Segmentacija srca iz CT snimaka pomoću ITK

Habijan, Marija

Master's thesis / Diplomski rad

2015

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:473515

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-26**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

ELEKTROTEHNIČKI FAKULTET

Sveučilišni studij

SEGMENTACIJA SRCA IZ CT SNIMAKA POMOĆU ITK

Diplomski rad

Marija Habijan

Osijek, 2015.

Sadržaj

1. Uvod 1
   1.1. Zadatak diplomskog rada 2
   1.2. Organizacija rada 2
2. Medicinske slike 3
   2.1. Stvaranje slika pomoću rendgenskih zraka 3
   2.2. Računalna tomografija 5
   2.3. DICOM format slika 6
      2.3.1. Tehnički pregled DICOM standarda 6
      2.3.2. Prikaz DICOM slika 7
   2.4. Anatomija srca 8
3. Metode za analizu medicinskih slika 10
   3.1. Predobrada slike 10
      3.1.1. Anizotropna difuzija 11
      3.1.2. Gaussov gradijentni operator 12
      3.1.3. Filtriranje Sigmoid filtrom 13
   3.2. Segmentacija 13
   3.3. Deformabilni modeli 15
      3.3.1. Level-set metoda 16
      3.3.2. Algoritamski opis level-set metode 18
   3.4. Fast marching metoda 19
   3.5. Segmentacija detekcijom oblika 21
      3.5.1. Proširivanje funkcije brzine 22
      3.5.2. Proširivanje uskog pojasa sa ponovnom inicijalizacijom 23
   3.6. Geodetske aktivne konture 25
   3.7. Binarizacija 26
4. Programska implementacija 27
   4.1. Implementacija pomoću Insight Toolkit-a 27
      4.1.1. Implementacija koraka predobrade 28
      4.1.2. Implementacija segmentacije fast marching metodom 29
      4.1.3. Implementacija segmentacije detekcijom oblika 30
      4.1.4. Implementacija segmentacije geodetskim aktivnim konturama 30

4.2. Fast Light Toolkit 31
5. Segmentacija srca 33
5.1. Rezultati dobiveni predobradom slika 34
5.2. Rezultati segmentacije dobiveni *fast marching* metodom 36
5.3. Rezultati segmentacije dobiveni metodom detekcije oblika 40
5.4. Rezultati dobiveni metodom geodetskih aktivnih kontura 45
5.5. Usporedba dobivenih rezultata 49
6. Zaključak 54
7. Literatura 55

Sažetak i ključne riječi

Segmentacija srca iz CT snimaka pomoću Insight Toolkit-a

Sažetak

Osnovni cilj rada je predstaviti sustav za segmentaciju srca iz CT slika kardiovaskularnog sustava. Predstavljena je implementacija triju metoda za segmentaciju medicinskih slika. Implementirani sustav sastoji se od dva osnovna dijela. Prvi dio je predobrada kojim se slike pripremaju za drugi dio: korak segmentacije. Opisane su teorijske osnove geometrijski deformabilnih modela, sa naglaskom na *fast marching* metodu, metodu detekcije oblika te metodu geodetskih aktivnih kontura. Implementacija navedenih metoda provedena je u programskom jeziku C++ uz pomoć biblioteka iz alata Insight Toolkit. Prikazani su dobiveni rezultati predobrade i segmentacije za svaku od navedenih metoda. Na kraju je prikazana usporedba dobivenih rezultata segmentacije.

Ključne riječi

digitalna analiza slike, segmentacija srca, fast marching level-set metoda, metoda detekcije oblika, geodetske aktivne konture

Heart segmentation from CT images using Insight Toolkit

Abstract

The main goal of this paper is segmentation of the heart from cardiac CT images. The implementation of three methods for medical images segmentation is introduced in the paper. The action of implemented system is based on two main stages. First stage is preprocessing of the input images in which images are prepared for second stage: segmentation. Theoretical fundamentals of geometrical deformable models, with the emphasis on fast marching, shape detection and geodesic active contours are given. The system is implemented in programming language C++ with the help of libraries from Insight Toolkit. The results of efficiency are processed and displayed on actual images. Finally, comparison of obtained results is shown.

Keywords

digital image analysis, heart segmentation, fast marching level-set method, shape detection level-set method, geodesic active contours