

Segmentierung

Aufteilung von Bildern
in zusammenhängende homogene Bereiche

Wolfgang Heiden © 2014-22, mit Beiträgen von R. Herpers, F. Mannuß, B. Kahl, G. Heisenberg

Wolfgang Heiden © 2014-22 wolfgang.heiden@fh-bonn-rhein.sieg.de

-- auf der Grundlage einer Lehrveranstaltung von Prof. Dr. Rainer Herpers sowie Folien
von Florian Mannuß 2011, Dr. Björn Kahl 2012, Prof. Dr. G. Heisenberg, 2013 --

Fachbereich Informatik (Dpt. Computer Science)


Hochschule Bonn-Rhein-Sieg – University of Applied Sciences,

53754 Sankt Augustin

Germany

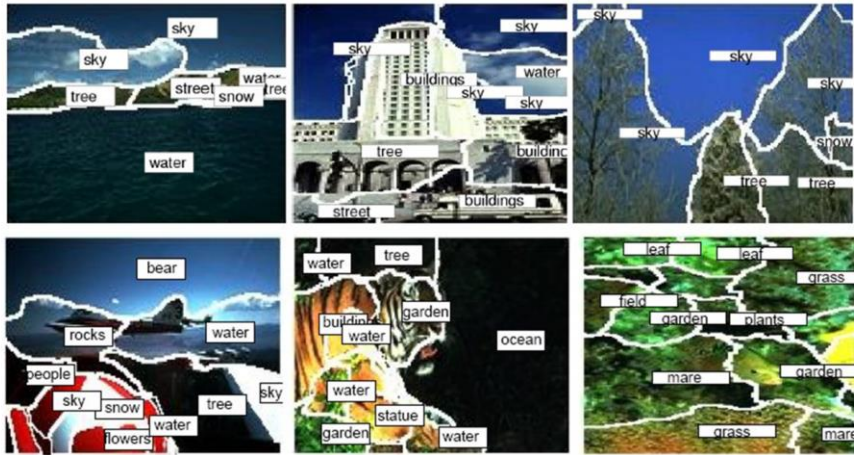
Wiederholung: Probleme bei Skelettierung

- **Bildrauschen**
(variiert zwischen
verschiedenen
Algorithmen)
- Qualität der **Segmentierung**
ausschlaggebend



Wie sich bereits bei der Skelettierung gezeigt hat, kann die Qualität einer vorherigen Segmentierung sich maßgeblich auf weitere Bildverarbeitungsschritte auswirken.

Bildanalyse




From: Object
Recognition
as Machine
Translation,
Duygulu,
Barnard, de
Freitas,
Forsyth,
ECCV02

Die Segmentierung von Bildern ist eine essenzielle Voraussetzung für die spätere Identifikation von Bildobjekten. (Zumindest gilt das für die „klassische“ Bildverarbeitung. Moderne Deep-Learning-Ansätze arbeiten anders, sind aber dafür i.d.R. nicht nachvollziehbar.)


Die Beispiele zeigen deutlich, dass manche Bildelemente korrekt identifiziert werden, andere dagegen total falsch gedeutet werden.

Aufgabe: Trennung von Vorder- und Hintergrund



Die erste und wichtigste Aufgabe einer Bildsegmentierung ist oft die Trennung von (wichtigen) Objekten und (unwichtigem) Hintergrund.

Segmentierung: Trennung von verschiedenen, in sich homogenen, Bildbereichen



Typische Segmentierungsverfahren trennen Bildkomponenten ausschließlich nach Homogenitätskriterien. Semantische Aspekte spielen dabei keine Rolle.

- **Segmentierung =**
Aufteilung/Gruppierung von Bildelementen auf der Grundlage eines **Homogenitätskriteriums**
- **Homogenität**
 - Zusammengehörige Merkmale (**Cluster**) identifizieren oder
 - nach Grenzen bzw. **Diskontinuitäten** suchen
- **Datenreduktion**
 - kompakte Repräsentation interessanter Bilddaten als Sammlung von Merkmalen
 - Uninteressante Bilddaten können entfernt oder stärker komprimiert werden.

- **Merkmale (Tokens)** sind alles, was man zur Gruppierung heranziehen kann, z.B.:
 - Pixel (Ecken, Linien/Kanten, etc.)
 - größere Regionen mit einheitlicher Farbe und/oder Textur
 - diskrete Objekte und deren Dichte (z.B. Blutkörperchen, Zellen einer bestimmten Art, etc.)
- Ansätze zur **Zusammengehörigkeit**
 - **Top down**
 - Lage auf dem selben Objekt
 - **Bottom up**
 - lokale Kohärenzen
 - Beide Ansätze schließen einander nicht gegenseitig aus.

Vorder-/Hintergrund via Top-down vs. Bottom-Up



Was wäre hier sinnvoll
und warum ?

Das surrealistische Bildbeispiel illustriert die Problematik, Vorder- und Hintergrund in einem Bild zu unterscheiden. An diesem Beispiel scheitert auch die Bildverarbeitung im menschlichen Gehirn, obwohl (oder in diesem Fall gerade weil) sie auch aus semantische Aspekte zurückgreifen kann.


Scheinbare Verdeckungen werden hier im Bild ad absurdum geführt.

Grundlegende Fragen:

- Wie sind die Elemente zu gruppieren?
- Was ist das Homogenitätskriterium?
- Wie geht das menschliche visuelle System damit um?

Einige Beispiele als Denkanstöße:

Exkurs: Menschliche Wahrnehmung Objekt vs. Hintergrund




Was ist hier
Objekt, was
Hintergrund?

A driving force behind the gestalt movement is the observation that it isn't enough to think about pictures in terms of separating figure and ground (e.g. foreground and background). This is (partially) because there are too many different possibilities in pictures like this one. Is a square with a hole in it the figure? or a white circle? or what?

Exkurs: Menschliche Wahrnehmung Objekt vs. Hintergrund (2)


Wieviele/welche Objekte?



Sehen Sie hier zwei schwarze Gesichter oder einen weißen Pokal?

Exkurs: Menschliche Wahrnehmung Objekt vs. Hintergrund (2)


Wieviele/welche Objekte?



Meist fällt es leichter, intuitiv von schwarzen Objekten vor weißem Hintergrund auszugehen. Somit wandelt sich der Bildinhalt allein durch Invertieren der Farben.

● Gestalteigenschaften (Gestalt properties):

- Elemente in einer Ansammlung von anderen Elementen können Eigenschaften besitzen, die sich aus dem Verhältnis zu den anderen Elementen ergeben (Muller-Lyer Effekt).
- Eine Reihe dieser Eigenschaften legen fest, ob Elemente einander zugehörig sind und folglich gruppiert werden oder nicht.
→ Gestaltfaktoren
(**Gestalt factors**)



Muller-Lyer illusion

Interessanterweise hat das deutsche Wort „Gestalt“ sogar unmittelbar in die englische Sprache Einzug gehalten, wenn es um die Beschreibung von Bildinhalten bzw. deren charakteristische Formeigenschaften geht.

Eine bekannte optische Täuschung spielt mit der relativen Einschätzung von Längen nach ihrer Umgebung. Die horizontale Linie ist in beiden Fällen gleich lang, wie sich durch Nachmessen leicht überprüfen lässt. Dennoch kann man sich kaum des Eindrucks erwehren, sie sei im oberen Bild deutlich länger.

Exkurs: Menschliche Wahrnehmung Gestalteigenschaften (Beispiele)

Not grouped



Proximity



Similarity





Similarity




Common Fate




Common Region




Parallelism



Symmetry



Continuity




Closure

Quelle: Uni Michigan, Silvio Savarese

Zusammengehörigkeit von Bildelementen (Gruppierung) lässt sich auf unterschiedliche Weise erkennbar machen.

Exkurs: Menschliche Wahrnehmung imaginäre Konturen

unsichtbare/scheinbare Verdeckung



24

* Images from Steve Lehar's Gestalt papers: <http://cns-alumni.bu.edu/pub/lehar/lehar.html>

In der unwillkürlichen Annahme kontinuierlicher Formen werden in unterschiedliche interpretierbaren Bildern oft einfache geometrische Formen unterbewusst postuliert und die zugehörigen (unsichtbaren) Konturlinien für die kognitive Verarbeitung imaginär ergänzt.

Exkurs: Menschliche Wahrnehmung Verdeckungs-Hinweise



Versuchen Sie die 5
Ziffern zu lesen.

Quelle: Mediz. BV, Rainer Herpers, WS 2006/07

Occlusion cues seem to be very important in grouping. Most people find it hard to read the 5 numerals (each "9") in this picture

Exkurs: Menschliche Wahrnehmung Occlusion cues



Die 5 Ziffern sind leichter
zu lesen.

Quelle: Mediz. BV, Rainer Herpers, WS 2006/07

but easy in this

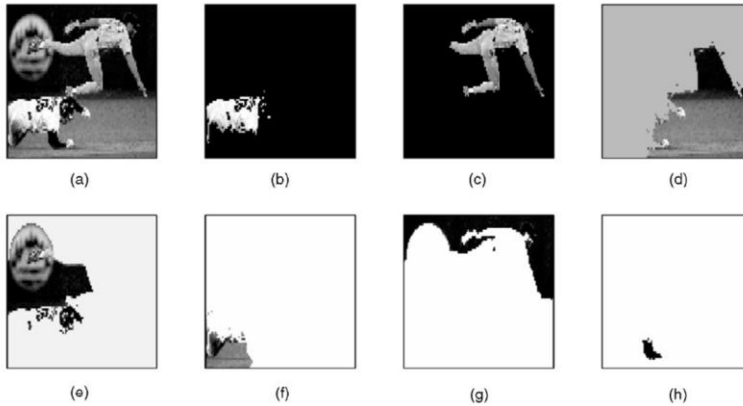
Segmentation und Klassifikation



Aufgabe: Vordergrund/Hintergrundsegmentation (Personen)

Quelle: Mediz. BV, Rainer Herpers, WS 2006/07

Segmentation durch Clusterbildung



Quelle: Mediz. BV, Rainer Herpers, WS 2006/07

Das Szenenfoto aus einem American Football-Match wird in verschiedene Segmente (d.h. zusammengehörige Bildbereiche) unterteilt.

Die automatische Aufteilung entspricht nicht immer der menschlichen Intuition.

Segmentierung und Interpretation

- **Segmentierung**

- Aufteilung (eines Bildes) in zusammenhängende Bereiche



- **Klassifizierung**

- Kategorisierung, Vergleich

- **Interpretation**

- Bewertung, Schlussfolgerungen
- z.B. Vordergrund, Hintergrund, etc.

■ = Auge, etc.

Zur Objekterkennung gehört die Klassifizierung der Objekte. Als Klassifizierung oder Klassifikation bezeichnet man einen Vorgang oder eine Methode zur Einteilung von Objekten in Klassen oder Kategorien über Merkmale (Token). Die Menge der Token definiert den Merkmalsvektor.

[Folie © Heiden, modifiziert durch Heisenberg, 2006/7]

- **Einheitliche Bestandteile (Token):**
(Alles was man benötigt, um nach einheitlichen Bestandteilen zu gruppieren)
 - Merkmale, Pixel (Ecken, Linien, etc.)
 - Größere Regionen mit einheitlicher Farbe und/oder Textur
 - Diskrete Objekte und deren Dichte
(z.B. Personen in eine Menschenmenge, Erbsen, Blutkörperchen etc.)

- **Zusammenfassen von Bildinhalten die “zusammen gehören”**

- **Partitionierung**

- Unterteilung in Regionen/Sequenzen mit einheitlichen internen Eigenschaften (Homogenitätskriterium)
- grob → fein

- **Gruppierung**

- Identifikation von (Unter-)Gruppen mit einheitlichen Bestandteilen
- fein → grob

Segmentierungsprinzipien (Übersicht)


- **Pixel-basiert**
 - Schwellenwert
 - statisch
 - dynamisch
 - adaptiv
 - Clustering
- **Kanten-basiert**
- **Region-basiert**
 - agglomerativ
 - divisiv
 - hierarchisch
- **Objekt-basiert**
 - Template-matching
- **Szenen-basiert**
 - a-priori-Wissen über Objektpositionen
- **Modell-basiert**
 - aktive Konturen
 - formbasierte Modelle

nach: Lehmann, Meyer zu Bexten: Handbuch der medizinischen Informatik. Hanser 2002, Kap. 8.7, pp 386-394

wichtige Folie!

Trennung zusammenhängender Bereiche

- **Schwellenwerte**
(*Threshold*)
- **Gebietswachstum**
(*Region growth*)




verschiedene Abbruchkriterien bei RG
auch: Kombination RG & Schwellenwert

Kantenbasierte Segmentierung

- **Kanten statt Pixeln**
- **Voraussetzung: klare Objektkanten**
 - (Anwendung z.B. bei metallischen Implantaten in Knochen bei CT)
- **Vorverarbeitung:**
 - Binarisierung
 - morphologische Filter
 - Skelettierung
 - Konturschließung (suchen entlang der Kanten)

● Template Matching



Als Maßstab dafür, ob das Template zu einer Bildregion passt, kann der quadratische Abstand von Eingangsbild S_e und Template T verwendet werden:

$$q_s(x, y) = \sum_{p=0}^{P-1} \sum_{q=0}^{Q-1} [S_e(x+p, y+q) - T(p, q)]^2$$

Wie bereits aus der Anwendung von Faltungsfiltern bekannt, sprechen Maskenoperationen an, wenn Templates genau oder mit einer gewissen Ähnlichkeit in Bildern auftreten. Somit eignen sie sich auch für die Suche nach bestimmten Bildinhalten.

Region-basierte Segmentierung (Clustering)

- **Zusammenfassen** von Bildeinheiten **zu benachbarten Regionen** über ein **Ähnlichkeitsmaß** (~“Abstand“) in einem **Parameterraum** (*Feature space*)
- Varianten:
 - **divisiv** (top-down)
 - Regionen entlang geeigneter Grenzen teilen
 - rekursiv
 - **hierarchisch**
 - Protokollierung von Zwischenstufen
 - Visualisierung: **Dendrogramm**
 - **agglomerativ** (bottom-up)
 - Pixel zu benachbarten Regionen hinzufügen

Divisive regionbasierte Segmentierung

- **top-down**
- **Split**
 - Teilung des Bildes entlang Achsenlinie
 - keine weitere Teilung bei Erfüllen einer Homogenitätsbedingung
- **Merge**
 - nachträgliches Verbinden willkürlich getrennter Regionen
- **keine Startpunkte**
- **Nachbearbeitung (Split&Merge) nötig**
- **stufige Objektgrenzen**

Divisive Region-basierte Segmentierung (top-down)


- **Split**

- Teilung des Bildes entlang Achsenlinie
- keine weitere Teilung bei Erfüllen einer Homogenitätsbedingung

- **Merge**

- nachträgliches Verbinden willkürlich getrennter Regionen

- keine Startpunkte
- Initialisierung mit dem Eingangsbild als eine Region
- Nachbearbeitung (**Split&Merge**) nötig
- stufige Objektgrenzen

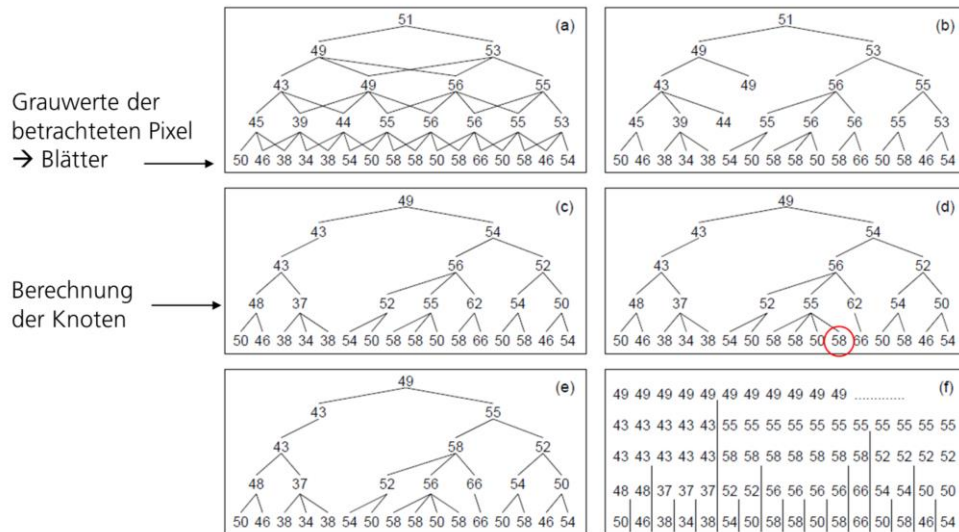


Die divisive Methode teilt (Split) ein binäres Bild (bzw. einzelne Bereiche davon) iterativ dort, wo beide Arten von Werten vorkommen. Am Ende werden benachbarte Bereiche gleicher Farbe wieder vereint (Merge).

Hierarchische regionbasierte Segmentierung

- bei Bildobjekten deutlich unterschiedlicher Größe
- Erstellung einer Detailpyramide
(z.B. Gauß-Pyramide)
- Segmentierung auf mehreren Pyramiden-Ebenen

Hierarchische Region-basierte Segmentierung



SS 2022

Segmentierung

Quelle: Mediz. BV, G. Heisenberg, SS 2013;
modif. 42

- Einsatz bei Bildobjekten deutlich unterschiedlicher Größe
- Erstellung einer Detailpyramide (z.B. Gauß-Pyramide)
- Segmentierung auf mehreren Pyramidenebenen

Erläuterung:

Die „Blätter“ enthalten die Intensitätswerte der einzelnen Pixel. Diese werden nun in mehreren Hierarchieebenen zu größeren Einheiten zusammengefasst.

Dabei werden zunächst (a) benachbarte Werte der jeweils direkt unterhalb der aktuellen Ebene liegenden Ebene gemittelt. Im nächsten Schritt (b) werden redundante Verbindungslinien gelöscht, so dass jedes „Blatt“ nur noch einem Repräsentanten der nächst höheren Eben zugeordnet ist. Die Auswahl erfolgt so, dass die Repräsentanten möglichst nah an den von ihnen repräsentierten Werten liegen. Ein weiterer Schritt (c) löscht Repräsentanten ohne Zuordnung und berechnet dann die Werte der verbliebenen Repräsentanten neu als Mittelwert der ihnen nun noch zugeordneten, darunter liegenden Knoten. Danach (d) werden die Knoten jeder Ebene den darüber liegenden (benachbarten) Repräsentanten so neu zugeordnet, dass diese ihnen möglichst gut entsprechen. Nach dieser Neuordnung werden die Werte der Repräsentanten wiederum neu berechnet (e). Dadurch entsteht eine hierarchisch gestaffelte Vereinfachung über Repräsentanten in jeder Ebene, die je nach Auswahl der Ebene wenige grobe oder mehr feiner differenzierte Cluster ferner oder näher den ursprünglichen Werten darstellt.

Weitere Segmentierungsansätze

- **Objektbasiert**
 - Template-matching (vgl. morphol. Hit&Miss)
- **Szenenbasiert**
 - Szenenbegrenzung durch bekannte Kanten
 - neuronale Netze zum Finden von Zusammenhängen
- **Wasserscheidentransformation**
 - Auffüllen von Höhenprofilen
- **Modellbasiert**
 - Active Contour: Randkontur als Polygonzug, Optimierung über Stützstellen
 - Shape-based: Bildraum-basiert od. Suchraum-basiert

noch auszuarbeiten!

Quelle: Lehmann, Meyer zu Bexten: Handbuch der medizinischen Informatik. Hanser 2002

Wasserscheiden-T.:

- Betrachtung der Helligkeiten als z-Koordinaten
- iterative Suche nach lokalen Minima und Zusammenfassen der Regionen zwischen lokalen Maxima

Agglomerative regionbasierte Segmentierung

- **bottom-up**
- **Bereichswachstum (seeded region growth)**
 - Wahl eines Startpunkts
 - Wachstum in Richtung benachbarter Pixel
 - Abbruch bei Nichterfüllung einer Homogenitätsbedingung
 - Neuer Startpunkt in bisher nicht zugeordneter Bildregion
- **abhängig von**
 - Wahl der Startpunkte (Position und Reihenfolge)
 - Wachstumsrichtung
 - Ähnlichkeitsmaß
 - Verschmelzungsschwelle

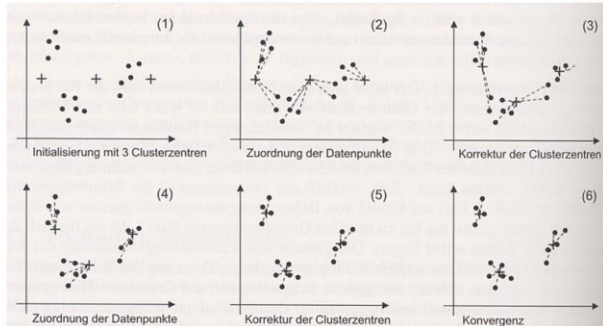
Wahl der Startpunkte meist manuell

- **multiparametrische Segmentierung**

- „Nähe“ in Parameterraum

- **typisches Verfahren: K-Means**

- willkürliche Verteilung von Cluster-Zentren
- iterative Gruppierung
- Cluster-Anzahl vorgegeben




Quelle: Lehmann, Meyer zu Bexten:
Handbuch der medizinischen Informatik.
Hanser 2002

Nähe/Abstand im Parameterraum ~ distance in feature space

Das iterative Verfahren ähnelt vom Ablauf her der hierarchischen regionbasierten Segmentierung, ist aber nicht ganz identisch.

Agglomeratives Clustering



Durch Hinzunehmen jeweils des (im Parameterraum) nächstgelegenen Punktes zu einem Cluster entsteht eine hierarchisch gestaffelte Struktur, die mit jedem Schritt um einen Datenpunkt abnimmt, ein „Dendrogramm“ (bezogen auf das griechische Wort dendron = Baum; und nicht, wie oft fälschlich gedruckt, „Dendogramm“). Verschiebt man die Knoten zu einer normalen Ebenenhierarchie, wird ein Ergebnis erreicht, das demjenigen der zuvor beschriebenen, hierarchischen regionbasierten Segmentierung ähnelt.


Agglomerative Region-basierte Segmentierung (bottom-up)

- **Bereichswachstum
(seeded region growth)**
- **Abhängigkeiten**
 - Wahl der Startpunkte (Position und Reihenfolge)
 - Wachstumsrichtung
 - Ähnlichkeitsmaß (Merkmal/Token)
 - Verschmelzungsschwelle
(Homogenitätskriterium und Prüfbedingung)

(Seeded) Region Growing Segmentierung

Algorithmus:

- Setze einen Saatpunkt (**seed point**) in die zu segmentierende Region des Eingangsbilds.
- Checke Nachbapixel auf Ähnlichkeit
 - Homogenitätskriterien
 - gleiche Farbe, gleicher Grauwert
 - ähnliche Farbe
 - ähnlicher Grauwert (Δg)
- Wenn das Homogenitätskriterium erfüllt ist, dann füge der Region den Nachbapixel hinzu (Label) und gehe zum nächsten Pixel.



Verschiedene Möglichkeiten zur Homogenitätsprüfung

Homogenitätsbedingung $\Delta g \leq 3$

Zwei Pixelreihen mit Grauwerten

5	4	4	5	7	8	4	4	4
6	4	3	5	6	9	4	4	4

Differenz zum aktuellen Pixel

5	4	4	5	7	8	4	4	4
6	4	3	5	6	9	4	4	4

Differenz zum Startpixel

5	4	4	5	7	8	4	4	4
6	4	3	5	6	9	4	4	4

Differenz zum Durchschnittswert

5	4	4	5	7	8	4	4	4
6	4	3	5	6	9	4	4	4


Δg = Grauwertabstand

single linkage: ein benachbartes Pixelpaar mit Grauwertdifferenz $< t$ genügt zum Verbinden

→ chaining-Problem: Zwei Segmente können über ein einziges Pixelpaar unter dem Schwellenwert verschmolzen werden.

(Seeded) Region Growing: Chaining-Problem

- **single linkage:** Prüfen einzelner Pixelpaare
- **chaining problem:** Solange irgendwo zwischen sonst klar getrennten Segmenten eine kontrastarme Brücke existiert, kann das zum Verschmelzen der Segmente führen.



vgl. Lehmann S.376

Lösung des Problems bzw. Entfernen des gelben Punktes: z.B. Median oder morphologischer Filter

Distanzmaße für Verschmelzen benachbarter Regionen

- **Single linkage**
 - einzelne Pixelpaare zwischen den Regionen $< t$
→ Chaining
- **Contiguity constraint complete linkage**
 - alle Pixelpaare auf gemeinsamer Kante
→ Eine 1-Pixel-Lücke verhindert Verschmelzen.
- **Contiguity constraint average linkage**
 - Mittelwert gemeinsamer Kantenpixel $< t$ führt zu Verschmelzung beider Bereiche.
- **Centroid linkage**
 - Verschmelzung, wenn Mittelwerte beider Regionen $< t$
- **Complete linkage**
 - berücksichtigt Dynamik
→ geeignet nach Wasserscheiden-Segmentierung

Voraussetzung:
vorsegmentierte
Regionen

vgl. Lehmann S.376

Distanz- und Ähnlichkeitsmaße

Hierarchisches Clustering

- Vorgehensweise -

1. Distanzmatrix berechnen (Wahl der Metrik)
 2. Zunächst ein Cluster pro Objekt
 3. Zwei ähnlichste Objekte bzw. Cluster suchen und zu neuem Cluster zusammenfassen
 4. Distanz zwischen neuem Cluster und allen anderen berechnen
 5. Schritte 3 bis 4 wiederholen bis nur noch ein Cluster übrig ist
- "Objekt" = Sample

Quelle: Günther, Krausz, Fiksman: Clustering von Microarray-Daten, SS'06

Hierarchisches Clustering

- Distanzberechnung -


- **Single Linkage:**
minimale Distanz zwischen zwei Objekten (zu Schritt 4)
- **Average Linkage:**
durchschnittliche Distanz als Mittel aller paarweisen Distanzen
- **Complete Linkage:**
maximale Distanz zwischen zwei Objekten
- **Centroid Distance:**
Distanz zwischen Centroiden der Cluster

Quelle: Günther, Krausz, Fiksman: Clustering von Microarray-Daten, SS'06

vgl. Verschmelzen bei Seeded Region Growth

Hierarchisches Clustering

- Beispiel -



- Anwendung in Bioinformatik: Genomforschung

→ Clusteranalyse ähnlicher Gene

Quelle: Günther, Krausz, Fikshan: Clustering von Microarray-Daten, SS'06 (nach Perou et al.)

Hierarchisches Clustering

- Diskussion -

Nachteile



- **Große Cluster** → Expressionsvektor, der Cluster repräsentiert, ist evtl. weit von tatsächlichen Vektoren im Cluster entfernt.
- → **Tatsächliche Vektoren** werden im Verlauf des Clustering-Vorgangs zunehmend **unwichtig**.
- **Keine Korrektur** möglich, wenn zu Beginn ein Fehler auftrat.

Vorteile


- **Einfach**
- **Übersichtliche Visualisierung** mit Dendrogramm
- **Variabel: Metrik, Linkage**

Quelle: Günther, Krausz, Fiksman: Clustering von Microarray-Daten, SS'06

Beispiel: Pixel-Clustering im RGB-Farbraum



Bildregionen schrittweise zusammenfassen



Self-organizing Maps


- **Basis: neuronale Netzwerke (NN)**
- **ähnlich k-Means-Clustering**
 - Unterschied: Definition der Referenz-Vektoren eines Clusters
- **Training der Referenzvektoren für eine Partition:**
 1. **Generierung zufälliger (Referenz)-Vektoren** für Partitionen
 2. zufällige Auswahl eines Datenpunkts: **Ermittlung des nächstgelegenen Referenzvektors**
 3. **Referenzvektor wird angepasst** (näher zum Startpunkt), dasselbe wird für die anderen Vektoren durchgeführt
 4. Wiederholung von 2 u. 3: **Referenzvektoren konvergieren** gegen Wert
 5. **Zuordnung** der Objekte (z.B. Gene) zu den Partitionen gemäß Referenzvektoren

Quelle: Günther, Krausz, Fiksman: Clustering von Microarray-Daten, SS'06

Quelle: Clustering von Microarray-Daten,


Self-organizing Maps - Beispiel

a) Self-Organizing Map
2-dimensional lattice of neurons




+ = SOM weight vectors
o = Original data rows


b)



d)




c)



Quelle: Günther, Krausz, Fiksman: Clustering von Microarray-Daten, SS'06

Support Vector Machines (SVM)

- **Überwachtes Lernen**
(Trainingsdaten:
Expressionsprofile von
Patienten mit bekannter
Diagnose)
- **Ziel: Entscheidungsregel,
die beide Klassen
voneinander trennt**
- **Idee: finde eine optimale
Hyperebene, welche die
klassifizierten Beispiele
trennt**





Quelle: Günther, Krausz, Fiksman: Clustering von Microarray-Daten, SS'06

Support Vector Machines

- Prinzip -

- Welche Hyperebene wird gewählt?
- Maximierung des Abstands für Support Vektoren von der Hyperebene (Optimierungsproblem)




Quelle: Günther, Krausz, Fiksman: Clustering von Microarray-Daten, SS'06

Support Vector Machines

- Kernel-

- Einfachere Trennung in hohen Dimensionen
→ Kernelfunktionen



Quelle: Günther, Krausz, Fikshan: Clustering von Microarray-Daten, SS'06

- **Anzahl der Cluster vorher bekannt**
 - **Bildung von k Clustern:**
 1. Initiale zufällige Verteilung der Objekte auf k Cluster
 2. Berechnung Durchschnitts-Expressionsvektor pro Cluster;
Ermittlung Distanzen zwischen den Clustern
 3. Iterativ: Verschieben der Objekte zw. Clustern (Distanzen zw.
Cluster / innerhalb Cluster; Objekte bleiben, falls sie näher zu
akt. Cluster als zu vorherigem)
 4. Wiederholung bis
 - Distanzen zwischen Clustern möglichst groß;
 - Distanzen innerhalb Cluster möglichst klein;

Quelle: Vortrag AVLS, B. Krauss, SS 2006

Wiederholung: (vgl. Folie 47: Cluster-Bildung)

"K-means" → vorgegebene Anzahl k von Cluster-Repräsentanten als gemittelte Position (*mean*) im Parameterraum

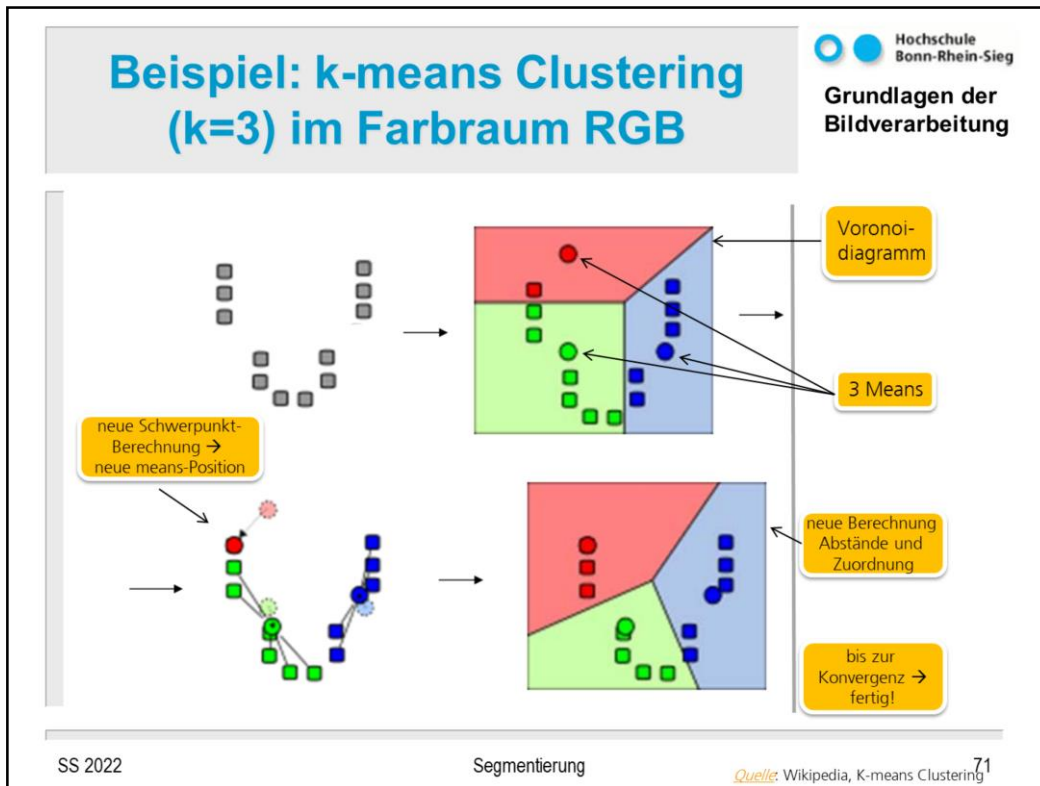


image segmentation—say, on the basis of color—is an obvious application here


Voronoi tessellation, a **Voronoi decomposition**, or a **Dirichlet tessellation**

K-means Clustering nach Intensität bzw. Farbe


Farbbild (Original)



Intensitäts-Cluster



Farb-Cluster



K-means Clustering ausschließlich nach Intensität bzw. Farbe

Quelle: Mediz. BV, Rainer Herpers, WS 2006/07

I gave each pixel the mean intensity or mean color of its cluster --- this is basically just vector quantizing the image intensities/colors. Notice that there is no requirement that clusters be spatially localized and they're not.

Fuzzy C-Means (FCM)

(= Fuzzy k-Means)

- **Zugehörigkeitsfunktion** (Membership function)
 - Zuordnung z.B. über (euklid.) Abstand Datenpunkt – Clusterzentrum
 - Gewichtung (~Unschärfe) einstellbar
- **Partitionsmatrix**
 - Membership degree Tupel vs. Cluster
 - Gewichtung $[0, \dots, 1]$ für jedes Tupel zu jedem Cluster
- **Abbruchbedingung**
 - Differenzen in Partitionsmatrix $<$ Grenzwert

J.C. Dunn in 1973, improved by J.C. Bezdek in 1981
[https://en.wikipedia.org/wiki/Fuzzy_clustering; 11.06.2019]

Beispiel Fuzzy Clustering





Image segmented by fuzzy clustering, with the original (top left), clustered (top right), and membership map (bottom)



By Danielcschossow - Own work, CC BY-SA 4.0,
<https://commons.wikimedia.org/w/index.php?curid=58470609>

Bildsegmentierung mit Fuzzy Logic

(Bachelor Thesis Sebastian Stucken, 2015)

- **Iteratives Gebietswachstum (Seeded Region Growth)**

- Automatische Wahl der Saatpunkte
- Fuzzyfizierung über Linguistische Variable „Helligkeit“
- Fuzzy Inferenz durch kombinierte Unähnlichkeitsprüfung Linguistischer Variablen

- **Hierarchische Segmentierung über Gauß-Pyramide**

- minimiert Rechenaufwand
- Segmentierung von Feinstrukturen nur, wenn Varianzen der vorsegmentierten Regionen benachbarter Ebenen der Gauß-Pyramide einen Schwellwert überschreiten
- Fehlerbehandlung: iterative Senkung der Schwellwerte für nicht zu Regionen zugeordnete Punkte

Bildsegmentierung mit Fuzzy Logic (Bachelor Thesis Sebastian Stucken, 2015)

Iterationsschritt zum Gebietswachstum

1. Wahl der Saatpunkte

- Seeded Region Growth
- lokale Maxima und Minima (Grauwertintensität) → automatische Wahl geeigneter Saatpunkte

2. Fuzzyfizierung

- Zuordnung aller Grauwerte zur Linguistischen Variable *Helligkeit*
 - sehr dunkel, dunkel, grau, hell, sehr hell
 - dynamische Zuordnungsfunktionen nach Otsu-Schwellwertverfahren anhand Histogramm

3. Fuzzy Inferenz

- Ähnlichkeit benachbarter Bildpunkte zur aktuellen Region
- Kombination 3er (Un-)Ähnlichkeitsmaße
 - Nachbarpunkt zum Regions-Referenzpunkt
 - Nachbarpunkt zum Regions-Mittelwert
 - Mittelwert aller Nachbarpunkte zum Regions-Mittelwert
- Kanten (Canny) als zusätzliche Grenzmarkierungen


Bildsegmentierung mit Fuzzy Logic

(Bachelor Thesis Sebastian Stucken, 2015)

Anwendung auf CT-Schnitte



Originalbild




Segmentiertes Bild

Bildsegmentierung mit Fuzzy Logic


(Bachelor Thesis Sebastian Stucken, 2015)

Anwendung auf CT-Schnitte:


Vergleich zu semi-manuellem Trainable Weka-Verfahren
(Plugin Software „Fiji“)




Originalbild



Manuell gesetzte Punkte und
Regionen für den Algorithmus



Segmentiertes Bild



b

Trainable Weka Segmentation

Fuzzy
Segmentation

- **Hierarchisches Clustering**
 - Cluster analysis and display of genome-wide expression patterns, Eisen et al., 1998
- **Self-Organizing Maps - Clustering**
 - Analysis of gene expression data using self-organizing maps, Toronen et al., 1999
- **Support Vector Machines - Clustering**
 - Support vector machine classification and validation of cancer tissue samples using microarray expression data, Furey et al., 2000
 - http://lectures.molgen.mpg.de/statistik/docs/Kapitel_16.pdf
- **Fuzzy Segmentierung**
 - Heiden, W., Brickmann, J.: Segmentation of protein surfaces using fuzzy logic. J. Mol. Graphics **12** (1994), 106-115
- **Fuzzy Bildsegmentierung**
 - Stucken, S.: Segmentierung von medizinischen Bilddaten über Fuzzy Logic. Bachelor Thesis Informatik, Hochschule Bonn-Rhein-Sieg, 2015

Kompetenzcheck

- **Prinzip Segmentierung**
 - Definition, Homogenität
 - Vorder- und Hintergrund
- **Segmentierungskonzepte**
 - pixel-, region-, kantenbasiert, etc.
 - objekt-, szenen-, modellbasiert
- **Clustering**
 - agglomerativ vs. divisiv
 - Seeded Region Growth
 - Hierarchisches Clustering
 - K-Means, SVM, etc.
- **Segmentierung mit Fuzzy Logic**

