

Vorlesung

„Bildverarbeitung in der Medizin“

Teil 6: Segmentierung

Jürgen Braun, Dagmar Krefting – Institut für Medizinische Informatik



Segmentierung I

- I. Definitionen Segmentierung / Segmentierungsproblem
- II. Wichtige Segmentierungsverfahren
- III. Wechselspiel Segmentierung - Bildmaterial
- IV. Beispiel automatisches Segmentierungsverfahren
- V. Beispiel interaktives Segmentierungsverfahren

Einführung

2

Ziele der Vorlesung

- Nach dieser Veranstaltung sollten Sie wissen:
- wie das Segmentierungsproblem formuliert werden kann
 - welche wichtigen Segmentierungstechniken existieren
 - Vor- und Nachteile der unterschiedlichen Techniken
 - welchen Einfluß unterschiedliches Bildmaterial besitzt
 - welche Anwendungen es im Bereich der Medizin gibt
 - Beispiel für ein automatisches Segmentierungsverfahren
 - Beispiel für ein interaktives Segmentierungsverfahren

Einführung

3

I. Definition von Segmentierung

Eine Segmentierung kann man als Unterteilung eines Bildes in nicht überlappende Teilregionen, die entsprechend einer charakteristischen Eigenschaft (z.B. Grauwertintensität oder Textur) homogen sind, beschreiben. Für ein Bild I müssen Teilregionen S_k gefunden werden, deren Vereinigung das Gesamtbild I ist.

$$I = \bigcup_{k=1}^n S_k \quad \text{mit} \quad S_k \cap S_j = \emptyset \quad \text{für} \quad k \neq j$$

Die Vorgang der Bestimmung der Teilregionen S_k wird als Pixelklassifikation und die Teilregionen selbst werden als Klassen bezeichnet. Idealerweise werden mit einer Segmentierung Regionen ermittelt, die zu eindeutigen anatomischen Strukturen korrespondieren.

Grundproblem bei digitalem medizinischem Bildmaterial: die Bildaufnahme (Sampling und Digitalisierung) führt je nach Anatomie zu mehr oder weniger starken Partitivolumeneffekten, die Uneindeutigkeiten beim Auffinden von anatomischen Strukturen bewirken.

1. Definitionen

4

I. Formulierung des Segmentierungsproblems

Die meisten Segmentierungsverfahren können als Optimierungsprobleme formuliert werden, worin die Segmentierung eine durch das jeweilige Verfahren gegebene Energie- oder Kostenfunktion minimiert. In wahrscheinlichkeitstheoretischen Verfahren ist dies gleichbedeutend mit der Maximierung einer Wahrscheinlichkeit.

Mit dem gegebenen Bild I ist eine Segmentierung \hat{x} erwünscht, für die gilt:

$$\hat{x} = \underset{x}{\text{arg min}} \varepsilon(x, I)$$

wobei die Energiefunktion ε vom Bild I und der jeweiligen Segmentierung x abhängt. Der Vorteil bei der Formulierung von Segmentierungen als Optimierungsproblem liegt darin, daß klar definiert ist, was eine gute Segmentierung ist.

Die Definition einer geeigneten Energiefunktion ε ist das Hauptproblem beim Entwurf eines Segmentierungsverfahrens, da eine Vielzahl von Bildeigenschaften dazu verwendet werden können (Kanten, Texturen, Intensitäten, ...).

1. Definitionen

5

I. Reviews zur Segmentierung von digitalen Bildern


- R.M. Haralick and L.G. Shapiro. Image segmentation techniques. *Comput. Vis. Graph. Im. Proc.*, 29:100–132, 1985.
- N.R. Pal and S.K. Pal. A review on image segmentation techniques. *Pat. Rec.*, 26:1277–1294, 1993.
- M.S. Atkins and B.T. Mackiewicz. Fully automatic segmentation of the brain in MRI. *IEEE T. Med. Imag.*, 17:98–109, 1998.
- J.C. Bezdek, L.O. Hall, and L.P. Clarke. Review of MR image segmentation techniques using pattern recognition. *Med. Phys.*, 20:1033–1048, 1993.
- E.L. Chaney and S.M. Pizer. Defining anatomical structures from medical images. *Seminars in Radiation Oncology*, 2:215–225, 1992.
- L.P. Clarke, R.P. Velthuizen, M.A. Camacho, J.J. Heine, M. Vaidyanathan, et al. MRI segmentation: methods and applications. *Mag. Res. Imag.*, 13:343–368, 1995.
- P. Suetens, E. Beillon, D. Vandermuelen, M. Smet, G. Marchal, J. Nuyts, and L. Morelmans. Image segmentation: methods and applications in diagnostic radiology and nuclear medicine. *Eur. J. of Radiology*, 17:14–21, 1993
- A.P. Zijdenbos and B.M. Dawant. Brain segmentation and white matter lesion detection in MR images. *Critical Reviews in Biomedical Engineering*, 22:401–465, 1994.

1. Definitionen

6

Segmentierungstechniken: Schwellwertbildung

Bei der Schwellwertbildung werden skalare Bilder durch binäre Partitionierung von Bildintensitäten segmentiert. Es werden Schwellwerte (=Grauwert oder Bildintensität) gesucht, mit denen sich die gesuchten Klassen separieren lassen. Dies kann beispielsweise mit Hilfe von Histogrammen durchgeführt werden. Die Schwellwerte werden in der Regel interaktiv bestimmt, es existieren jedoch auch automatische Verfahren.



2. Segmentierungsverfahren

7

Segmentierungstechniken: Schwellwertbildung

Die Schwellwertbildung ist ein einfaches, oft aber effektives Verfahren zur Segmentierung wenn gesuchte Strukturen sich im Grauwert unterscheiden. Schwellwertverfahren werden häufig auch in der Bildvorverarbeitung eingesetzt.

Einschränkungen:

- Effekte die Einfluß auf das Grauwert-Histogramm besitzen. Dazu zählen Aufnahmebedingte Intensitätsschwankungen und die Höhe des Bildrauschens (Signal zu Rausch Verhältnis (SNR)).
- in der einfachsten Form kann nur ein Schwellwert gesetzt werden
- nicht auf Mehrkanalbilder anwendbar
- Interaktiver Optimierungsprozeß

Literatur:
P.K. Sahoo, S. Soltani, and A.K.C. Wong, A survey of thresholding techniques. Comput. Vis. Graph. Im. Proc., 41:233-260, 1988.

2. Segmentierungsverfahren

8

Segmentierungstechniken: Klassifikatoren

Klassifikatoren sind Mustererkennungstechniken mit denen versucht wird, einen aus einem Bild erzeugten Eigenschaftsraum in Klassen zu unterteilen. Klassifikatoren sind interaktive, überwachte Verfahren, die manuell segmentierte Trainingsdaten als Referenz für den Segmentierungsvorgang benötigen.

Wichtige Klassifikatoren sind:


- nearest-neighbor Klassifikator (NN): einfaches Verfahren bei dem jeder Bildpunkt der Referenzklasse mit der ähnlichsten Intensität zugewiesen wird
- k-nearest-neighbor Klassifikator (kNN): Verallgemeinerung des NN-Klassifikators Trainingsdatensätze werden in einen mehrdimensionalen Merkmalsraum abgebildet, der durch die manuelle Segmentierung automatisch in Klassen unterteilt ist. Ein Punkt x im Eigenschaftsraum wird einer Klasse c durch Mehrheitsentscheid zugewiesen, d.h. c muß diejenige Klasse in den Trainingsdaten sein, die den Punkt x am häufigsten umgibt. Beim kNN-Klassifikator werden keine Annahmen über die statistische Verteilung der Daten vorausgesetzt.
- Maximum Likelihood (ML) oder Bayes Klassifikator: hier wird angenommen, daß die Pixelintensitäten als unabhängige Proben einer Summe von gaussförmigen Wahrscheinlichkeitsverteilungen (von Intensitäten) aufgefaßt werden können.

2. Segmentierungsverfahren

10

Segmentierungstechniken: region growing

Region growing ist ein Verfahren zur Extraktion eines Bildausschnitts, der über eine gemeinsame Eigenschaft (Bildintensitäten, Kanten, ...) verfügt ist. Im einfachsten Fall wird manuell ein Startpunkt (seed point) gewählt, von dem ausgehend benachbarte Bildpunkte im Falle einer bestimmten identischen Eigenschaft mit dem Startpunkt verbunden werden. Wie die Schwellwertbildung wird auch region growing häufig zusammen mit anderen Bildverarbeitungsfunktionen eingesetzt.



Einschränkungen:

- Hoher Grad an Interaktion (Startpunkte für alle zu segmentierenden Gewebeklassen müssen von Hand gesetzt werden).
- rauschempfindlich, es kann zu Löchern in eigentlich zusammenhängenden Gebieten kommen
- Partialvolumeneffekte können zum Zusammenwachsen unterschiedlicher Strukturen führen.

2. Segmentierungsverfahren

9

Segmentierungstechniken: Clusterverfahren

Clusterverfahren sind Klassifikationsverfahren, die ohne Trainingsdaten auskommen. Zur Kompensation der fehlenden Trainingsdaten iterieren die Verfahren zwischen Segmentierung des Bildes und der Charakterisierung der Eigenschaften unterschiedlicher Klassen.

Wichtige Clusterverfahren sind:

- K-means (SODATA): clustering durch iterative Berechnung von mittleren Intensitäten pro Klasse. Die Segmentierung erfolgt dann durch Zuweisung der Pixelintensität in die Klasse mit dem nächstgelegenen Intensitätsmittelwert.
- Fuzzy c-means: Verallgemeinerung des K-means Algorithmus und erlaubt überlappende Bereiche bei der Segmentierung aufgrund unscharfer Entscheidungen, die die fuzzy-Logik erlaubt.
- Expectation-maximization (EM): hier wird die Annahme gemacht, daß die Daten durch eine Wahrscheinlichkeitsdichtefunktion (Komponenten besitzen Gauss-Verteilung) modelliert werden können (siehe Maximum Likelihood-Klassifikator). Es iteriert zwischen der Bestimmung von Wahrscheinlichkeiten und der Berechnung von ML-Schätzungen des Mittels, der Kovarianzen und der Wichtigungskoeffizienten der Wahrscheinlichkeitsverteilungskomponenten.

2. Segmentierungsverfahren

12

Segmentierungstechniken: Klassifikatoren

Diese Summe wird durch eine Wahrscheinlichkeitsdichtefunktion beschrieben:

$$f(y_i; \theta, \pi) = \sum_{k=1}^K \pi_k f_k(y_i; \theta_k)$$

mit y_i als Intensität eines Pixels i , f_k als Wahrscheinlichkeitsverteilungskomponente parametrisiert durch θ_k und gewichtet mit dem Wichtigungskoeffizienten π_k . Trainingsdaten werden durch Ermittlung repräsentativer Stichproben aller Wahrscheinlichkeitsverteilungskomponenten f_k und Schätzung der zugehörigen mittleren Intensitäten θ_k , der Kovarianzen und der Wichtigungskoeffizienten erzeugt. Bei der Segmentierung neuer Daten werden die Pixel unter Berücksichtigung aller gegenseitig bedingter Wahrscheinlichkeiten Klassen zugeordnet.

Klassifikatoren arbeiten gut, solange die in den Trainingsdaten manuell definierten Klassen im Eigenschaftsraum unterschieden werden können. Sie sind auf mehrdimensionale Daten anwendbar und sind als nichtiterative Verfahren recheneffizient.

Einschränkungen:

- örtliche Intensitätsschwankungen können nicht modelliert werden
- hohe Interaktion bei der manuellen Erstellung der Trainingsdaten
- es müssen genügend Testdatensätze vorhanden sein um anatomische und physiologische Normvarianten berücksichtigen zu können

2. Segmentierungsverfahren

11

Segmentierungstechniken: Clusterverfahren

- Einschränkungen:
- es wird eine initiale manuelle Segmentierung benötigt oder, gleichbedeutend, optimale Startwerte
 - Abhängigkeit der Ergebnisse von den Anfangsbedingungen
 - keine Berücksichtigung ortsabhängiger Intensitätsschwankungen
- empfindlich gegenüber Rauschen und Intensitätsschwankungen
(Lösungsansatz: Verwendung von Markov random fields)

Segmentierungstechniken: Markov random fields

Die Markov random field (MRF) Modellierung ist ein statistisches Modell, das für Segmentierungsprobleme eingesetzt wird. Es werden dabei räumliche Wechselbeziehungen zwischen benachbarten oder in der Nähe liegender Pixel statistisch beschrieben. Mit den solchen Korrelationen können zahlreiche Bildigenschaften modelliert werden. Für medizinisches Bildmaterial wird weiterhin die Annahme getroffen, das die meisten Pixel der gleichen Klasse wie Ihre Nachbarn angehören.


MRFs werden oft in Cluster-Verfahren (z.B. K-means) zur Segmentierung integriert. Bei der Segmentierung wird auf Grundlage des Bildmaterials durch iterative Verfahren die Wahrscheinlichkeit der Zugehörigkeit von Pixeln zu einer Klasse maximiert. MRF's werden neben Segmentierungen auch zur Modellierung von Textureigenschaften und Intensitätsschwankungen in MRT Bildern eingesetzt.

Einschränkungen:

- Parameterwahl zu Modellierung der räumlichen Wechselbeziehungen (falsche Parameter können beispielsweise zu einer sehr starken Glättung führen)
- rechenintensiv

Segmentierungstechniken: Markov random fields

Vergleich Segmentierungsergebnisse K-means und Markov random field



Original MRT Bild T1-Wichtung
Segmentierung mit K-means
Segmentierung mit Markov random fields

Segmentierungstechniken: Neuronale Netze

Künstliche Neuronale Netze (KNN) sind Netzwerke von massiv parallel arbeitenden Verarbeitungselementen (Knoten), die biologisches Lernen simulieren. Jeder Knoten in einem KNN kann elementare Berechnungen durchführen. Lernen wird durch die Anpassung von Gewichten der Knotenverknüpfungen realisiert.

Die am weitesten verbreitete Anwendung Neuronaler Netze in der Verarbeitung medizinischer Bilddaten besteht im Einsatz als Klassifikatoren. Die Gewichte der Knotenverbindungen werden vor der Segmentierung durch Trainingsdaten festgelegt. Einige KNNs können aber auch wie Clusterverfahren die Trainingsphase parallel zur Segmentierung von Daten erlernen.

Durch die erzielbare hohe Komplexität bei der Verschaltung vieler Knoten können Ortsinformationen leicht in KNNs integriert werden. Obwohl KNNs in der Regel zur parallelen Datenverarbeitung ausgelegt sind, reduziert sich dieser Vorteil durch die Rechenumgebung auf seriell arbeitenden Standardcomputern.

Übersichtsarbeiten über KNNs:

- J.W. Clark. Neural network modelling. *Phys. Med. Biol.*, 36:1259–1317, 1991.
- S. Haykin. *Neural networks: a comprehensive foundation*. Macmillan College, New York, 1994.

Segmentierungstechniken: deformable models

Deformable models sind auf Basis der Physik modellierte Techniken zur Abgrenzung von Regionen mit Hilfe geschlossener Linienzüge oder Oberflächen, die unter dem Einfluß interner und externer Kräfte deformiert werden. Interne Kräfte (F_{int}) werden vom Inneren der geschlossenen Linie aus berechnet und bewirken deren glatten Verlauf. Externe Kräfte (F_{ext}) werden in der Regel aus dem Bild abgeleitet und zwingen den Linienzug an die Form der zu segmentierenden Struktur.

Deformable models verhalten sich entsprechend zugrundeliegender Bewegungsgleichungen und streben dem Minimum einer gegebenen Energiefunktion zu. Bewegungsgleichung für ein 2D-Modell:

$$\mu(s) \frac{\partial^2 (x(s,t), y(s,t))}{\partial t^2} + \gamma(s) \frac{\partial (x(s,t), y(s,t))}{\partial t} = F_{int} + F_{ext}$$

s: Ortsvariable, μ : Dichteparameter, γ : Dämpfungsparameter

Als externe Kraft wird meistens der Gradient über die Bildintensitäten gewählt.

Segmentierungstechniken: deformable models

Die gebräuchlichste Formulierung der internen Energie ist:

$$F_{int} = \frac{\partial}{\partial \alpha} \left(\alpha(s) \frac{\partial (x(s,t), y(s,t))}{\partial x} \right) - \frac{\partial^2}{\partial x^2} \left(\frac{\partial^2 (x(s,t), y(s,t))}{\partial x^2} \beta(s) \right)$$

mit α und β als Parameter für Dehnungs- und Biegekräfte.

Vorteile:

- Erzeugung geschlossener Abgrenzungen
- Berücksichtigung einer Glättungsbedingung
- robust gegenüber Rauschen und nicht durchgängigen Kanten

Einschränkungen:

- manuelle Interaktion bei der initialen Definition des abgrenzenden Linienzuges
- Abhängigkeit von der Lage der genauen Lage der Startlinie
- schlechte Anpassung an konkave Strukturen

Übersichtsarbeit über deformable models:

- T. McInerney and D. Terzopoulos. Deformable models in medical image analysis: a survey. *Med. Im. Anal.*, 1:91–108, 1996.

Segmentierungstechniken: Atlasgestützte Techniken

Atlasgestützte Techniken sind leistungsfähige Werkzeuge zur Segmentierung Medizinischer Bilddaten. Die Erzeugung von Atlanten erfolgt durch die Erstellung von Information (manuelle Segmentierung, Wertebereiche in Abhängigkeit der Aufnahmetechnik) zu anatomischen Strukturen. Der Atlas dient dann als Referenz zur Segmentierung unbekannter Daten.

Konzeptuell sind die Atlasgestützten Verfahren bis auf den Unterschied, daß sie im Orts- und nicht im Eigenschaftsraum arbeiten, den Klassifikatoren ähnlich.

Atlasgestützte Techniken behandeln die Segmentierung als Registrierungsproblem. Dazu muß eine Transformation gefunden werden, die ein Atlasbild auf das Zielbild abbildet. Oftmals reichen einfache Translationen, Rotationen oder affine Transformationen nicht aus, in der Regel sind elastische Registrierungsverfahren (warping) notwendig. Da Atlasbilder bereits segmentiert sind, kann so die gesamte Information auf das Zielbild übertragen werden.


Einschränkungen:

- trotz nichtlinearer Registrierungsverfahren können Atlasdaten oftmals nicht vollständig an die komplex geformte Anatomie angepaßt werden

19

2. Segmentierungsverfahren

Segmentierungstechniken: Atlasgestützte Techniken



Segmentierung von 3 Schichten aus einem MRT-Volumendatensatz mit Hilfe eines Atlases. Abweichungen sind im Bereich der Furchen, der Ventrikel und des Putamens zu erkennen.

20

2. Segmentierungsverfahren

III. Segmentierung und bildgebende Modalitäten

Bei der Anwendung von Segmentierungstechniken müssen spezifische Eigenschaften der zur Aufnahme verwendeten bildgebenden Verfahren berücksichtigt werden.

Im folgenden werden bildaufnahmebezogene Probleme und Anwendungen von Segmentierungsverfahren vorgestellt.

3. Segmentierung / Bildgebende Modalitäten 21

III. Segmentierung und Radiographie

Klassische Röntgenaufnahmen fanden bislang nur wenig Anwendung bei Segmentierungsverfahren.

Hauptprobleme:

- Die Projektion eines 3D-Objekts auf einen Film führt zur Überlagerung anatomischer Strukturen die nur schwer zu trennen sind
- Die Bildanalyse durch den Arzt ist so einfach, daß keine Diagnoseunterstützung durch Segmentierungsverfahren benötigt wird

Es existieren vereinzelte Ansätze zur Segmentierung von Thoraxaufnahmen in anatomische Strukturen mit

- Klassifikatoren
- Markov random fields
- deformable models

3. Segmentierung / Bildgebende Modalitäten 22

III. Segmentierung und Computertomographie (CT)

In der Computertomographie (CT) sind durch die Aufnahme von Schichtbildern Probleme sich komplex überlagernder Strukturen eliminiert. Die CT erlaubt Aufnahmen von 3D-Datensätzen mit höheren Auflösungen als die MRT, wobei der Kontrast zwischen Weichgeweben in der MRT besser ist.

Unter Berücksichtigung der Stärken der CT-Aufnahmetechnik werden daher hauptsächlich Knochen, Knochentumore und thorakale Strukturen segmentiert, seltener auch andere Gewebe.

3. Segmentierung / Bildgebende Modalitäten 23

III. Segmentierung und CT

Segmentierung von knöchernen Strukturen / Knochentumoren:

- Schwellwertbildung
- region growing
- Markov random field
- deformable models
- fuzzy region growing

Segmentierung von Thoraxaufnahmen:

- region growing kombiniert mit Wasserscheiden-Algorithmus
- fuzzy region growing
- deformable models
- spezielle Verfahren zur 3D-Segmentierung von Bronchien / Lungen

Segmentierung anderer Gewebe:

- Gehirn (wissensbasiert)
- Leber (deformable models)
- Aortenaneurysmen (deformable models)
- Herz (deformable models, dynamisches Finite Element Model)

3. Segmentierung / Bildgebende Modalitäten 24

III. Segmentierung und Mammographie

Bei der Segmentierung von Mammographie Aufnahmen steht primär die Lokalisierung von Brusttumoren und Mikrocalcifikationsherden im Vordergrund.

- Als Segmentierungstechniken dienen:
- am häufigsten einfache Schwellwertbildung
 - region growing
 - Markov random field (texturbasiert)

Probleme:


Das Hauptproblem ist nicht die Qualität des Bildmaterials sondern die bislang nicht auszuschließenden Übersegmentierungen und durch Klassifikation bestimfte falsch negative Gewebestrukturen (Erkrankungen fälschlicherweise als gesund klassifiziert).

Momentan dienen vollautomatische Segmentierungsverfahren von Mammogrammen nur zur Diagnoseunterstützung. Verbesserte Ergebnisse lassen sich möglicherweise durch manuelle Vorsegmentierung verdächtiger Strukturen oder durch ausschließliche Unterscheidung in gesunde und kranke Gewebe erzielen.


III. Segmentierung und Mammographie



Mammogramm und vom Radiologen festgelegte Grenze (Blau) eines bösartigen Tumors



Variationsfeld δ des Gradienten (lokales Texturmaß $\delta = \sqrt{I_{xx}^2 + I_{yy}^2}$)



Segmentierung mit Waterscheiden-Algorithmus und Nachbarschaftsichte



Nach Klassifikation statistisch unter Berücksichtigung von δ hell = krankes Gewebe

Das vorliegende digitale Mammogramm wird durch den einfachen Wasser-scheidenalgorithmus übersegmentiert. Mit statistischen Klassifikatoren auf Grundlage von Textureigenschaften werden Regionen mit Mikrocalcifikationen bestimmt. Das größte Problem bilden die falsch negativen Segmente (krank aber als gesund klassifiziert). Falsch Positive Segmente (gesund aber als krank klassifiziert) liegen hier randständig oder außerhalb des Bildes und können in diesem Fall als solche relativ leicht erkannt werden.

IV. Segmentierung und Magnetresonanztomographie

Anwendung von Segmentierungsverfahren in der Magnetresonanztomographie:

- Hirngewebe:
- Volumenbestimmung (deformable models, Atlanten)
 - Gewebedifferenzierung (Eigenschaftsbasiert, Klassifikatoren, Neuronale Netze, Markov random fields, deformable models, Atlanten)

- Herzabbildgebung
- Dynamik von Herzbewegungen (Kantendetektion, Schwellwert, deformable models, region growing)

Gefäßdarstellung

- Koronararterien (modellbasiert, Schwellwert)
- Gefäßverzweigungen (deformable models)
- Gefäßbäume (modellbasiert)

III. Segmentierung und Magnetresonanztomographie

Das für Segmentierungen am häufigsten eingesetzte medizinische Bildmaterial stammt aus der Magnetresonanztomographie.

- Gründe dafür sind:
- hohe Ortsauflösung (3D: 1mm kubische Voxel)
 - sehr guter Weichgewebekontrast
 - gute Ausleuchtung tiefliegender Gewebe
 - hohes Signal/Rausch Verhältnis
 - viele unabhängige Aufnahme-Techniken → mehrdimensionale Merkmalräume

Keine Seite der Vielzahl von Aufnahme-Techniken sind:

- es existieren nur wenige quantifizierbare Maßgrößen
- eingeschränkte Vergleichsmöglichkeiten
- Ermittlung der optimalen Aufnahme-Technik/Aufnahmeparameter ist schwierig

Weitere Probleme:

- ungleichmäßige Ausleuchtung (Intensitätsschwankungen)
- überlappender Wertebereich von Gewebeparametern
- Partialvolumeneffekte

III. Segmentierung und MRT


Es existieren verschiedene Vorgehensweisen zur Berücksichtigung von Intensitätsschwankungen:

(I) externe Verfahren

- Berechnung der Feldverteilung
- Theoretische Berechnung der individuellen Feldverteilung von Spulen,
- Probleme: Modellierung schwieriger Geometrien, Magnetisierbarkeit des Objektes in der Spule bleibt unberücksichtigt.
- Phantomuntersuchungen
- Verwendung von Phantomen mit einheitlicher Struktur zur Kartierung der makroskopischen Spulencharakteristik. Die Korrekturfunktion kann unter der Annahme, daß das ungestörte Signal einheitlich ist, berechnet werden.

III. Segmentierung und MRT

Hauptproblem bei der Segmentierung von MRT-Bildern: Bildintensität ist leicht ortsabhängig, d.h. durch die Spulencharakteristik kommt es zur Dunkelblöndung von Bildbereichen



synthetisches Bild ohne Intensitäts-schwankung und Histogramm der Gewebeklassen

nach Einführung von Intensitäts-schwankungen: die drei Gewebeklassen können nicht mehr eindeutig separiert werden

Besonders betroffen sind intensitätsbasierte Segmentierungsverfahren, die einen konstanten Grauwert für einen Gewebetyp voraussetzen.

III. Segmentierung und MRT

(1) interne Verfahren, datengetrieben (beruht auf individueller Bildinformation):

- Filterung im Ortsraum, die Intensitätsverteilung wird durch Vergleich von geschätzten (Mittlung oder Medianfilterung) lokalen Bildintensitäten mit einem globalen Intensitätserwartungswert bestimmt (oft besteht die Annahme, daß nur ein einheitlicher Gewebetyp vorliegt, d.h. andere Gewebe müssen zuvor maskiert werden).
- Filterung im Frequenzraum, der Fouriersatz beruht auf der Annahme, daß die Intensitätsschwankung im Vergleich zum MR-Signal langwellig variieren und beide Spektren daher separierbar sind. Zur Intensitätskorrektur werden tiefpassgefiltertes Bild und Originalbild subtrahiert.
- Surface Fitting Methoden, hier wird durch Identifikation eines a priori erkennbaren „guten“ Bildbereiches eine Referenzoberfläche festgelegt. Ausgehend von dieser Region werden Bereiche mit Intensitäts-schwankungen extrapoliert.

III. Segmentierung und Ultraschall (US)

Die Anwendung von Segmentierungsalgorithmen auf Ultraschallbildmaterial ist durch die schlechte Bildqualität (geringer Grauwertbereich, Streumuster) ziemlich eingeschränkt.

Da Ultraschallaufnahmen in Echtzeit aufgenommen und in Form von Filmen abgespeichert werden können, existieren einige deformable model-Verfahren zur Bewegungsverfolgung von anatomischen Strukturen des Herzens.

Segmentierung von US-Daten:

- Cysten in Eierstöcken (Schwellwertbildung kombiniert mit Texturen)
- Cysten in Brustgewebe (deformable models)
- Abgrenzung Kopf vom Körper des Fetus (deformable models)
- Echokardiogramme (deformable models, phys. Modellierung)
- Koronararterien bei intravaskulärem US (wissensbasiert)

IV. Beispiel automatisches Segmentierungsverfahren

Fragestellung: ischämischer Hirninfarkt

Plötzlich auftretende neurologische Ausfälle unterschiedlichster Ausprägung, die meist auf eine akute Durchblutungsstörung im Gehirn zurückzuführen sind. Beim ischämischen Hirninfarkt ist die Minderdurchblutung Folge eines thrombotischen (Bildung eines Blutgerinnsels als überschüssende Reaktion des Gerinnungssystems) oder embolischen (Verschleppung eines Blutgerinnsels, Gefäßverschlusses).

Folgen:

- Hemiparese
- Arm- u. Gesichtsbereich betonte sensorische Hemiparese
- Hemianopsie zur gelähmten Seite
- abgeschwächte Reflexe sind primär abgeschwächt
- bisweilen Schluckstörungen, Aphasie

Die neurologische Symptomatik bildet sich nur inkomplett bzw. gar nicht zurück oder führt zum Tod (Letalität bei Hirnmassenblutung bis 50%).

IV. Beispiel automatisches Segmentierungsverfahren

Epidemiologie des Hirninfarktes:

- Inzidenz (Neuerkrankungen): ca. 200-350/100.000 Einwohner pro Jahr
- Prävalenz (Krankheitshäufigkeit): 600/100.000 Einwohner
- Größter Risikofaktor: arterielle Hypertonie
- Mortalität: an dritter Stelle nach kardiovaskulären und tumorösen Erkrankungen

Therapie des Hirninfarktes:

- Aufrechterhaltung eines ausreichenden Perfusionsdrucks
- Stabilisierung des Blutzuckers und der Sauerstoffsversorgung
- schneller Transport in ein geeignetes Zentrum zur Hirninfarktbehandlung (Lysetherapie (Fibrinolyse) nur in einem engen Zeitfenster möglich)


Voraussetzung Lysetherapie: Ausschluss einer Hirnblutung (CT)

Probleme: relativ hohes Risiko (Blutungen)

→ möglichst genaue bildgestützte Charakterisierung des Infarktgebietes


IV. Beispiel automatisches Segmentierungsverfahren

CT oder MRT zur Infarkterkennung?



Patient mit ausgedehntem Infarkt nahezu zeitgleiche Untersuchung CT: Standard Kopf-Protokoll MRT: Diffusionswichtung (DWI)

Welche der vielfältigen MRT-Methoden sind am besten geeignet?

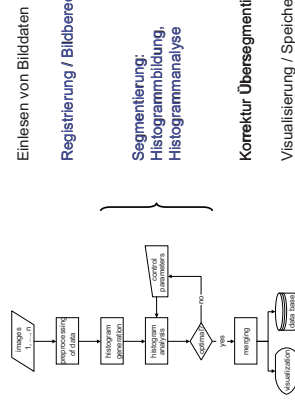


Patient mit akut-chronischem Infarkt Pathophysiologie

chronischer Infarkt akuter Infarkt

IV. Beispiel automatisches Segmentierungsverfahren

Mehrdimensionales (multispektrales), datengetriebenes, eigenschaftsbasiertes Verfahren



IV. Beispiel automatisches Segmentierungsverfahren

Registrierung:

- Die Bilddaten müssen für die notwendigen Bildberechnungen und die Histogrammanalyse deckungsgleich sein
- intramodal: MRT/MRT aber deutliche Kontrastunterschiede innerhalb der Bildserien (T2w, DWI, ADC) → quasi-intermodal
- Registrierung mit Automated Image Registration (AIR) Software
- AIR source code (in C) ist für Forschungszwecke frei verfügbar <http://bishopw.toni.ucla.edu/AIR5/>



Bildberechnungen:


- Die ortsauflöste Verteilung des apparenten Diffusionskoeffizienten (ADC) wird aus mehreren unterschiedlich diffusionsgewichteten Bildern berechnet
- Linear least squares Fit der Signalintensität als Funktion der Stärke der Diffusionswichtung (b-Wert)

4. Beispiel Automatische Segmentierung 37

IV. Beispiel automatisches Segmentierungsverfahren

Segmentierung:

- Histogrammbildung: nD-Histogramm, Eingabedaten beliebig (quantitativ/qualitativ, T1w, T2w, PD, DWI, ADC)
- identische Bildgröße (FOV, Matrix, Schichtdicke, Schichtposition)




4. Beispiel Automatische Segmentierung 38

IV. Beispiel automatisches Segmentierungsverfahren

Segmentierung:

- Histogrammanalyse: Pyramidalalgorithmus mit variabler Schrittweite
- Schrittweite nimmt bei kleiner werdenden Histogrammbesetzungszahlen zu
- Verminderung der Übersegmentierungsproblematik bei Geweben mit breiten Werteverteilungen




4. Beispiel Automatische Segmentierung 39


IV. Beispiel automatisches Segmentierungsverfahren

3D-Histogrammanalyse

MRT Eingabedaten:
T₁, T₂, PD-Wichtung



Segmentierung:
3D-Histogramm,
Histogrammanalyse




Visualisierung

4. Beispiel Automatische Segmentierung 40

IV. Beispiel automatisches Segmentierungsverfahren

Statistische Auswertung der Bilddaten



Aus den Daten können folgende statistische Größen bestimmt werden:

$$\text{Sensitivität} = \frac{TP}{TP + FN}$$


Wahrscheinlichkeit, ein positives Ergebnis auch als solches zu erkennen

$$\text{Spezifität} = \frac{TN}{m + FP}$$

Wahrscheinlichkeit, ein negatives Ergebnis auch als solches zu erkennen

4. Beispiel Automatische Segmentierung 41

IV. Beispiel automatisches Segmentierungsverfahren



- Histogrammbasierte Segmentierung:
- 64 Infarktpatienten, dargestellt sind 5 unterschiedliche Erscheinungsformen von Hirninfarkten
 - Eingabedaten: T2-Wichtung (T2w), Diffusionswichtung (DWI), Diffusionskoeffizient (ADC)
 - Beurteilung gegen „Goldstandard“ (manuelle Segmentierung Radiologe)
 - Ergebnisse: Sensitivität ~ 0.60 (Anteil der richtig als erkrankt erkannten Pixel), Spezifität ~ 0.99 (Anteil der richtig als gesund erkannten Pixel)

4. Beispiel Automatische Segmentierung 42

V. Beispiel interaktives Segmentierungsverfahren

Deformable Model (Snake) Verfahren:

- manuelle Definition einer geschlossenen Kontur auf Bilddaten
- automatische Anpassung der Kontur z.B. durch Grauwertgradienten
- Implementierung des klassischen Snake (Kass et al. 1988) und des SplineSnake-Verfahrens mit kubischen B-Splines (Jacob et al. 2001)

Zielsatzung:

- ein optimierter Parametersatz für jedes Snake-Verfahren
- universell nutzbar für alle Infarkt-Bildern

Probleme:

- unterschiedliche Bildkontraste / Bildinformation

Datenmaterial:

- 78 Schichtdatensätze, Pathologie vom Radiologen definiert
- 28 Patienten (13 weiblich, 15 männlich)
- Durchschnittsalter beim Infarkteintritt $64 \pm 12,67$ Jahre
- Durchschnittliches Infarktalter bei Untersuchung: $4,95 \pm 3,31$ Tage

4. Beispiel Interaktive Segmentierung

43

V. Beispiel interaktives Segmentierungsverfahren

Snake-Energie (E_{snake}) besteht aus mehreren Komponenten. Für das klassische Verfahren sind sie wie folgt definiert:

$$E_{snake} = \int_0^1 E_{intern}(r) ds + \int_0^1 E_{extern}(r) ds + \int_0^1 E_{image}(r) ds$$

mit Bildpunkt $r(s) = x(s), y(s)$

Interne Energie (E_{intern})

$$E_{intern}(r) = Tension(r) + Stiffness(r)$$

Tension: Term 1. Ordnung für die Spannung, Stiffness: Term 2. Ordnung für die Steifheit

Externe Energie (E_{extern})

$$E_{extern}(r) = k |i - r|^2$$

Atraktivität des Bildpunktes i zum Parameter k

Bildenergie (E_{image})

$$E_{image} = W_{lim} \int_0^1 I(r(s)) ds - W_{edge} \int_0^1 \left| \frac{\partial I}{\partial r} \right| ds$$

$I(r)$: Intensität des Bildpunktes r
 W_{lim} : Linienergieparameter, W_{edge} : Kantenergieparameter

4. Beispiel Interaktive Segmentierung

44

V. Beispiel interaktives Segmentierungsverfahren

Bildenergiefunktion für das SplineSnake-Verfahren:

$$E_{image} = \alpha F_{gradient} + \beta F_{region}$$

α, β : Wichtungparameter von gradientenbasierter und regionenbasierter Energie

Gradientenbasierte Energie ($E_{gradient}$)

$$E_{gradient} = \int_S \nabla^2 I(r(s)) ds$$

∇^2 : Gradient, I : Bildintensität am Snakepunkt r , S : Areal innerhalb der Snakekurve

Regionbasierte Energie (E_{region}), statistische Funktion von Staub und Duncan


$$E_{region} = \int_S \log \left(\frac{P(I(r(s)) | s \in S)}{P(I(r(s)) | s \in S')} \right) ds$$

S : Areal innerhalb der Snakekurve, S' : Areal außerhalb der Snakekurve
 P : Wahrscheinlichkeit für die Intensität I eines Bildpunktes r an der Position s

4. Beispiel Interaktive Segmentierung

45

V. Beispiel interaktives Segmentierungsverfahren



- Integration in ImageJ (rsb.info.nih.gov/ij/)

(Image Processing and Analysis in Java)

Universelle Erweiterbarkeit aufgrund integrierter Plugin-Technologie


- Große Entwicklungsgemeinde (open-source) und plattformunabhängig

4. Beispiel Interaktive Segmentierung

46

V. Beispiel interaktives Segmentierungsverfahren

Optimierung der Snake-Parameter durch Analyse von 5 unterschiedlichen, repräsentativen Infarkterscheinungsformen. Gütekriterium: Sensitivität und Spezifität gegen Referenzdaten (manuelle Segmentierung Radiologe).



Resultate für 5 Testdatensätze für das klassische Snake-Verfahren:

- universelles w_{lim} (-0,2) und w_{edge} (0,1) für alle Bilddaten
- eckige, nicht-physiologische Begrenzungen aufgrund des Polygonzugs
- sehr kleine Infarkte werden ungenau segmentiert


4. Beispiel Interaktive Segmentierung

47

V. Beispiel interaktives Segmentierungsverfahren

Resultate für 5 Testdatensätze für das SplineSnake-Verfahren:

- gute Segmentierungsergebnisse für alle Infarkttypen einschließlich des kleinen Infarktes
- gradientenbasierte Bildenergie lieferte die besseren Ergebnisse
- weitgehende Parameterunabhängigkeit der gradientenbasierten Bildenergie
- Relativ unempfindlich gegenüber Bildrauschen
- Die gekrümmte Segmentierungsgrenze des SplineSnake-Verfahrens ist den natürlichen, anatomischen Verhältnissen besser angepasst



4. Beispiel Interaktive Segmentierung

48

V. Beispiel interaktives Segmentierungsverfahren

Ergebnisse für die Snake-Verfahren:

Parameter	Klassischer Snake	SplineSnake	Signifikanz
Sensitivität	0,75 ± 0,12	0,82 ± 0,12	< 0,001
Spezifität	0,9987 ± 0,0012	0,9988 ± 0,0013	0,929

Vergleich mit dem automatischen histogrammbasierten Segmentierungsverfahren:

Parameter	Automatische Segmentierung	Klassischer Snake	Sig.	SplineSnake	Sig.
Sensitivität	0,59 ± 0,20	0,75 ± 0,12	< 0,001	0,83 ± 0,11	< 0,001
Spezifität	0,999 ± 0,009	0,998 ± 0,001	0,242	0,998 ± 0,001	0,219

V. Beispiel interaktives Segmentierungsverfahren

Zusammenfassung der Ergebnisse:

- Snake-Verfahren sind robuste Methoden zur Segmentierung von medizinischen Bildmaterial
- Die Nutzerinteraktion kann durch die Ermittlung universeller Parametersätze auf ein Minimum reduziert werden
- SplineSnake-Verfahren signifikant besser als klassische Snake-Verfahren
- Verbesserung der Sensitivität im Vergleich zur automatischen histogrammbasierten Segmentierung.
- Das SplineSnake-Verfahren ist vorteilhaft zur detaillierten Analyse einsetzbar
- Keine signifikanten Unterschiede hinsichtlich der Spezifität
- Zeitaufwand: 1s automatische Segmentierung pro Schicht gegenüber 10s mittels Snake-Verfahren
- Automatische Verfahren eignen sich besser zum Screening großer Datenmengen.

Zusammenfassung

- Segmentierungsproblem
 - Pixelklassifikation, Kostenfunktion
- Segmentierungsverfahren
 - Schwellwert, Region Growing, Klassifikatoren
 - Cluster-Verfahren, Markov Random Fields
 - Neuronale Netze, deformable models, Atlanten
- Segmentierung und bildgebende Modalitäten
 - Bildqualität, medizinische Fragestellung, Anwendungen
- Beispiel automatisches Segmentierungsverfahren
 - variables Erscheinungsbild der Erkrankung
 - mehrdimensionale Histogramme, Evaluation des Systems
 - Probleme, Vor- und Nachteile
- Beispiel interaktives Segmentierungsverfahren
 - deformable models
 - Probleme, vor- und Nachteile