmentierung



■ Definition

- Bild: Gesamtheit der Grauwerte der einzelnen Pixel
- Jedes Pixel steht für sich
- Segmentierung
- Die Pixel werden zu Gruppen (Objekten) zusammengefasst
- Objekte nach verschiedenen Merkmalen charakterisiert
 - Grauwert, Form, Intensitätsübergang, Nachbarschaft ...
- Segmentierung definiert *Semantik* im Bild



Segmentierung



■ Objekte

- Ein Pixel kann nur einem Objekt zugeordnet werden


$$I = \{x_1, x_2, \dots, x_N\} = \{x\}_{N} \quad N = \text{Anzahl der Pixel}$$

$$O_j = \{x\}_{N_j} \quad N = \text{Anzahl der Pixel im Objekt } J$$

$$O_i \cap O_j = \{\} \quad i \neq j$$

- Vollständige Segmentierung, jedes Pixel ist einem Objekt zugeordnet


$$O_1 \cup O_2 \cup \dots \cup O_M = I \quad M = \text{Anzahl der Objekte}$$



Segmentierung von linearen Strukturen



- Erkennen von :
 - Punkten
 - Linien
 - Kanten
- zweistufiger Prozeß
 - Verstärkung der Features, z B. Kantenverstärkung
 - Auswahl „geeigneter“ Features




Punktdetektion



-1	-1	-1
-1	8	-1
-1	-1	-1



- Summe der Maskenelemente = 0
- Maskenoperation auf Bild zum Hervorheben punktförmiger Objekte
- Operation ergibt in homogener Fläche den Wert 0
- Schwellenwertoperation zur Auswahl der Punkte



Punktdetektion




- Schritt 1: Binärisierung des Grauwertbildes




Punktdetektion



- Schritt 2: Maskenoperation
- Schritt 3: Schwellenwertbildung






Liniendetektion



-1	-1	-1	-1	2	-1	-1	-1	-1	2
2	2	2	-1	2	-1	-1	2	-1	-1
-1	-1	-1	-1	2	-1	-1	-1	2	-1

- 4 verschiedene Masken
- Masken für horizontale, vertikale, schräge Linien
- Optimal für Linien der Breite 1 Pixel




Segmentierung



- Kanten
 - Kanten geben maßgebliche Information zur Definition von Objekten
 - Abgrenzung eines Objekts zum Hintergrund
 - Intensitätsänderung
 - Gradientenoperator, Bestimmung zweier Parameter: Größe und Richtung



$$|\vec{g}| \quad \vartheta = \arccos\left(\frac{g_x}{|\vec{g}|}\right)$$

- Suche in Umgebung ob Kanten ähnlicher Stärke und Richtung vorhanden sind.
- Zusammenführung mehrerer Kanten in einem Bild



Wendepunkt zur Kantendefinition

- Kante als Intensitätsänderung
- Kontinuierlicher Übergang der Grauwerte auf mehrere Pixel verteilt
- Wendepunkt definiert Kante
 - Wendepunkt=Extremalwert der Steigung
 - 2. Ableitung = Null




Laplacian of Gaussian (LoG)

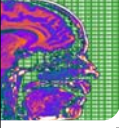
- Gradientenoperatoren verstärken Rauschen
- Glättung vor der dem Kantenoperator
- Zusammenfassung von Glättung und Laplaceoperator
 - Geschwindigkeitsvorteil

$$(img * g) * laplace = img * (g * laplace)$$


$$LoG(x, y) = \frac{1}{\pi\sigma^4} e^{-\frac{x^2+y^2}{2\sigma^2}} \left(\frac{x^2+y^2}{2\sigma^2} - 1 \right)$$

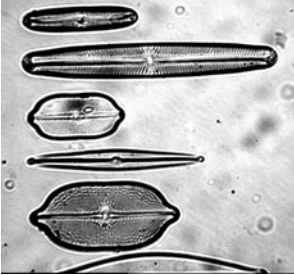
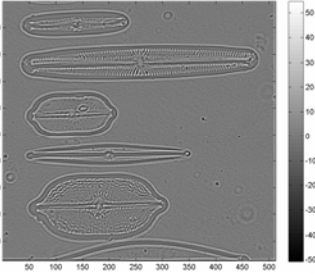


Mexican hat



Beispiel



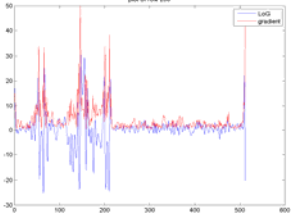



Durch Wahl von σ kann der Detailgrad der Kontur bestimmt werden

a	b
b	c

(a) Original, (b) LoG mit $\sigma=1$

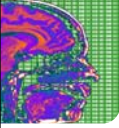
(c) LoG(blau) vs. Gradient (rot)




FH-Campus Hagenberg

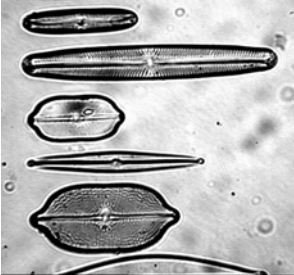
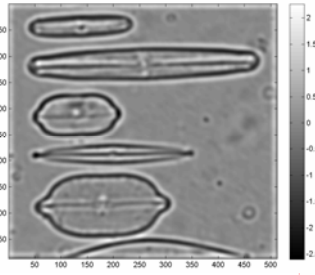
Werner Backfrieder

Folie 13



Beispiel



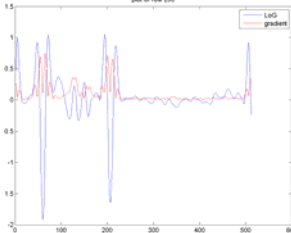



Ein größerer Wert σ unterdrückt die Feinstruktur und betont große Kanten

a	b
b	c

(a) Original, (b) LoG mit $\sigma=5$


(c) LoG(blau) vs. Gradient (rot)



FH-Campus Hagenberg


Werner Backfrieder

Folie 14




Regionen-basierte Segmentierung


- Regionen – ausgedehnte Strukturen
 - Region: zusammenhängender Bildbereich
 - Zusammenfassung zu Regionen aufgrund gemeinsamer Merkmale
 - ähnlicher Grauwert oder Farbe
 - Grauwertverteilung, Einfluss der Statistik
 - Nachbarschaftsrelationen
 - gemeinsames Muster (Textur)
 - im Allgemeinen mehrere Regionen (Objekte) in einem Bild
 - Vereinfachung: Unterscheidung eines Objektes vom Hintergrund



Schwellenwertbildung

- Globaler Threshold
 - *a priori* festgelegter Wert
 - Unterscheidung zwischen *Objekt* und *Hintergrund*
- $$f(x) = \begin{cases} 1 & g(x) > T \\ 0 & g(x) \leq T \end{cases} \quad \begin{array}{l} g \dots \text{Grauwertbild} \\ f \dots \text{Binärbild} \end{array}$$
- Problem: T global, veränderlicher Kontrast Vorder/-Hintergrund, Wahl von T
 - Konsequenz: falsche Zuordnungen







Schwellenwert



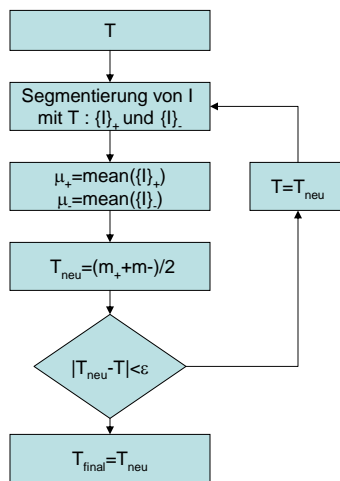
- *data-driven* threshold
 - *a priori* Wahl ist unflexibel
 - **data-driven**
 - einfacher Ansatz $(max-min)/2$
 - Problem: Ausreißer
 - threshold aufgrund der Häufigkeitsverteilung (Histogramme)
 - optimierte Wahl existiert für **bi-modale** Histogramme
 - bi-modales Histogramm: im Wesentlichen existieren zwei Strukturen im Bild (Objekt und Hintergrund)



optimal threshold



Algorithmus



a-priori threshold


Segmentieren des Bildes

Mittelwertbildung aus den Regionen

Berechnung des neuen thresholds

Abbruchkriterium
Wiederholung mit T_{neu}

optimaler threshold

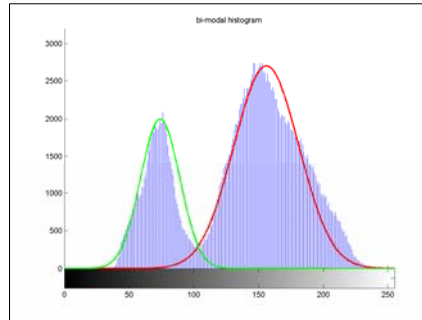


optimal threshold



■ Diskussion


- Modell: bimodales Histogramm
- Modellierung durch Gauß-Verteilung
- Minimierung falscher Zuordnung



FH-Campus Hagenberg

Werner Backfrieder

Folie 19



adaptive threshold



■ Veränderlicher Kontrast


- Beleuchtung nicht konstant
- Grauwertverhältnis Objekt /Hintergrund nicht konstant
- globaler Schwellenwert nicht suffizient
- Grund: Histogramm nicht bi-modal



FH-Campus Hagenberg


Werner Backfrieder

Folie 20



adaptive threshold


- Unterteilung des Bildes in Subregionen
 - eingeschränkter Bildregion
 - lokale Änderungen „konstant“
 - bi-modales Histogramm => optimal thresholding möglich




FH-Campus Hagenberg

Werner Backfrieder

Folie 21




adaptive threshold



FH-Campus Hagenberg

Werner Backfrieder

Folie 22




adaptive threshold



■ Diskussion


- Zellen der Unterteilung zu klein
- mono-modales Histogramm
- willkürliche Unterscheidung
- Kriterium: Histogramm ob bi-modal; z.B. Varianz



FH-Campus Hagenberg

Werner Backfrieder

Folie 23



region growing (flood fill)




- Schwellenwertoperation in Kombination mit Nachbarschaftsrelationen
- Ausgehend von einem „seed point“ wird die maximale zusammenhängende Region bestimmt.
- Die Region besteht aus allen Pixeln des Bildes, für die ein Pfad zum *seed point* existiert.
- Methode
 1. *Seed point* auswählen
 2. Intensitätsintervall festlegen
 3. Ausgehend vom *seed point* iterative Abfrage aller Nachbarpixel ob Sie im Wertebereich liegen.
 4. **Ja:** Pixel selektieren und Algorithmus in Punkt 3 fortsetzen


FH-Campus Hagenberg

Werner Backfrieder


Folie 24




Region Growing



Seedpoint



Reihenfolge der Abfrage der Nachbarpixel




Rekursive Implementierung



```
grow(g, m, x, D)
begin
  g(x) = label ed
  if g(x1) in D then grow(g, m, x1, D);
  if g(x2) in D then grow(g, m, x2, D);
  if g(x3) in D then grow(g, m, x3, D);
  if g(x4) in D then grow(g, m, x4, D);
  m(x) = 1;
end
```

g=Bild, m=Maske, x=seed point, x_i=Nachbarn, D=Wertebereich




Segmentierung von Farbbilder



■ Problem in 3D


- „Einfarbige“ Objekte besitzen ähnliche Farbwerte.
- Jedes Pixel hat 3 Farbwerte (r, g, b).
- Repräsentation im Farbraum
- Bild ist 3D Struktur
- Segmentierung bedeutet Klassifizierung der Punkte im Farbraum



FH-Campus Hagenberg

Werner Backfrieder

Folie 27




Segmentierung von Farbbilder



■ Region -> Cluster


- Regionen im Farbbild werden auf bestimmte Teile des RGB-Plots abgebildet
- z.B. Nase auf rote Punkte im Plot
- Objekte bilden Cluster
- Segmentierung: Clusteranalyse im RGB-Raum



FH-Campus Hagenberg


Werner Backfrieder

Folie 28




Clusteranalyse

- Gruppierung der Daten
 - Basis mehrdimensionale Daten
 - Inhärente Merkmale
 - Abstände (Metrik)
- Hierarchische Methoden
 - Stammbäume
- Partitionierende Methoden
 - NN, k-means
- Kein „bester“ Algorithmus (Trial & Error)




Problemstellung



Einteilung der Datenpunkte in Gruppen

Kriterium: Abstand




k-Means Clustering



- Grundsätzliche Annahmen
 - Anzahl der Cluster ist vordefiniert
 - Klassifizierung:
 - Gesamtabstand aller Punkte zu den Zentroiden soll minimal sein
- Bedingungen
 - Jeder Cluster enthält mindestens 1 Element
 - Jedes Element muss einem Cluster zugeordnet sein
 - Cluster werden durch die Zentroiden beschrieben

$$c_j = \frac{1}{N_j} \sum_{i=1}^{N_j} x_{ji}$$

j -te Komponente des Zentroiden
 N_j Anzahl der Punkte im Cluster
 x_{ji} Koordinate des i -ten Punktes in Richtung j




Klassifizierung



- Definitionen
 - **Dichte eines Clusters**
 - Summe der Abstände aller Punkte die einem Cluster zugeordnet sind vom Zentroiden des Clusters
 - **Gesamtdichte**
 - Summe der Dichten aller Cluster

k-means -> minimiert in einem iterativen Verfahren die Gesamtdichte




Iterativer Ansatz



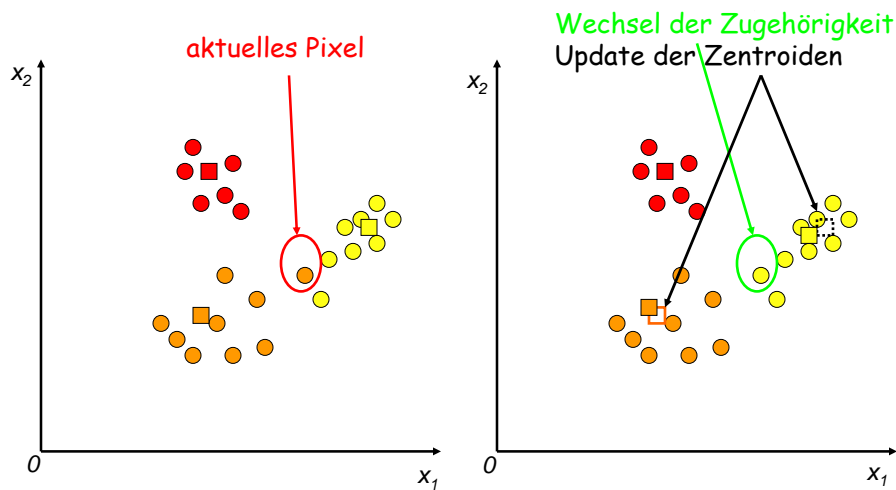
- Algorithmus
 - Auswahl von k Zentroiden
 - Anzahl k wird vorgegeben
 - *a-priori* Klassifizierung in k Cluster
 - sequentielle Abfrage welcher Zentroid am nächsten ist
 - Neuberechnung der Zentroiden


- Iteration: Testen aller Punkte
- Abfrage für jeden Punkt: Ist anderer Zentroid näher?
 - Wechsel des Clusters, Update der beiden Zentroiden

- Abbruchkriterium wenn minimale Änderungen der Zuordnungen innerhalb einer Iteration

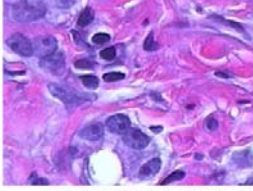


Cluster-Update





k-means Clustering, Resultate



H&E image

Image courtesy of Alan Patin, Johns Hopkins University

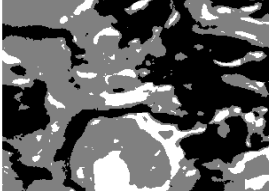
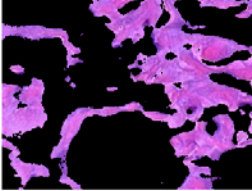


image labeled by cluster index

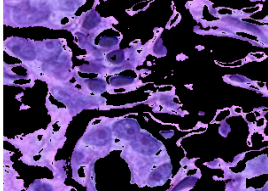
Segmentierung der Farbkomponente (U,V)

2 Cluster

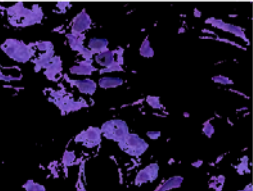
Weitere Segmentierung von cluster 2 -> Kerne (hierarchisch)



objects in cluster 1




objects in cluster 2



blue nuclei

FH-Campus Hagenberg
Werner Backfrieder
Folie 35



Diskussion

- Schneller, stabiler Algorithmus
- Gutes Konvergenzverhalten
- Effiziente Neuberechnung der Zentroiden

$$\bar{c}_k = \frac{1}{N_k} \sum_{j=1}^{N_k} \bar{x}_j :$$

$$\bar{c}_m^{neu} = \frac{(\bar{c}_m N_m - \bar{x}_l)}{(N_m - 1)} \quad \bar{c}_n^{neu} = \frac{(\bar{c}_n N_n + \bar{x}_l)}{(N_n + 1)}$$

- Keine „leeren“ Cluster können entstehen
- Probleme nur wenn Cluster a-priori leer ist!

FH-Campus Hagenberg
Werner Backfrieder
Folie 36