

Automatische Detektion von Zwischenorgan-3D-Barrieren in abdominalen CT-Daten

Oliver Mietzner¹ und Andre Mastmeyer²

¹ Universität zu Lübeck, Institut für Medizinische Informatik, 23568 Lübeck

² Hochschule Aalen, Fakultät für Mechatronik und Optik, 73430 Aalen

<http://imi.uni-luebeck.de>, <http://www.hs-aalen.de/faculties/4>

oliver.mietzner@student.uni-luebeck.de, andre.mastmeyer@hs-aalen.de

Zusammenfassung Volumenwachstumssegmentierungstechniken sind oftmals mit der Übersegmentierung angrenzender Organe oder Strukturen behaftet. Segmentierungsbarrieren können hier abhelfen, indem wie bei einem Staudamm eine künstliche Grenze gezogen wird. Aktuell werden diese Markierungen häufig noch als manuelle Scribbles vom Benutzer i.d.R. mühsam schichtweise erstellt. Hier wird ein neuer vollautomatischer Ansatz zum Finden von 3D-Barrieren mit maschinellen Lernmethoden vorgestellt. Die Barrierenfehler unmittelbar angrenzender Organe liegen zwischen $4,9 \pm 1,3$ und $10,3 \pm 3,6$ mm.

1 Einleitung

Ein typisches Problem von Volumenwachstums oder auch GraphCut-Segmentierungen [1], die bspw. für virtuelle 4D-Patientensimulationen benötigt werden [2,3,4,5] ist das Auftreten von Überläufen zwischen eng benachbarten Organen mit vergleichbaren Intensitäten, was zur starken Übersegmentierung eines Organs führt.

Dieses Risiko kann durch die Verwendung von Barrieren mitigiert werden, die das Wachstum stoppen. Wenn der Anwender eine Wachstumsgrenze in den problematischen Bildbereich einfügt, kann das Risiko des Auslaufens gemindert werden. Diese Grenze wird allgemein als „Barriere“ bezeichnet, vergleichbar mit einem Damm, der eine Welle abhält. In der momentanen Praxis muss der Anwender die Barrieren manuell markieren, indem er mühsam Konturen in die Schnittbilder zeichnet [8] oder die falsch segmentierten Bereiche später durch manuelle oder (halb-)automatische Nachbearbeitung der Labels korrigiert¹.

2 Material und Methoden

Der Datenmenge bestand aus 60 abdominalen CT-Scans und Label-Bildern. Die Daten wurden aus drei verschiedenen Segmentierungswettbewerben ausgewählt,

¹ <http://3dslicer.org>

namentlich SLIVER07², LiTS³ und VISCERAL⁴. Die einzelnen Scans unterscheiden sich nicht nur in der Anzahl der Schichten (64-861) bzw. dem Field-of-View (FoV), sondern auch im Bildrauschen. Einige Scans beziehen die Lunge komplett mit ein, während andere nur den unteren Brustbereich zeigen. Wir haben bez. des FoV nur die Scans verwendet, welche die Gesamtheit der fünf Zielorgane (Leber, Nieren, Milz, Bauchspeicheldrüse) enthielten. $\binom{5}{2} = 10$ Organpaarungen sind theoretisch möglich und werden als Paarungen bezeichnet.

Das Ziel unseres neuen Ansatzes ist es, automatisch 3D-Barrieren zwischen bestimmten Organen in abdominalen CT-Scans zu generieren, die innerhalb festgestellter Überlappungen von Bounding-Boxen (BBen) liegen. Wir verwenden zwei verschiedene maschinelle Lernmethoden, um die Barrieren basierend auf Intensitätsmerkmalen vorherzusagen. Die Abb. 1 und 2 stellen Training und Anwendung mit Random-Regression-Forests (RRF) und U-Nets dar.

Die Anwendungsgrundidee ist (Abb. 2), einen dedizierten RRF pro Organ zu verwenden, um die BB-Lagen zu schätzen. Im zweiten Schritt, prüfen wir, ob Überschneidungen zwischen den BBen auftreten. Falls eine Überschneidung detektiert wird, erhält ein U-Net, die entsprechende Region als Eingabe und schätzt die Segmentierung der Strukturen innerhalb der Region. Schließlich kann die so entstandene Segmentierung genutzt werden, um eine Barriere zwischen den Strukturen deterministisch zu generieren.

2.1 Datenvorbereitung

Es war regelmäßig notwendig, einige relevante Strukturen, insbesondere die Bauchspeicheldrüse, manuell zu segmentieren, da diese nicht in den Challenge-Daten enthalten waren. Neue Segmentierungen wurden von zwei Experten geprüft. Die Segmentierungen lieferten nun die BBen der Organe.

² <http://sliver07.org>

³ <http://competitions.codalab.org/competitions/17094>

⁴ <http://visceral.eu/closed-benchmarks/anatomy3>




Abbildung 1. Training der RRF und U-Nets: Dem RRF, dienen Voxel (p) und zugehörigen Feature Boxen (F_j) als Eingabe, um die Distanz der Voxel zur Organ-BB zu lernen. Dem U-Net wurden Schnitt-VOI-Intensitäten und Masken übergeben.

2.2 Gemeinsam genutzte Methoden in Training und Anwendung

Bounding-Box-Überschneidungen: Um eine Barriere zwischen nahen oder sich berührenden abdominalen Organen grob zu lokalisieren, nutzen wir Quader, welche durch die Überlappung von BBen definiert werden. Hierfür müssen sich die zugehörigen BB-Intervalle in jeder Dimension überschneiden. Hierzu wird jede Koordinaatenachse sequentiell auf eine Überschneidung untersucht und eine Überlappungsregion in Form des Schnittquaders entsteht. Während des Trainings, stellten wir fest, dass in der Praxis Überschneidungen zwischen den Nieren und zwischen Milz und rechter Niere nicht auftraten. Falls ein Schnitt detektiert wurde, wird das Volume-of-Interest (VOI) weiter untersucht (Abb. 3(b)).

2.3 Training der Modelle

Trainieren von Random-Forests für die BB-Detektion: Für die Schätzung der Koordinaten der BBen, nutzen wir pro Organ einen RRF [6]. Hierbei wird eine 3D-Organ-BB als ein 6D-Vektor $b = (x^L, x^R, y^A, y^P, z^H, z^F)$ in mm definiert. In Training und Anwendung iterieren wir über alle Voxel $p = (x_p, y_p, z_p)$, welche sich in einem bestimmten Radius ($r=5$ cm) zur Scan-Medialachse befinden (Zentrumszylinder). Der Distanzvektor eines solchen Voxels zu jeder der BB-Wände, berechnet durch $d(p) = (x_p - x^L, x_p - x^R, y_p - y^A, y_p - y^P, z_p - z^H, z_p - z^F)$, wird als Ausgabe gelernt. Für die Generierung des Eingabe-Feature-Vektors, nutzen wir im Gegensatz zu [6] nur 50 auf drei Kugelschalen ($r=5$ cm; 2,5 cm; 1,25 cm) gleichmäßig verteilte Feature-Boxen (FBen). Diese FBen F_j (Abb. 1) sollen den räumlichen und Intensitätskontext der BBen einfangen. Hierfür wird der Mittelwert der in den FBen enthaltenen Intensiten berechnet und in den Feature-Vektor der Länge 50 eingetragen. Der RRF lernt nun im Training anhand der FBen den Distanzvektor (Ausgabe) zur passenden BB.

Training eines U-Net für die semantische VOI-Segmentierung: Die Trainingsgrundlage für unser U-Net bilden die Expertensegmentierungen und die BB-Überlappungs-VOIs (siehe 2.2). Die VOIs werden dann genutzt um lokal die Intensitäts- und Label-Daten zu extrahieren. Als Eingabe erhält das U-Net somit eine VOI aus den Intensitätsdaten, während die gleiche Region innerhalb der Label-Daten als Ausgabe genutzt wird. Wir verwenden die U-Net-Architektur [7], die aus neun Layern mit vier Encoder-Decoder-Schritten besteht. Für jede der acht Organpaarungen haben wir je ein Modell trainiert.




Abbildung 2. Anwendung der BB- und Barrierendetektion: Flowchart der sequentiellen Anwendung unseres Verfahrens auf ungesehene, abdominale CT-Daten.

2.4 Anwendung der Modelle

Bounding-Box und überschneidungsdetektion: Die organspezifischen RRFs erkennen zunächst die Organ-BB-Kandidaten. Anschließend wird mittels Mehrheitsvotierung ein Distanz-Vektor ausgewählt und in einen 6D-BB-Vektor und somit eine finale organspezifische BB-Schätzung umgerechnet. Ihre Überschneidungen werden als VOIs für die typischen acht Organpaarungen, wie in Abschnitt 2.2 beschrieben, berechnet.

Partielle Segmentierung von Organen in BB-Schnittmengen: Nun bekommt das paarabhängige U-Net-Modell die entsprechende VOI als Eingabe. Jede detektierte VOI wird separat segmentiert und zur Erzeugung der Segmentierungsbarriere mit euklidischer Morphologie verwendet.

Barrieregenerierung: Wie in Abb. 3 zu sehen ist, werden die Segmentierungsbarrieren durch die Verwendung der VOIs zwischen den Organ BBen erzeugt. Um eine Barriere zu modellieren, wenden wir morphologische Operationen mit symmetrischen Kernen an. Zunächst wird die Anzahl der vorhandenen Organe im VOI bestimmt. Es gibt drei Fälle: (1) Falls im klassifizierten Teilbild keine Struktur vorhanden ist, passiert nichts. (2) Wenn eine Struktur gefunden wird, dilatieren wir sie heuristisch, bis sie die Hälfte des VOI-Volumens enthält und extrahieren die Trennfläche zwischen Hintergrund und Objekt als Barriere. Alternativ kann das Objekt auch bereits groß genug sein, dann wird nur eine Dilatation (Sicherheitsabstand) durchgeführt. (3) Wenn zwei oder mehr Objekte vorhanden sind, dilatieren wir alle Objekte, bis jeder Teil des VOI eindeutig ge-labelt ist. Die 3D-Barriere wird dann durch die sich berührenden Grenzen der Objekte definiert 3(b). Abb. 4 veranschaulicht eingefügte 3D-Barrieren.

2.5 Evaluation

Es wurde eine fünffache Monte-Carlo-Kreuzvalidierung basierend auf einer 30:20 (trainieren:testen) Patientendatenaufteilung verwendet. Das praktisch nicht relevante Paar „Leber:linke Niere“ mit ohnehin großer Distanz wurde berücksichtigt. Die resultierenden U-Net-Barrieren wurden anhand von Oberflächenabständen bewertet, d.h. dem mittleren Oberflächenabstand (MOA) und Hausdorff-Abstand (HA) [9].




Abbildung 3. 2D Organschema und eine BB-Überschneidung: (a) Das Abschätzen der räumlichen Nähe zweier Objekte ist mittels BB's möglich. (b) Falls eine Kollision zwischen BB's detektiert wird, wird morphologisch eine Trennfläche erstellt.

Tabelle 1. Ergebnistabelle: über der Hauptdiagonale: HA [mm]. Darunter: MOA [mm].

	Leber	Niere links	Niere rechts	Pankreas	Milz
Leber	-	23,5±9	29,1±16	19,4±8	20,5±11,4
Niere links	12,3±1,8	-	n.v.	17,2±1,4	21,9±7,4
Niere rechts	6,88±1,4	n.v.	-	19,7±10,4	n.v.
Pankreas	4,9±1,3	5,9±4,5	10±3,6	-	15±7,9
Milz	9,1±3	9,1±0,5	n.v.	9,5±4,2	-

3 Ergebnisse

Während sich einige BBen sehr häufig überschneiden (Leber:rechte Niere), waren andere selten, so dass die Paarungen innerhalb der Trainingsdaten nicht gleich verteilt waren. Abb. 4 zeigt zwei gefundene 3D-Barrieren am Pankreas. Tab. 3 zeigt MOA- und HA-Ergebnisse (Ausreißer) für detektierten vs. Goldstandardbarrieren für die Organpaarungen mit BB-Überschneidungen.

4 Diskussion

Die Trainingsdaten waren nicht für alle Organpaarungsmodelle von gleicher Mächtigkeit. Dies könnte durch die Patientendatenergänzung für selten vorkommende Paarungen angegangen werden. Die gefundenen BBen waren vergleichbar mit den Ergebnissen von [6]. Wir haben jedoch andere Daten und ein effizienteres Training mit nur 50 FBen gewählt und zudem größere BBen generiert. Dieser Unterschied kann für die hier vorgestellten weiteren Schritte günstig genutzt werden. Unser Random-Forest bevorzugt höhere/niedrigere Werte für Maximal-/Minimalwerte der BB-Grenzen. Größere 3D-Barrieren sind von Vorteil für die Gesamtbildsegmentierung mit Barrieren in Zukunft. Die lokal-partiellen Segmentierungen aus unseren U-Net-Modellen kann nicht mit anderen Ansätzen




Abbildung 4. Beispiel einer 3D Barriere zwischen 2 Organen: (a) PA-Ansicht: Die Organe Leber (lila) und Bauchspeicheldrüse (weiß) werden durch eine Barriere (grün) räumlich getrennt. (b) Ansicht von oben: Die Organe Niere (rot) und Bauchspeicheldrüse (weiß) werden durch eine Barriere (grün) räumlich getrennt.

verglichen werden, da für die neue Methode mit keine Vergleichsdaten existieren. Die Barrieren wurden nicht direkt gelernt, da sie nur dünne Strukturen mit wenig Intensitätsinformationen darstellen, was die Robustheit der Modelle in Frage stellen würde. Einige Paarungen ergaben regelmäßig kleine VOIs, die schwer zu segmentieren sind. Dies erklärt die schlechtere Leistung in Tab. 1 einiger Modelle, beispielsweise Leber:Milz mit dem MOA $9,1\pm 3$ mm und HA $20,5\pm 11,4$ mm. Schwierige Organpaarungen mit der Bauchspeicheldrüse führten oft zu schlechten Ergebnissen mit MOA von $10\pm 3,6$ mm und HA $19,7\pm 10,4$ mm. Beispielsweise ist der MOA bei dem nicht relevanten Paar „Leber:Niere links“ am größten. Zwischen diesen Organen sind stark individuelle Strukturen wie unterschiedlich gefüllter Magen und Darm, welche nicht gut maschinell gelernt werden können. Dennoch verursacht eine ungenaue U-Net-Segmentierung nicht zwangsläufig eine unnützliche Barriere, die aufgrund des Spielraums zwischen den Organen qualitativ richtig liegen kann. Folglich wird sich die zukünftige Arbeit mit der Barriere-gestützten Gesamtbildsegmentierung befassen.

Danksagungen: DFG-Projekt: MA 6791/1-1.

Literatur

1. Mastmeyer A, Fortmeier D, Handels H. Efficient patient modeling for visuo-haptic VR simulation using a generic patient atlas. *Computer methods and programs in biomedicine*; 2016, 132:161-75.
2. Mastmeyer A, Fortmeier D, Schroeder J, Handels H. Real-Time ultrasound simulation for training of us-guided needle insertion in breathing virtual patients. *Medicine Meets Virtual Reality 22 - MMVR22*; 2016, S. 220:219.
3. Mastmeyer A, Fortmeier D, Handels H. Random forest classification of large volume structures for visuo-haptic rendering in CT images. In *Medical Imaging 2016: Image Processing*. International Society for Optics and Photonics; 2016, S. 97842H.
4. Mastmeyer A, Wilms M, Handels H. Population-based respiratory 4D motion atlas construction and its application for VR simulations of liver punctures. In *Medical Imaging 2018: Image Processing*. International Society for Optics and Photonics; 2018, S. 10574:17.
5. Mastmeyer A, Wilms M, Handels H. Interpatient respiratory motion model transfer for virtual reality simulations of liver punctures. *arXiv.org*; 2017, 1707.08554, S. 1-10.
6. Criminisi A, Robertson D, Pauly O, Glocker B, Konukoglu E, Shotton J, Mateus D, Martinez Möller A, Nekolla SG, Navab N. Anatomy Detection and Localization in 3D Medical Images. In: Criminisi A, Shotton J, editor. *Decision Forests for Computer Vision and Medical Image Analysis*. London (GBR): Springer-Verlag; 2013, S. 193-210.
7. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *arXiv.org*; 2015, 1505.04597, S. 1-8.
8. Zou Z, Liao SH, Luo SD, Liu Q, Liu SJ. Semi-automatic segmentation of femur based on harmonic barrier. *Computer Methods and Programs in Biomedicine*; 2017, 143:171-184.
9. Taha AA, Hanbury A. Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. *BMC medical imaging*; 2015, 15(29).