

# Ein wissensbasiertes dreidimensionales Formmodell für die automatische Nierensegmentierung aus CT-Datensätzen in der Strahlentherapieplanung

Rimon Saffoury

12.01.2015

Computer Science Dept. 5 (Pattern Recognition)

Friedrich-Alexander University Erlangen-Nuremberg



FRIEDRICH-ALEXANDER  
UNIVERSITÄT  
ERLANGEN-NÜRNBERG

TECHNISCHE FAKULTÄT



Ein wissensbasiertes dreidimensionales Formmodell für die automatische Nierensegmentierung aus CT-Datenätzen in der Strahlentherapieplanung

- Einleitung
- Grundlagen
- Segmentierung mit Hilfe der aktiven Formmodelle
- Ergebnisse
- Zusammenfassung und Ausblick


# Einleitung

## Strahlentherapie

Durchführung erfordert Wissen über:

- Volumen des zu bestrahlenden Objekts
- Alter des Patienten
- Gewicht des Patienten
- usw.

## Manuelle Segmentierung...



... hat viele Nachteile:

- sehr aufwändig
- Überlappung von Organen erschwert die Erkennung
- Ergebnisse hängen stark vom Beobachter ab

## Automatische Segmentierung

Zahlreiche Ansätze zur automatischen Segmentierung wurden in den letzten Jahren vorgeschlagen

- Regionorientierte Ansätze
- Atlasbasierte Ansätze
- Modellbasierte Ansätze
  - Aktive Formmodelle (engl. Active Shape Models – ASM)
- ...

## Notes

# Grundlagen



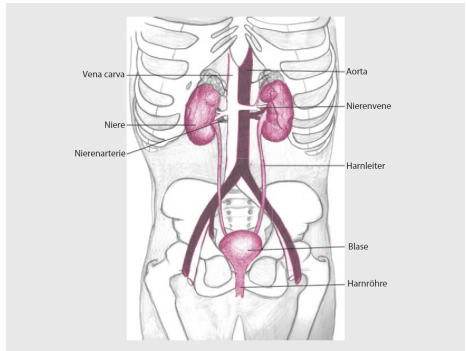
## Anatomie der Nieren

Sie hat eine Länge von ca.  
11 cm  $\pm$  1 cm und eine Breite  
von 5.5 cm  $\pm$  0.5 cm.

Ihr Gewicht beträgt ca. 150 g  
 $\pm$  50 g


Sie hat eine Embryohaltung  
(leichte Krümmung)

Sie befindet sich im  
Retroperitonealraum (hinter  
dem Bauchfell)



Das menschliche Ausscheidungssystem. Rensing, Ludger/ Rippe, Volkhard:  
Altern. Springer Verlag, Berlin 2014.

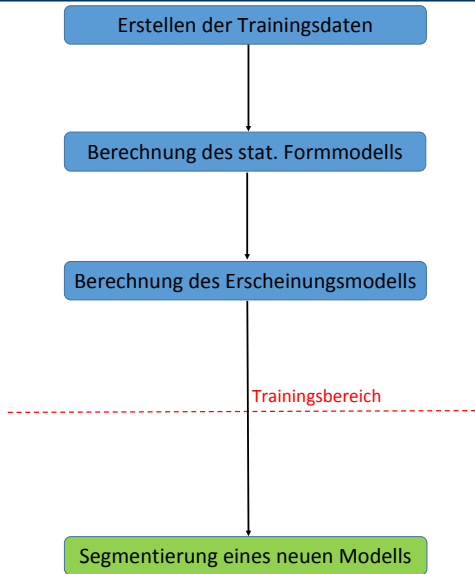
## 3D-CT-Aufnahmen des Abdominalbereichs



Der Abdominalbereich

## Notes

# Segmentierung mit Hilfe der aktiven Formmodelle




Segmentierungsvorgang anhand ASM

## Erstellen der Trainingsdaten

### Workflow


1. Manuelle Segmentierung der Trainingsdaten



## Erstellen der Trainingsdaten

### Workflow

1. Manuelle Segmentierung der Trainingsdaten
2. Produktion der Punktwolken



## Erstellen der Trainingsdaten

### Workflow

1. Manuelle Segmentierung der Trainingsdaten
2. Produktion der Punktwolken
3. Generierung eines Meshes von einem Datensatz

→ Marching Cubes-Algorithmus





## Erstellen der Trainingsdaten


### Workflow

1. Manuelle Segmentierung der Trainingsdaten
2. Produktion der Punktwolken
3. Generierung eines Meshes von einem Datensatz
4. Filtern des Meshes

→ Laplace-Mesh-Glättungsfilter

**Warnung**

**Volumenverlust!**



## Erstellen der Trainingsdaten


### Workflow

1. Manuelle Segmentierung der Trainingsdaten
2. Produktion der Punktwolken
3. Generierung eines Meshes von einem Datensatz
4. Filtern des Meshes
5. Reduktion der Anzahl der Dreiecke des Meshes

→ Garland-Heckbert-Algorithmus

Warnung

Volumenverlust!




## Erstellen der Trainingsdaten

### Workflow

1. Manuelle Segmentierung der Trainingsdaten
2. Produktion der Punktwolken
3. Generierung eines Meshes von einem Datensatz
4. Filtern des Meshes
5. Reduktion der Anzahl der Dreiecke des Meshes
6. Korrektur des Meshes

→ Nächste-Nachbar-Suche




## Berechnung des statistischen Formmodells

### Workflow

1. Anpassung aller Punktwolken an das reduzierte Mesh

→ Iterative-Closest-Point-Algorithmus (ICP)

$$\min(\text{dist}(\hat{X}, P)) \quad \text{mit} \quad \hat{X} = RQ + t$$



Prinzip des ICP-Algorithmus

## Berechnung des statistischen Formmodells

### Workflow

1. Anpassung aller Punktwolken an das reduzierte Mesh
2. Oberflächendezimierung der restlichen Punktwolken

→ Nächste-Nachbar-Suche


## Berechnung des statistischen Formmodells

### Workflow

1. Anpassung aller Punktwolken an das reduzierte Mesh
  2. Oberflächendezimierung der restlichen Punktwolken
  3. Dimensionsreduktion
- Hauptkomponentenanalyse (engl. Principal Component Analysis – PCA)
- Berechnung des mittleren Formmodells  $\bar{\mathbf{x}}$
  - Bestimmung der Eigenvektoren  $\mathbf{P}$  und dazugehörige Eigenwerte  $\lambda$
  - Aufstellung der kumulativen Varianz und Reduktion dieser mit Hilfe eines Varianzkriteriums

$$\mathbf{x} = \bar{\mathbf{x}} + \mathbf{P}\mathbf{b} \quad \text{wobei} \quad |b_j| = 3\sqrt{\lambda_j}$$

## Berechnung des statistischen Formmodells



$$b_1 = -3\sqrt{\lambda_1}$$


mittleres Modell

$$b_1 = 3\sqrt{\lambda_1}$$

## Berechnung des Erscheinungsmodells

### Workflow

1. Minimierung des Rauschens von den Datensätzen  
 → Bilateraler Filter





## Berechnung des Erscheinungsmodells

### Workflow

1. Minimierung des Rauschens von den Datensätzen
2. Extrahieren von 1D-Profilen

Differenzieren: 
$$g_k = I(\mathbf{y}_{k+1}) - I(\mathbf{y}_{k-1})$$

mit 
$$\mathbf{y}_k = \mathbf{p}_{start} + \frac{k-1}{n_p-1}(\mathbf{p}_{end} - \mathbf{p}_{start})$$

Normalisieren: 
$$\mathbf{g}' = \frac{\mathbf{g}}{\sum_{k=1}^{n_p} g_k}$$

## Berechnung des Erscheinungsmodells

### Workflow

1. Minimierung des Rauschens von den Datensätzen
  2. Extrahieren von 1D-Profilen
  3. Berechnung des statistischen Grauwertmodells der korrespondierenden Profile
- entweder durch Hauptkomponentenanalyse (analog zum Formmodell)  
oder Bestimmung der Kovarianzmatrix


## Segmentierung des neuen ungesehenen Modells

### Workflow


1. Platzierung des mittleren Formmodells in der Nähe des zu segmentierenden Objekts (evtl. Skalierung)
2. Extrahieren von 1D-Profilen ( $> n_p$ ) und auf Ähnlichkeit mit den eingelernten Profilen auswerten
  - Mahalanobis-Distanz:  $f(\mathbf{g}_s) = (\mathbf{g}_s - \bar{\mathbf{g}})^T \mathbf{S}_g^{-1} (\mathbf{g}_s - \bar{\mathbf{g}})$
  - Methode der kleinsten Quadrate:  $R^2 = (\mathbf{g}_s - \bar{\mathbf{g}})^T (\mathbf{g}_s - \bar{\mathbf{g}}) - \mathbf{b}_g^T \mathbf{b}$   
mit  $\mathbf{b}_g = \mathbf{P}_g^T (\mathbf{g}_s - \bar{\mathbf{g}})$
3. Projektion des mittleren Modells auf das gefundene Modell und Ermittlung der Gewichtungparameter (unter Einschränkung)
 
$$\mathbf{b} = \mathbf{P}^T (\bar{\mathbf{x}} - \mathbf{x})$$
4. Berechnung des plausiblen Formmodells:  $\mathbf{x}_{res} = \bar{\mathbf{x}} + \mathbf{P}\mathbf{b}$
5. Wdh. Schritt 2–4 bis zum Auftreten eines Konvergenzkriteriums

## Notes

# Ergebnisse



Segmentierungsergebnisse mit 1D- bzw. 2D –Profil unter Verwendung der Methode der kleinsten Quadrate



Segmentierungsergebnisse mit 1D- bzw. 2D -Profil unter Verwendung der Mahalanobis-Distanz

---

## Methode der kleinsten Mahalanobis-Distanz Quadrate

---

initiale Modellform

8.0248

8.0248

nach 2 Iterationen

1D-Profile

4.0228

4.2485

2D-Profile

3.5065

3.8820

nach 7 Iterationen

1D-Profile

1.6447

1.6411

2D-Profile

1.6326

1.6308



## Eigenschaften des trainierten Modells

Kompaktheit	Generalisierungsfähigkeit durch Leave-One-Out- Methode	Spezifität
0	3.0506 <i>mm</i>	2.1466 <i>mm</i>
0.3585	3.0407 <i>mm</i>	2.1628 <i>mm</i>
0.5883	2.8518 <i>mm</i>	2.1436 <i>mm</i>
0.7348	2.8458 <i>mm</i>	2.1635 <i>mm</i>
0.8746	2.8097 <i>mm</i>	2.1961 <i>mm</i>
0.9915	2.8049 <i>mm</i>	2.2307 <i>mm</i>
1	2.7275 <i>mm</i>	2.2243 <i>mm</i>

Eigenschaften des statistischen Formmodells

## Notes

# Zusammenfassung und Ausblick

## Zusammenfassung

### Aktive Formmodelle

- Ein sehr häufig benutzter Algorithmus zur automatischen Segmentierung (2D und 3D)
- Aufwändige Trainingsphase
- Liefert immer plausible Ergebnisse
- Robust gegen Rauschen und Artefakte im Bild
- Nicht geeignet für stark variierende Objekte
- Undenkbar für Modelle, dessen Erscheinungsmodell immer unterschiedlich ist (Tumor)

## Ausblick

### Verbesserungsvorschläge

- Gleichzeitige Segmentierung benachbarter Organe
- Mehr Landmarken
- Edit-Button

Fragen?