

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**MEDİKAL GÖRÜNTÜLER İÇİN YENİ BİR BÖLÜTLEME
ALGORİTMASI VE ANALİZ UYGULAMASI**

Serhat CAN

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**ANKARA
2018**

Her hakkı saklıdır

TEZ ONAYI

Serhat CAN tarafından hazırlanan “**Medikal Görüntüler için yeni bir bölümlleme algoritması ve analiz uygulaması**” adlı tez çalışması 06/08/2018 tarihinde aşağıdaki jüri tarafından oy birliği ile Ankara Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi Mehmet Serdar GÜZEL
Ankara Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı



Jüri Üyeleri:

Başkan : Doç. Dr. İ. Tolga MEDENİ
Yıldırım Beyazıt Üniversitesi İşletme Fakültesi



Üye : Dr. Öğr. Üyesi Gazi Erkan BOSTANCI
Ankara Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı



Üye : Dr. Öğr. Üyesi Mehmet Serdar GÜZEL
Ankara Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı



Yukarıdaki sonucu onaylarım.

Prof. Dr. Atila YETİŞEMİYEN
Enstitü Müdürü

ETİK

Ankara Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki bütün bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

06.08.2018



Serhat CAN

ÖZET

Yüksek Lisans Tezi

MEDİKAL GÖRÜNTÜLER İÇİN YENİ BİR BÖLÜTLEME ALGORİTMASI VE ANALİZ UYGULAMASI

Serhat CAN

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Mehmet Serdar GÜZEL

Medikal görüntüler tıbbi alanda teşhis ve tedavi gibi amaçlar için kullanılan verilerdir. Bu veriler üzerinden anlamlı çıkarımlarda bulunmak medikal uğraşı alanının yanı sıra görüntü işleme alanı için de ayrı bir çalışma konusu oluşturmaktadır. Esasında, medikal görüntüler üzerinden anlamlı verilerin elde edilmesi, görüntü işleme çalışmalarında ayrı bir ihtisas gerektiren önemli bir çalışma alanı olarak kabul edilmektedir. Elde edilen veriler, hekime hastaya ait teşhis ve tedavi yöntemleri ile ilgili nasıl bir yol izlemesi hususunda önemli bilgiler sunmaktadır. Bu bağlamda, medikal görüntülerden karaciğer, akciğer, kalp, beyin vb. organların CT ve MR gibi görüntüleme yöntemleri ile elde edilen DICOM formatındaki imgelerinden, görüntü işleme yöntemleri ile veri çıkarımı yapmak günümüzde popüler ve önemli bir çalışma alanı olarak kabul edilmektedir.

Bu çalışma, medikal resimlerden karaciğer dokusunu, bölütleme yöntemleri ile tespit edip karaciğer dokusuna ait özelliklerin çıkarımını sağlayan yeni bir yöntem önermiş ve bu yöntemi kullanan bir uygulanmanın sonuçlarını detayları ile tartışmıştır. Bu çalışma kapsamında karaciğer organının bulunması, hacminin belirlenip görselleştirilmesi, 3-B modellenmesi ve doku kesitinin gerçekçi oranda hesaplanmasını sağlayan özgün algoritmalar önerilmiş ve bu algoritmaların gerçekleştirildiği özgün bir yazılım deneyler için geliştirilerek algoritmaların doğrulanması sağlanmıştır.

Ağustos 2018, 72 sayfa

Anahtar Kelimeler: Medikal Görüntü, Bölütleme Algoritması, Resim İşleme, Karaciğer Analizi, DICOM Görüntüler.

ABSTRACT

Master Thesis

A NEW SEGMENTATION ALGORITHM FOR MEDICAL IMAGES AND ANALYSIS APPLICATION

Serhat CAN

Ankara University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Dr. Mehmet Serdar GÜZEL

Medical images are mainly used with the purpose of diagnoses and treatment in medicine and corresponding fields. Having obtained meaningful results from those images do not only concern medical subject but also interests image processing. Essentially, analyzing medical images are considered as a new and critical field in image processing. These meaningful data may provide crucial information to surgeons or other doctors in terms of finding the best diagnosis and also preplanning of treatments. Analyzing medical images in DICOM format, employing medical visualization techniques such as CT and MR, facilitate to evaluate medical images of vital organs, namely, liver, lung, heart and brain, which has also been accepted as a popular research field in medical image processing.

This study proposes a new approach to extract and analyses tissue features of livers from medical images based on segmentation techniques. As well as, the results of an application using this approach is discussed in detail. Overall this study proposes novel algorithms for detection, volume estimation, visualization, 3-D modeling and accurate tissue slice estimation of liver organ respectively. As well as a new software is implemented for experiments so as to verify the performance of those algorithms.

August 2018, 72 pages

Key Words: Medical Image, Segmentation Algorithm, Image Processing, Liver Analysis, DICOM images.

TEŐEKKÜR

Söz konusu tez çalışmasının yürütülmesinde başından sonuna kadar arařtırmalarımın her aşamasında bilgi, öneri ve yardımlarını esirgemeyerek akademik ortamda olduđu kadar beşeri ilişkilerde de engin fikirleri ile yetiřme ve gelişmeye büyük emeđi bulunan tez danışmanım ve deđerli hocam Sayın Öğretim Üyesi Dr. Mehmet Serdar GÜZEL'e (Ankara Üniversitesi Bilgisayar Mühendisliđi Anabilim Dalı) ve Tıbbi alanda gerekli akademik bilgi ve destekleri ile tez çalışmamda büyük katkıda bulunan Ankara Üniversitesi Tıp Fakültesi Cerrahi Tıp Bilimleri Bölümünden Sayın Doç. Dr. Deniz BALCI hocam'a sonsuz řükranlarımı ve saygılarımı sunarım.

Serhat CAN
Ankara, Ađustos 2018



İÇİNDEKİLER

TEZ ONAYI SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
TEŞEKKÜR	iv
KISALTMALAR	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	x
1. GİRİŞ.....	1
2. MEDİKAL GÖRÜNTÜ VE KARACİĞER ANATOMİSİ.....	3
2.1 Bilgisayarlı Tarama	3
2.2 Karaciğer Anatomisi	4
3. BÖLÜTLEME YÖNTEMLERİ	7
3.1 Eşikleme Tabanlı Bölütleme Yöntemi	7
3.2 Bölgesel Tabanlı Bölütleme Yöntemi.....	8
3.2.1 Bölge Genişletme.....	8
3.2.2 Bölge Ayrıştırma ve Birleştirme.....	9
3.3 Sınıflandırma Tabanlı Bölütleme Yöntemi	10
3.3.1 K-Means yöntemi.....	10
3.3.2 Fuzzy C-Means yöntemi.....	12
3.4 Watershed Bölütleme Algoritması.....	13
3.5 Maksimum Olasılık ve Gaussian Yoğunluk Tahmini	15
3.6 Bayesian Sınıflandırma	16
3.7 Snake (Aktif Kontur) Yöntemi.....	17
3.8 Level Set and Curve Evolution.....	20
4. GÖRÜNTÜ İYİLEŞTİRME YÖNTEMLERİ.....	26
4.1 Gaussian Tabanlı Yumuşatma	26
4.2 Anizotropik Difüzyon Filtresi.....	27
5. KARACİĞER BÖLÜTLEME YÖNTEMLERİ	30
5.1 Bölgesel Tabanlı Bölütleme	32
5.2 Sınıflandırma Tabanlı Bölütleme.....	35

5.3 Level Set Bölütleme	35
5.3.1 Yumuşatma Filtresi	36
5.3.2 Eğim Büyüklük Filtresi	37
5.3.3 Sigmoid Filtresi	38
5.4 Karaciğer Bölütleme Problemleri	40
5.4.1 Doğruluk sorunu	40
5.4.2 Çalışma zamanı sorunu	41
6. KARACİĞER BÖLÜTLEMEDE YENİ YAKLAŞIM.....	42
6.1 3B Bölge Genişletme.....	43
6.1.1 Eşik Değer belirleme işlemi.....	45
6.1.1.1 Tam otomatik eşik değer belirleme işlemi	45
6.1.1.2 Kullanıcı tabanlı eşik değer belirleme işlemi	46
6.1.2 Başlangıç noktası konumlandırma.....	46
6.2 Ön İşlemler.....	46
6.2.1 Gaussian Yumuşatma.....	47
6.2.2 Dilation/Erosion	48
6.3 Kontur Tespiti.....	49
6.4 Kontur Seçimi	51
6.5 Kontur Düzeltme	53
7. DENEYSEL SONUÇLAR.....	60
8. SONUÇ	67
KAYNAKLAR	69
ÖZGEÇMİŞ.....	72

KISALTMALAR DİZİNİ

CT	Computer Tomography
MR	Magnetic Resonance
RG	Region Growing



ŞEKİLLER DİZİNİ

Şekil 2.1 CT-Kesit.....	3
Şekil 2.2 CT-Scan	4
Şekil 2.3 Kesit Karaciğer görüntüsü (Karaciğer Kırmızı Renkte).....	5
Şekil 2.4 Genel Karaciğer Anatomisi.....	6
Şekil 3.1 Bölge Genişletme Formülü	8
Şekil 3.2 Bölge Genişletme Adımı	9
Şekil 3.3 Bölge Ayrıştırma ve Birleştirme.....	9
Şekil 3.4 K-means algoritma akış şeması	11
Şekil 3.5 Binary Resim	14
Şekil 3.6 Watershed Eğim Resmi.....	14
Şekil 3.7 Gri Resim	14
Şekil 3.8 Bölütlenmiş Resim.....	15
Şekil 3.9 Kontur Gelişim Eğrisi	18
Şekil 3.10 Kontur Gelişim Eğrisi Yerel Minimum Hatası.....	20
Şekil 3.11 Kontur Gelişim Eğrisi Çoklu Nesne Durumu.....	20
Şekil 3.12 Kontur	21
Şekil 3.13 Düzgün Yayılımlı Eğri.....	21
Şekil 3.14 Eğri Gelişimi	23
Şekil 3.15 Kontur Adım-18.....	24
Şekil 3.16 Kontur Adım-40.....	24
Şekil 3.17 Kontur Adım-51	24
Şekil 3.18 Kontur Adım-72.....	25
Şekil 4.1 Gaussian Kernel.....	27
Şekil 4.2 CT-Image	28
Şekil 4.3 CT Resim Gaussian Yumuşatma	28
Şekil 4.4 CT Resim Anizotropik Difüzyon.....	28
Şekil 5.1 Sağlıklı Karaciğer dokusu.....	30
Şekil 5.2 Hastalıklı Karaciğer dokusu.....	31
Şekil 5.3 CT- Doku Çeşitleri.....	31
Şekil 5.4 Bölgesel Büyüme Bölütleme Yöntemi	32
Şekil 5.5 Doğru Bölütlenmiş Alan	33

Şekil 5.6 Sınıflandırma Tabanlı Bölütleme.....	35
Şekil 5.7 Orijinal Resim.....	36
Şekil 5.8 Anizotropik Difüzyon Filtresi Çıktısı.....	37
Şekil 5.9 Eğim Büyüklük Filtresi Çıktısı.....	38
Şekil 5.10 Sigmoid Filtresi Çıktısı.....	39
Şekil 5.11 Level Set Bölütleme Algoritması.....	39
Şekil 5.12 Karaciğer Bölgesi.....	40
Şekil 5.13 3B-Karaciğer Bölüt Yüzeyi.....	41
Şekil 6.1 Algoritma Akış Şeması.....	43
Şekil 6.2 3B Bölge Genişletme Çıktısı.....	44
Şekil 6.3 3B Doğru Karaciğer Yüzeyi.....	44
Şekil 6.4 Doğru Belirlenmiş Eşik Değer Aralıkları (İşaretli Mavi Renk).....	45
Şekil 6.5 2B Binary Resim.....	47
Şekil 6.6 2B Yumuşatılmış Binary Resim.....	47
Şekil 6.7 Dilation İşlemi.....	48
Şekil 6.8 Dilation/Erosion Binary Görüntü.....	49
Şekil 6.9 Binary Görüntü.....	50
Şekil 6.10 Binary Kontur Görüntü.....	50
Şekil 6.11 Laplacian Kernel.....	51
Şekil 6.12 Kontur Görüntüler.....	52
Şekil 6.13 Optimum Kontur Görüntü.....	52
Şekil 6.14 3B Binary Yüzey (Birleştirilmiş kontur kümeleri).....	53
Şekil 6.15 Hatalı Karaciğer Bölütü.....	54
Şekil 6.16 Eğim Haritası.....	55
Şekil 6.17 Binary Kontur Görüntü.....	55
Şekil 6.18 Binary Kontur Eğim Haritası.....	55
Şekil 6.19 Ortalama Eğim Grafiği.....	57
Şekil 6.20 Axial- Kesit Resim.....	58
Şekil 6.21 Axial-Binary Resim.....	58
Şekil 6.22 Sagittal-Kesit Resim.....	58
Şekil 6.23 Sagittal-Binary Resim.....	59
Şekil 7.1 Medikal Görselleştirme ve Analiz Uygulaması.....	60

ÇİZELGELER DİZİNİ

Çizelge 5.1 Algoritmaların Karşılaştırılması	34
Çizelge 7.1 Önerilen Algoritmanın Test Sonuçları.....	61



1. GİRİŞ

Medikal resim, CT görüntüler üzerinde karaciğer bölütlemesi ve hacim tahmini gibi işlemler klinik uygulamalarda önemli bir yer tutar. Günümüzde karaciğer sirozu, karaciğer tümörleri, karaciğerin büyümesi gibi birçok karaciğer ile ilgili hastalıklar oluşmaktadır. Bu hastalıkların doğru ve etkin tedavi yöntemleri için medikal görüntüleme ve analiz alanında uygulamalar geliştirilmektedir. Bu uygulama ve algoritmalar ile karaciğerin CT resimlerden doğru, hızlı ve otomatik bölütlemesi hedeflenmektedir.

Önerilen çalışma iki ana bölümden oluşmaktadır. Bunlar sırasıyla, Geleneksel bölütleme algoritmalarının incelenmesi ve yeni bir karaciğer bölütleme algoritmasının sunulması ve tıbbi veriler üzerinden doğrulanmasıdır. Bu çalışmanın ilk kısmında literatürdeki bazı bölütleme yöntemlerinin matematiksel ve algoritma bazında incelenip uygulamalı örnekler ile test edilmiştir. Literatürde bölütleme yöntemleri ile ilgili farklı yaklaşımlar bulunmaktadır. Bu yaklaşımlar Geleneksel ve İleri Bölütleme yöntemleri olarak incelenebilir.

1) Geleneksel Bölütleme Yöntemleri;

- a) Eşikleme Tabanlı Bölütleme Yöntemi
- b) Bölgesel Tabanlı Bölütleme Yöntemi
- c) Sınıflandırma Tabanlı Bölütleme Yöntemi
- d) Watershed Bölütleme Algoritması

2) İleri Bölütleme Yöntemleri;

- a) Maksimum olasılık ve Gaussian yoğunluk tahmini
- b) Bayesian Sınıflandırma
- c) Snake (Aktif Kontur) Yöntemi
- d) Level Set and Curve Evolution (Seviye Dizi ve Eğri Evrimi)

Bu alıřmanın ikinci kısmı literatürdeki bazı yöntemleri kullanarak, gelişmiş, etkin ve hızlı karaciğer bölütleme algoritmasının oluşturulması ve deneysel testler ile bu yöntemin doğrulanması aşamalarını içermektedir.




2. MEDİKAL GÖRÜNTÜ VE KARACİĞER ANATOMİSİ

Bu bölümde sırasıyla, medikal görüntüleme teknikleri ve karaciğerin anatomisi detaylandırılacaktır. Popüler medikal görüntüleme tekniklerinden olan Bilgisayarlı Tarama (CT) ve karaciğer organının yapısı detaylı olarak incelenecektir.

2.1 Bilgisayarlı Tarama

Bilgisayarlı Tarama (CT-Computerized Tomography) X-ray makinasının özel bir tarama türüdür. Taranacak olan bölge belirli zaman aralıklarında ve farklı ışın boyutlarında taranarak bir axial kesit elde edilir. Bu bağlamda elde edilen axial kesitlerin toplamı ile vücudun çoğu bölgesini medikal resim olarak ifade edilebilir. Bu axial kesitler bir ekmeğin dilimleri şeklinde düşünülebilir ve bu kesitlere slice adı verilir (Şekil 2.1). Bu kesitlerin ifade ettiği medikal resimler doktorlar tarafından farklı teşhis ve tedavilerde kullanılır.



Şekil 2.1 CT-Kesit (<https://www.quora.com/2018>)



Şekil 2.2 CT-Scan (<https://en.wikipedia.org/2018>)

CT Sistemin çalışma mantığı (Şekil 2.2)

- Hareket eden bir tabla üzerinde hasta CT tarayıcısının içine doğru yönlendirilir.
- Hasta tarayıcının içinde iken, X-ray ışın kaynağı ve bu ışın kaynağını döndüren bir detektör kullanılarak tarama yapılır ve ışın kaynağı döndürücü mekanizmadan ortalama 1sn de bir kesit almaktadır.
- Hastanın X-ray ışın kaynağı ile çekilmiş farklı açılardan elde edilen görüntüler toplanır.
- Elde edilen bu görüntüler bilgisayara gönderilir ve burada işlenerek farklı açılardan çekilmiş görüntüler birleştirilir.

Elde edilen veriler kas, kemik, organ gibi dokuların görüntülerini içermektedir. Bu dokular CT görüntülerde farklı yoğunluk ve piksel değerleri ile ifade edilir. Bu sayede bir medikal resimdeki dokular göz ile ayırt edilebilme özelliğine sahip olur.


2.2 Karaciğer Anatomisi

Karaciğer anatomik olarak diyafram ve midenin üstünde, karın boşluğunun sağ üst kısmında yer alır. Şekil olarak koniye benzemektedir (Şekil 2.3). Sağlıklı bir karaciğer

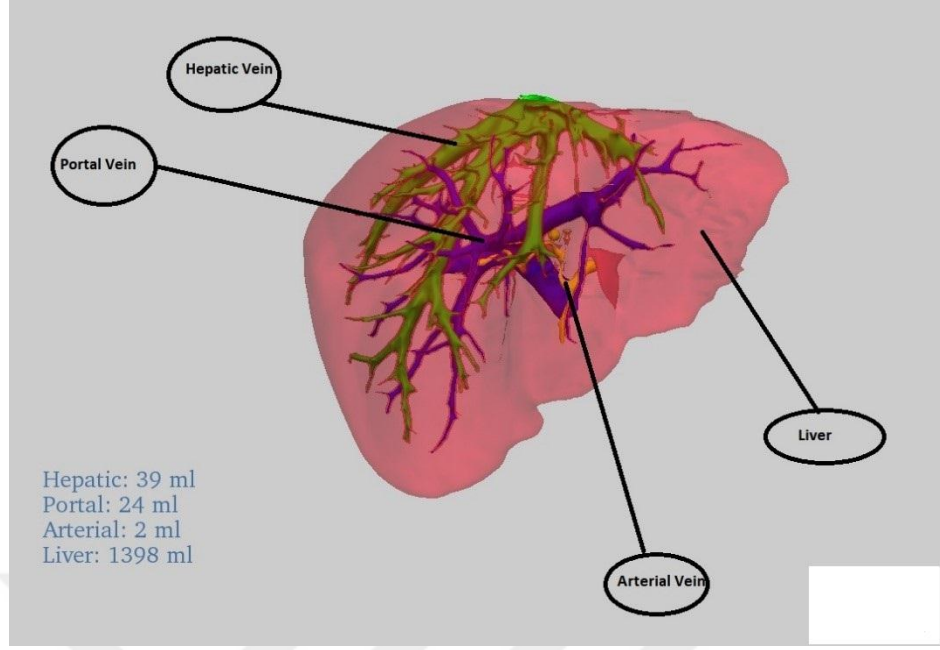
1.4 Kg olup, rengi koyu kahverengidir. Karaciğer temel olarak 3 ana damar yapısı ve karaciğer dokusundan oluşmaktadır.

Bu ana damar yapıları sırasıyla Hepatic Vein, Portal Vein ve Artery Vein olarak adlandırılır. Bu damar yapılarının fonksiyonları genel olarak hepatic vein, vücuttan karaciğer dokularına gelen kirli kanı taşır, portal vein karaciğer tarafından, vücuda besin ve mineral açısından zengin kanı taşır. Artery vein ise karaciğeri besleyen damarlar bütünüdür (Şekil 2.4).

Karaciğer dokusu ise kendi içinde 8 ana bölümden oluşan ve kendini yenileyebilen bir doku çeşididir. Karaciğer vücut toplam kanının yaklaşık %13'ünü tutar ve bu oran 1 lt kana karşılık gelmektedir.



Şekil 2.3 Kesit Karaciğer görüntüsü (Karaciğer Kırmızı Renkte)



Şekil 2.4 Genel Karaciğer Anatomisi (<http://www.livervision.org/2018>)

Karaciğer vücutta önemli fonksiyonları yerine getirmektedir. Bunlar:

- Karaciğer safra üretiminden sorumludur, safra yağların emilimi ve atıkların taşınmasını sağlar.
- Kan plazması için belirli proteinlerin üretiminden sorumludur.
- Yağların taşınmasına yardımcı olan kolesterol ve özel proteinlerin üretiminden sorumludur.
- Karaciğer fazla glikozun glikojene dönüşümünden sorumludur, bu besin daha sonra kullanılmak üzere depolanır.
- Hemoglobinin işlenmesi ve kullanılmasından sorumludur.
- Zehirli amonyakın üreye dönüşümünden sorumludur.
- İlaçlardan ve zehirli maddelerden kaynaklı bileşenlerin temizlenmesinden sorumludur.
- Kan pıhtılaşmasını düzenler.
- Bağışıklık sistemini düzenleyici bileşenler

3. BÖLÜTLEME YÖNTEMLERİ

Bu bölümde literatürde bulunan bölütleme yöntemleri detaylı bir şekilde incelenecektir. Bölütleme yöntemleri matematiksel modeller ve algoritma yaklaşımları ile, Eşikleme Tabanlı Bölütleme Yöntemi, Bölgesel Tabanlı Bölütleme Yöntemi, Sınıflandırma Tabanlı Bölütleme Yöntemi, Watershed Bölütleme Algoritması, Maksimum Olasılık ve Gaussian Yoğunluk Tahmini Bayesian Sınıflandırma, Snake (Aktif Kontur) Yöntemi ve Level Set ve Curve Evolution algoritması başlıklarında detaylı olarak incelenecektir.

3.1 Eşikleme Tabanlı Bölütleme Yöntemi

Tıbbi görüntü bölütlemesinde kullanılan en yaygın yöntemlerden biri Eşikleme yöntemidir [4]. Gri renk tonlarına [0-255] renk piksel değerlerine sahip resim, seçilecek bir eşik değere göre arka plan ve ön plan olmak üzere iki bölgeye ayrılır. Bu bölgeler binary resim olarak ifade edilir. Bu bilgiler nesnelerin konumu ve şekli hakkında önemli bilgiler içerir. Gri-skala resimleri binary resimlere çevirmenin avantajı sınıflandırma için kolaylık sağlamaktır. Resimlere uygulanan eşikleme yöntemi ile elde edilen binary resimlerden ön plan piksel kodu 1 olarak ifade edilirken, arka plan 0 piksel kodu ile ifade edilir.

Eşikleme değeri seçiminde iki tür yaklaşım bulunmaktadır, bunlar Global Eşikleme ve Yerel Eşiklemedir. Global Eşikleme yöntemi resim üzerinde seçilecek eşik değer başlangıçta belirlenir ve tüm piksel taramaları bu eşik değere göre sınıflandırılır, resim üzerinde farklı bölgelerde ortaya çıkan aydınlanma veya bozulmalardan kaynaklı piksel değişimlerinde bu yöntem başarılı sonuç üretmeyecektir. Yerel Eşikleme yöntemi, resim üzerinde farklı bölgelerde farklı durumlara göre kendini optimize ederek ve farklı eşik değerleri kullanarak bozulmalara karşı daha kararlı bir sınıflandırma yapabilir.

Otomatik eşik değeri farklı yöntemler kullanılarak bulur, Ortalama Piksel Değeri, Histogram Tekniği ve Kenar Maksimizasyon (Thakur ve Madaan 2014) tekniği yöntemleri ile otomatik eşik değeri tespit edilebilir. Ortalama piksel değeri, resimdeki piksellerin ortalamasını eşik değeri olarak kabul edip sınıflandırma bu değere göre

yapılır, resimdeki nesnelerin heterojen olarak dağılması durumunda iyi sonuç üretir. Histogram tekniğinde eşik değer belirleme işlemi, tespit edilecek nesnenin ön planın arka planından maksimum derecede heterojen olduğu bölge standart sapma (Denklem 3.1) ile tespit edilerek eşik değer belirlenir. Kenar Maksimizasyonu yönteminde eşik değer belirleme işlemi, resmin köşe noktaları belirlenerek bir ön plan-arka plan ayırım haritası Laplacian fonksiyonu kullanılarak çıkartılır.

3.2 Bölgesel Tabanlı Bölütleme Yöntemi

Bölgesel tabanlı sınıflandırma tekniği, piksel değerlerinin benzerliği ve konumları kullanılarak ortak bir sınıflandırma kümeleri oluşturulur (Elayaraja ve Suganthi 2014). Bölgesel tabanlı sınıflandırma tekniğine dayanan iki farklı yaklaşım bulunmaktadır. Bunlar Bölge Genişletme (Region Growing) ve Bölge Ayırıştırma ve Birleştirme (Region Splitting and Merging) teknikleridir.


3.2.1 Bölge Genişletme

Bölge Genişletme bölütleme tekniği, benzer piksel yoğunluklarının sınıflandırılması tekniğini kullanmaktadır. Bu yöntem resim üzerinde kullanıcının belirleyeceği bir piksel koordinat noktası değerinin, komşu piksel değerlerinin yoğunluğu ya da renk değerine göre belirli bir eşik değerinin altında olması durumunda aynı kümeye eklenmesidir. Her yeni bulunan çevre piksellere aynı çevre piksel taraması uygulanıp sınıflandırma kümeleri elde edilir (Şekil 3.1).

```
Define : list-class
Procedure: list-class.empty
  list-class.push(seed)
  While(list-class-> has-neighbors) do
    x=list-class->pop-neighbor
    f(x)>threshold then
      list-class.push(x)
```

Şekil 3.1 Bölge Genişletme Formülü


Şekil 3.2’de özetlenen örnek bir bölgesel genişletme adımı ifade edilmiştir. Genişletme çerçevesi olarak 3x3 boyutunda bir matris seçilmiştir.



Şekil 3.2 Bölge Genişletme Adımı

3.2.2 Bölge Ayrıştırma ve Birleştirme

Bölge Ayrıştırma ve Birleştirme bölütleme tekniği, resim piksellerini maksimum derecede homojen en küçük birime parçalanması ve bu parçalı bölgelerin daha sonra birleştirilmesi ilkesine dayanmaktadır.



Şekil 3.3 Bölge Ayrıştırma ve Birleştirme (<http://homepages.inf.ed.ac.uk/2018>)

Bölütleme yönteminde homojenlik eşik değeri belirleme işlemi standart sapma ile belirlenir (Eşitlik 3.1).

$$\sigma = \left[\frac{1}{N-1} \sum_{j=1}^N (x_j - \bar{x})^2 \right] \quad (3.1)$$

3.3 Sınıflandırma Tabanlı Bölütleme Yöntemi

Sınıflandırma tekniği, resim üzerinde piksel değerlerini baz alan böl ve sınıflandır tekniğini kullanır. Resimdeki piksel noktaları ya da bölünmüş homojen piksel kümeleri kullanılarak, benzer özellikte olan noktalar birleştirilerek sınıflandırılmış benzer özellikleri barındıran kümeler oluşturulur. Kısmi olarak **Bölge Ayırıştırma ve Birleştirme bölütleme** yöntemine benzemektedir.

Sınıflandırma işleminde farklı yaklaşımlar bulunmaktadır; denetimli sınıflandırma (supervised clustering) ve denetimsiz sınıflandırma (unsupervised clustering) olmak üzere iki farklı sınıflandırma tekniği kullanılır. Denetimli sınıflandırma yönteminde, kullanıcı sınıflandırma kümelerini belirleme işleminde, doğrudan etkin rol oynar, denetimsiz sınıflandırma tekniğinde ise sınıflandırma otomatik gerçekleşir.

Literatürde farklı nesne sınıflandırma teknikleri bulunmaktadır. Bunlar K-Means, Fuzzy C-Means yöntemleridir.

3.3.1 K-Means yöntemi

K-means algoritması, resimdeki pikselleri, belirli k adet kümeye ayıran denetimsiz bir sınıflandırma işlemidir. K-means algoritması piksel değerleri yakın olan noktaları adım adım aynı kümeye doğru yaklaştırarak sınıflandırma yapar (Funmilola vd. 2012).


$$J = \sum_{i=1}^k \sum_{j=1}^s \|v_j^{(i)} - c_i\|^2 \quad (3.2)$$

$\|v_j^{(i)} - c_i\|^2$ denklemi, $v_j^{(i)}$ piksel değerinin, c_i 'nin kümesinin merkezine olan uzaklığını vermektedir. Euclidean uzaklığı ile belirlenen ölçüm, bir pikselin belirli kümeler ile olan yakınlık ilişkisini vermektedir.

K-Means Algoritmasının işlem adımları şu şekildedir;

- Adım-1: Küme sayısını belirle (Kullanıcı tabanlı k adet küme belirle).
- Adım-2: Random piksel değerlerine göre her bir kümenin merkezini belirle.
- Adım-3: Her bir piksele en yakın kümeye eleman olarak seç.
- Adım-4: Her bir kümenin merkezini tekrar hesapla

Adım-2'den Adım-4'e kadar olan işlemleri herhangi bir pikselin kümesinde değişiklik gerçekleşmeyinceye kadar tekrar et.



Şekil 3.4 K-means algoritma akış şeması

3.3.2 Fuzzy C-Means yöntemi

Fuzzy C-means algoritması, resimdeki her bir pikseli belirli fuzzy aralıklarında belirlenmiş kümelere dahil etme yöntemidir. K-means algoritmasının aksine Fuzzy C-Means algoritması bir pikseli mutlak bir kümeye dahil etmez, her pikselin belirli ağırlıklarda kümelere etkisi bulunmaktadır (Ravindraiah ve Tejaswini 2013), (https://home.deib.polimi.it/matteucc/Clustering/tutorial_html/cmeans.html 02.08.2018).

$$J_m = \sum_{i=1}^K \sum_{j=1}^C \mu_{ij}^m \|v_i - c_j\|^2 \quad (3.3)$$

Fuzzy C-Means algoritmasının denklemi (3.3)'de formüle edilmiştir. m coefficient değeri $1 < m < \infty$ olacak şekilde tanımlanır. μ_{ij}^m değeri v_i piksel değerinin j sınıfındaki fuzzy değeridir. v_i resmin i . indeksindeki piksel değeridir. c_j ise j kümesinin merkezi-centroid değeridir. Bir pikselin belirli bir kümeye ait fuzzy derecesi

$$\mu_{ij} = \frac{1}{\sum_{n=1}^S \left(\frac{\|v_i - c_j\|}{\|v_i - c_n\|} \right)^{\frac{2}{m-1}}} \quad \text{denklemleri ile hesaplanır. Bir kümenin merkezi değeri ise}$$

$$c_j = \frac{\sum_{i=1}^N \mu_{ij}^m v_i}{\sum_{i=1}^N \mu_{ij}^m} \quad \text{denklemleri ile hesaplanır.}$$

Fuzzy C-means algoritması $\max_{ij} \{ |u_{ij}^{t+1} - u_{ij}^t| \} < \rho$ kriterini sağlaması durumunda sonuçlanacaktır. Buradaki ρ değeri 0 ile 1 arasında bir değerdir. Denklemdaki t değeri iterasyon derecesini vermektedir. Buradaki amaç piksellerin optimum derecede dağılımının garanti edilmesidir. ρ değeri ne kadar küçük seçilirse dağılım en iyiye doğru yaklaşır ve tekrar sayısı buna bağlı olarak artar.

Fuzzy C-means algoritması işlem adımları;

Adım 1: Piksellerin her kümeye ait fuzzy değerlerini belirten bir matris'in oluşturulması

$$M = [u_{ij}] \quad (3.4)$$

Adım 2: Kümelerin merkezlerinin belirlenmesi

$$C^{(t)} = [c_j] \text{ ile } U^{(t)} \quad (3.5)$$

$$c_j = \frac{\sum_{i=1}^N u_{ij}^m \cdot v_i}{\sum_{i=1}^N u_{ij}^m} \quad (3.6)$$

Adım 3: Her bir aitlik fuzzy değerlerinin güncellenmesi

$$\mu_{ij} = \frac{1}{\sum_{n=1}^S \left(\frac{\|v_i - c_j\|}{\|v_i - c_n\|} \right)^{\frac{2}{m-1}}} \quad (3.7)$$

Adım 4: Fuzzy değerleri $\max_{ij} \{|u_{ij}^{t+1} - u_{ij}^t|\} < \rho$, denklemini sağlıyor ise işlemin tamamlanması, Aksi durumda Adım-2 ye dönülmesi.

3.4 Watershed Bölütleme Algoritması


Watershed bölütleme algoritması, resim üzerinde topolojik ayırım haritasına göre bölütleme gerçekleştiren bir yöntemdir. Bölütleme temel olarak resim üzerinde eğim haritası çıkarma ve bu eğim haritasına göre topoloji oluşturma ilkesine dayanmaktadır. Gri ([0-255]) aralığına sahip bir resim üzerinde Laplacian filtresi (Denklem 6.2) ile eğim haritası çıkartılır (Şekil 3.5) ve binary bir görüntü elde edilir. Bu binary görüntü, resim üzerindeki köşe noktalarını ifade etmektedir. Bu görüntü üzerinden her bir piksel koordinatının en yakın köşe (eğim piksel koordinatı) noktasına olan euclidean uzaklık değeri ile Watershed eğim resmi çıkartılır (Şekil 3.6). Elde edilen Watershed eğim resmi üzerinden konturlar tespit edilerek (6.3 Kontur Tespiti) istenilen bölgelerin bölütlenmesi sağlanmış olur. Şekil 3.7 Gri resim üzerine Watershed bölütleme algoritması uygulandığında, şekil 3.8 her bir bölüt bölgesi ayrı olarak ifade edilmiş bir bölütlenmiş görüntü elde edilir. Watershed bölütleme algoritması her ne kadar resim bölütleme işleminde başarılı bir yöntem olsa da, karaciğer gibi içeriğinde birçok topolojik değişimi barındıran resimlerde istenilen başarı oranını gösterememektedir.

1	1	0	0	0
1	1	0	0	0
0	0	0	0	0
0	0	0	0	0
0	1	1	1	0


Şekil 3.5 Binary Resim (<https://www.mathworks.com/2018>)

0.00	0.00	1.00	2.00	3.00
0.00	0.00	1.00	2.00	3.00
1.00	1.00	1.41	2.00	2.24
1.41	1.00	1.00	1.00	1.41
1.00	0.00	0.00	0.00	1.00

Şekil 3.6 Watershed Eğim Resmi (<https://www.mathworks.com/2018>)



Şekil 3.7 Gri Resim (<https://www.mathworks.com/2018>)



Şekil 3.8 Bölütlenmiş Resim (<https://www.mathworks.com/2018>)

3.5 Maksimum Olasılık ve Gaussian Yoğunluk Tahmini

Maksimum olasılık tahmin tabanlı sınıflandırma (Maximum Likelihood and Gaussian Density Estimation) yöntemi rasgele seçilen v_1, v_2, \dots, v_n değerlerinden oluşan veri setini olasılıksal olarak, benzerlik değerlerini maksimum derecede tahmin edip sınıflandırmaktadır. Buradaki amaç benzerlik değerini maksimum derecede tahmin etmektir (Shashua 2008). $P(v|\theta)$ olasılıksal dağılımında veri seti v_1, v_2, \dots, v_n ise $P(v_i|\theta)$, v_i değeri θ dağılımına sahip bir fonksiyondaki bulunma olasılığını ifade etmektedir. $\theta^m = \arg \max_{\theta} (P(v|\theta))$ fonksiyonu ile θ^m maksimum derecede tahmin edilir.

$$\theta^m = \arg \max_{\theta} (L(\theta)) = \arg \max_{\theta} \prod_{j=1}^V P(v_j|\theta) \quad (3.8)$$

Denklem (3.8)'deki formül kullanılarak bir veri setinin bir kümedeki bulunma olasılığı tespit edilir. Denklemde her bir değişkeninin olasılık değerleri çarpılarak maksimum benzerlik değeri elde edilir. Denklemde daha kolay çözülmesi ve tahminin daha iyi yapılabilmesi amacı ile, denkleme monoton bir fonksiyon olan logaritmik bir fonksiyon eklenir (Denklem 3.9).

$$\arg \max_{\theta} \prod_{j=1}^V P(v_j|\theta) = \arg \max_{\theta} \ln\left(\prod_{j=1}^V P(v_j|\theta)\right) = \arg \max_{\theta} \sum_{j=1}^V \ln(P(v_j|\theta)) \quad (3.9)$$

Maksimum tahmin yönteminde, tahmin fonksiyonunu Gaussian dağılımı olarak ifade edilebilir. $P(v|\mu) \sim N(\mu, \sigma^2)$ denkleminde σ^2 bilinen bir değer olan standart sapmayı ifade ederken, μ ise bilinmeyen bir değer olup maksimum tahmin fonksiyonuna θ ya eşittir ve ortalama değeri vermektedir.

$$\begin{aligned} \arg \max_{\mu} L(\mu) &= \arg \max_{\mu} \left(\sum_{j=1}^V \ln \left(\frac{1}{\sqrt{2\pi\sigma}} \exp \left(-\frac{(v_j - \mu)^2}{2\sigma^2} \right) \right) \right) = \\ \arg \max_{\mu} &\left(\sum_{j=1}^V -\ln \sqrt{2\pi\sigma} - \frac{(v_j - \mu)^2}{2\sigma^2} \right) \end{aligned} \quad (3.10)$$

Maksimum olasılık tahmin fonksiyonu Gaussian fonksiyonu ile ifade edilir ise (3.10)'daki denklem ortaya çıkmaktadır. Burada ortalama değer μ bulabilmek için denklemin kısmi türevi alınır, logaritma fonksiyonunda $\theta = \mu$ eşitliğine göre alınacak kısmi türevde, fonksiyon denklemini sıfıra eşit olur ve maksimum tahmin değerinin sonucu bulunur.

$$\frac{d}{d\mu} (L(\mu)) = \sum_{j=1}^V \frac{1}{\sigma^2} (v_j - \mu) = 0 \quad \sum_{j=1}^V v_j - V * \mu = 0 \quad (3.11)$$

$$\theta = \mu = \frac{1}{V} \sum_{j=1}^V v_j \quad \sigma^2 = \frac{1}{V} \sum_{j=1}^V (v_j - \mu)^2 \quad (3.12)$$

Denklem (3.11)'de $L(\mu)$ fonksiyonu üzerine kısmi türev uygulanarak ortalama değer bulunur. Elde edilen ortalama değer denklem (3.12)'de görüldüğü üzere verilerin ortalamasını alan bir denklem elde edilerek ispatlanmıştır.

3.6 Bayesian Sınıflandırma

Bayesian Sınıflandırma Yöntemi, Bayesian teoremine dayanan bir sınıflandırma yöntemidir. Bu sınıflandırma Maksimum Olasılık Sınıflandırma Yönteminde olduğu gibi, optimum derecede veri setlerinin sınıflandırılmasını sağlar. Bayesian sınıflandırma yöntemi genelde birçok çeşitte veri ve birçok ilişkili ağı olan karmaşık durumların sınıflandırılmasında kullanılır (Shashua 2008).

$v_1, v_2 \dots \dots v_n$ veri setine ait $s_1, s_2 \dots \dots s_k$ sınıfları olsun, $P(s_i, v_j)$ olasılık değeri, v_j değerinin s_i sınıfında bulunma olasılığını vermektedir.

Bayesian Teoremi (3.13)'deki denklem ile formüle edilir.

$$P(s_i|v_j) = \frac{P(v_j|s_i).P(s_i)}{P(v_j)} \quad (3.13)$$


Formül (3.13)'deki denklemde $P(v_j, s_i)$ “likelihood” benzerlik olarak, $P(s_i)$ sınıfın olasılık değeri “prior” olarak, $P(v_j)$ “evidence” verinin olasılık değeri olarak ve $P(s_i, v_j)$ ise “posterior” olarak tanımlanır.

$$S_{Result} = arg \max_{s_j} \frac{P(v_j|s_i).P(s_i)}{P(v_j)} \quad (3.14)$$

Bayesian sınıflandırmada temel amaç denklem (3.14)'de görüldüğü üzere benzerlik oranını maksimum düzeye çıkarmaktır. $P(v_j, s_i)$ “likelihood” benzerlik değeri ve $P(s_i)$ sınıfın olasılık değerini ifade etmektedir.

3.7 Snake (Aktif Kontur) Yöntemi

Snake (Aktif Kontur) yöntemi resimdeki nesnelerin bölütlenmesinde kullanılan enerji tabanlı bir bölütleme yaklaşımıdır. Snake yöntemi kullanıcı tarafından belirlenen bir kontur'un hedeflenen nesneyi içine alacak şekilde gelişim gösterip, bölütleme işlemidir. (Bresson vd. 2005). Bu yöntemdeki amaç hedeflenen nesneye maksimum derecede benzerlik gösteren kapsayıcı bir kontur'u elde etmektir (Şekil 3.9).



Şekil 3.9 Kontur Gelişim Eğrisi

Snake yönteminde kontur gelişim denklemi (3.15)'de ifade edilmiştir. Denklemde $E(c)$ kontur'un enerji değerini ifade etmektedir. $E_{Internal}(c)$ değeri kontur'un şeklinden dolayı kazandığı enerjiyi ifade ederken, $E_{external}(c)$ değeri resimdeki gradient magnitude (eğim büyüklük) (denklem 5.5) değerine göre kontur'un kazandığı enerjiyi ifade etmektedir. Snake yöntemindeki temel amaç kontur'un kazandığı enerji değeri $E(c)$ 'nin azaltılmasıdır.

$$E(c) = E_{Internal}(c) + E_{external}(c) \quad (3.15)$$


$E_{Internal}(c)$ değeri kontur'un kendi şeklinden dolayı kazandığı enerjiyi ifade etmektedir. Denklem (3.16)'da kontur'un içsel enerji denklemi ifade edilmiştir. Denklem incelendiğinde, $\alpha \|c^I(s)\|^2$ fonksiyonu, kontur fonksiyonunun birinci derece türevi alınarak elde edilir. Bu fonksiyon kontur'u oluşturan noktalar kümesinin gelişimi sırasında, bu noktaların kontur'un üzerinde kalmasını sağlar. $\beta \|c^{II}(s)\|^2$ fonksiyonu ise, kontur fonksiyonunun ikinci derece türevi alınarak elde edilir. Bu fonksiyon kontur'u oluşturan noktalar kümesinin gelişimi sırasında, bu noktaların kontur üzerinde yumuşak bir eğri oluşturacak bir biçimde dağılımını sağlamaktadır. Fonksiyonlardaki a ve β parametre değerleri, sabit birer değişkendir ve kontur'un gelişim sürecinde doğrudan etkisi bulunmaktadır. Bu değerler bölütlenmesi istenen nesne ve resim yapısına göre kullanıcı tarafından deneysel olarak test edilip verilmektedir.

$$E_{Internal}(c) = \int_0^1 \alpha \|c^I(s)\|^2 + \beta \|c^{II}(s)\|^2 ds \quad (3.16)$$


$E_{external}(c)$ değeri kontur'un gelişim gösterdiği resmin eğim büyüklük değerinden dolayı kazandığı enerjiyi ifade etmektedir. Denklem (3.17)'de kontur'un dışsal enerji denklemini ifade edilmiştir. Kontur resimdeki eğim büyüklük değeri ∇I değerini azaltacak bir şekilde gelişim göstermektedir. ∇I değeri resmin köşe olmayan noktalarında $\nabla I=0$ eşitliğini sağlarken, resmin köşe noktalarında $\nabla I >0$ eşitsizliğini sağlamaktadır. Buradaki amaç ∇I değerini maksimize edip kontur'un resim üzerindeki köşe noktalarına doğru gelişimini sağlamaktır. Bu sayede $E_{external}(c)$ 'nin enerjisi azaltılarak toplam enerji azaltılmış olur.

$$E_{external}(c) = \int_0^1 -\|\nabla I(c(s))\|^2 ds \quad (3.17)$$

Snake yönteminin bazı dezavantajları bulunmaktadır bunlardan biri, kontur'un yerel minimum bölgelerine takılma olasılığının bulunmasıdır. Kontur'un gelişimi sırasında bölütlenmesi istenen nesnenin çevresinde $E(c)$ 'nin minimum olduğu bölgeler bulunabilmektedir, bu durumda kontur bu değerleri barındıran bölgelere doğru eğilim gösterip gerçek nesnenin kontur'una ulaşamayabilir (Şekil 3.10). Snake yönteminin bir diğer dezavantajı resim üzerindeki gürültülerden kaynaklı $E(c)$ 'nin minimum olduğu hatalı eğim büyüklük değerlerinin oluşmasıdır. Bu durumda kontur yanlış bölgelere doğru gelişim gösterebilir. Snake yönteminin bir diğer dezavantajı bazı konkav şekilli nesnelere doğru bir bölütleme yaklaşımı gösterememesidir. Bunun yanında birden fazla ayrık nesnenin bölütlenmesi durumunda kontur'un gelişim sırasında bütünlüğü değişip her bir nesnenin şekline göre gelişim gösteremediğinden dolayı başarılı bir bölütleme yaklaşımı gösterememektedir (Şekil 3.11).



Şekil 3.10 Kontur Gelişim Eğrisi Yerel Minimum Hatası




Şekil 3.11 Kontur Gelişim Eğrisi Çoklu Nesne Durumu

Snake algoritmasındaki yapıya benzer bir başka bölütleme yaklaşımı Başlık 3.8 Level Set and Curve Evolution yönteminde bahsedilecektir. Level Set and Curve Evolution yaklaşımı Snake algoritmasındaki bazı dezavantajları giderebilecek bir yöntem olup Snake algoritmasına göre daha gelişmiş bir bölütleme yaklaşımı sunmaktadır.

3.8 Level Set and Curve Evolution


Level Set and Curve Evolution yöntemi, bir surface ya da konturun bir resim üzerinde hedef alınan nesnenin sınırlarını belirleyecek şekilde kademeli olarak değişim gösterip, nesnenin optimum sınırlarını belirleme işlemidir. Elde edilen sınırlar nesnenin bölütleme çerçevesini oluşturur (Gamarendi vd. 2007).



Şekil 3.12 Kontur

Şekil 3.12’de örnek bir kontur gösterilmiştir. ϕ curve (eğri fonksiyonu) olarak tanımlanır. $\phi(x, y) = 0$ olması durumunda (x, y) eğri üzerinde, $\phi(x, y) > 0$ olması eğrinin içinde, $\phi(x, y) < 0$ olması ise noktanın eğrinin dışında bir bölgede olduğu kabul edilir.

\vec{N} normal vektör, $\frac{\nabla\phi}{|\nabla\phi|}$ denklemi ile ifade edilir. $\nabla\phi$ eğrinin gradient (eğim) değeridir. $|\nabla\phi|$ ise gradient magnitute (eğim büyüklüğü) olarak tanımlanır. \vec{T} ise eğrinin hız vektörü (velocity vector) ya da güç vektörü (force vector) olarak ifade edilir. Düzgün yayımlı eğrilerde bu değer $\vec{T} = 1$ iken (Şekil 3.13). Doğrusal olmayan yayımlılarda ise güç vektörü $\frac{\nabla\phi}{|\nabla\phi|}$ olarak alınır.



Şekil 3.13 Düzgün Yayımlı Eğri

Bir eğrinin başlangıç yayılım fonksiyonu ϕ olarak ifade edilir. Bu eğrinin herhangi bir t anında hareketi, eğrinin t ye göre türevi alınarak bulunabilir ($\frac{\partial \phi}{\partial t}$). Bir eğrinin herhangi bir t anında x noktasındaki değeri 0'a eşit oluyor ise ($\phi(x(t), t) = 0$) bu nokta eğri üzerindedir. ϕ eğrisinin t anında hareketini bulmak için başlangıç formülüne ($\phi(x(t), t)$) zincir kuralı uygulanarak türevi alınır (Denklem-(3.18),(3.19),(3.20)).

$$\frac{\partial \phi(x(t), t)}{\partial t} = 0 \quad (3.18)$$

$$\frac{\partial \phi}{\partial x(t)} \frac{\partial x(t)}{\partial t} + \frac{\partial \phi}{\partial t} = 0 \quad (3.19)$$

$$\frac{\partial \phi}{\partial x(t)} x_t + \phi_t = 0 \quad (3.20)$$

ϕ eğrisinin x noktasına göre türevi o noktaya göre eğimini vermektedir ($\frac{\partial \phi}{\partial x} = \nabla \phi$), $x(t)$ fonksiyonun t anındaki türevi ise gücü vermektedir ($\frac{\partial x(t)}{\partial t}$) ve x_t olarak ifade edilir. $x_t = F(x(t))\vec{N}$ olarak ifade edilebilir.

$$\phi_t + \nabla \phi x_t = 0 \quad (3.21)$$

$$\phi_t + \nabla \phi \vec{F} \vec{N} = 0 \quad (3.22)$$

$$\phi_t + \vec{F} \nabla \phi \frac{\nabla \phi}{|\nabla \phi|} = 0 \quad (3.23)$$

$$\phi_t + \vec{F} |\nabla \phi| = 0 \quad (3.24)$$

ϕ eğrisinin t anında nasıl dağıldığını formüle eden denklemler (Denklem (3.21), (3.22), (3.23), (3.24))'de gösterilmiştir. Denklem 3.24 ϕ eğrisinin dağılım özetidir. $\phi_t + \vec{F} |\nabla \phi|$ denkleminde ϕ eğrisinin bir sonraki eğri denkleminde \vec{F} Güç Vektörü ve $|\nabla \phi|$ eğim gücünün doğrudan etkisi bulunmaktadır.

ϕ eğrisinin bir sonraki adımda nasıl yayılacağına ilişkin kural $curvature = div(\frac{\nabla\phi}{|\nabla\phi|})$ dir. $\frac{\nabla\phi}{|\nabla\phi|}$, fonksiyonunun kısmi türevi alınırsa denklem (3.25) elde edilir.

$$curvature = \frac{\phi_y^2\phi_{xx} - 2\phi_{xy}\phi_x\phi_{yy} + \phi_x^2\phi_{yy}}{(\phi_y^2 + \phi_x^2)^{3/2}} \quad (3.25)$$

ϕ eğrisinin, gerçek bir resimde nasıl yayıldığını görmek için, eğim fonksiyonu piksel bazında ayrıştırılması gerekmektedir. ϕ fonksiyonunun bir resimde, (x,y) noktasındaki yayılım değişimi, zamana bağlı olarak denklem (3.26)'da gösterilmiştir.


$$\Delta\phi = \frac{\phi(x,y,t+\Delta t) - \phi(x,y,t)}{\Delta t} \quad (3.26)$$

$\phi(n)$ eğrisi için yayılım fonksiyonu hesaplanırken, bir önceki $\phi(n-1)$ ve bir sonraki $\phi(n+1)$ eğrileri dikkate alınır. Denklem 3.27 ve 3.28'de $\phi(n)$ için Force durumuna göre pozitif ve negatif iki eğim farkı hesaplanır. Şekil 3.14'de bir eğrinin gelişim özeti gösterilmiştir, buna bağlı olarak da bir eğrinin bir sonraki hareket durum formülü 3.29 denkleminde ifade edilmiştir.


$$\nabla^{+t}(x,y) = \max[0, \Delta^{-t}\phi(x,y)]^2 + \min[0, \Delta^{+t}\phi(x,y)]^2, Force > 0 \quad (3.27)$$

$$\nabla^{-t}(x,y) = \max[0, \Delta^{+t}\phi(x,y)]^2 + \min[0, \Delta^{-t}\phi(x,y)]^2, Force < 0 \quad (3.28)$$


$$\frac{\phi(x,y,t+\Delta t) - \phi(x,y,t)}{\Delta t} + \max[0, F]\nabla^{+t}(x,y) + \min[0, F]\nabla^{-t}(x,y) = 0 \quad (3.29)$$




Şekil 3.14 Eğri Gelişimi




Şekil 3.15 Kontur Adım-18



Şekil 3.16 Kontur Adım-40



Şekil 3.17 Kontur Adım-51



Şekil 3.18 Kontur Adım-72

Şekil 3.15-3.18 arasında level set bölütleme tekniği kullanılarak konturın farklı adımlarda resim üzerindeki dağılım gelişimi gösterilmiştir.

4. GÖRÜNTÜ İYİLEŞTİRME YÖNTEMLERİ

Görüntü iyileştirme, özellikle medikal resimlerde önemli bir yer tutmaktadır. Resimler üzerindeki bozulmalar, parlamalar ve gürültülerin giderilip anlamlı bir veri haline getirilmesi resim üzerinde yapılacak bölütleme işlemlerinde başarı oranını arttıracak önemli faktörlerdendir. Medikal resimler (CT ya da benzeri resimlerde) de en büyük sorunlardan biri düşük çözünürlükte gelen resimlerdeki gürültüler ve detaylardaki eksikliklerdir. Bu sorunları gidermek için Gaussian tabanlı yumuşatma (Gaussian Based Smoothing) ve Anizotropik Difüzyon Filtresi (Anisotropic Diffusion Filter) yöntemleri önerilmektedir.

4.1 Gaussian Tabanlı Yumuşatma

Gaussian tabanlı yumuşatma işlemi resimdeki gürültülerin giderilmesinde başarılı sonuçlar üreten hızlı ve efektif isotropic (eşit dağılımlı) bir resim yumuşatma yöntemidir. Yöntem Gaussian dağılımını kullanmaktadır. Formül 4.1'de Gaussian dağılım denklemi görülmektedir. Bu dağılımın en büyük dezavantajı, dağılımın isotropic olmasıdır, bu durumda resim üzerindeki köşe (edge) özellik barındıran bölgelerde kayıpların oluşmasıdır.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\left(\frac{x^2+y^2}{2\sigma^2}\right)} \quad (4.1)$$

Resim üzerinde Gaussian dağılımı bir kernele indirgenerek, yani bir resim matris 'ine dönüştürülerek kullanılır. Farklı boyutlarda ve içeriklerde kernel elde etmek mümkündür. σ parametresine bağlı olarak kernelin içeriği değiştirilir. σ değeri arttıkça kernelin resim üzerindeki yumuşatma değeri artmaktadır. Kernelin boyutu ise problemin durumuna göre kullanıcı tarafından ya da otomatik olarak belirlenir (Şekil 4.1) (https://en.wikipedia.org/wiki/Gaussian_blur 02.08.2018).

$\frac{1}{273}$	1	4	7	4	1
	4	16	26	16	4
	7	26	41	26	7
	4	16	26	16	4
	1	4	7	4	1

Şekil 4.1 Gaussian Kernel

4.2 Anizotropik Difüzyon Filtresi

Anizotropik Difüzyon Filtresi, resimdeki gürültülerin giderilmesinde oldukça başarılı sonuçlar üreten anizotropik bir yumuşatma yöntemidir. Gaussian yumuşatma yönteminin aksine, anizotropik yumuşatma yöntemi işlem sırasında köşe noktalarını korumaktadır. Böylece resim üzerindeki gürültüler giderilip, resim yumuşatılırken, resimdeki keskin noktalar korunmaktadır (Perona 1990).

$$I_t = \text{div}(f(\|\nabla I\|)\nabla I) = f(\|\nabla I\|)\Delta I + \nabla_f \cdot \nabla I, \quad I(x, y, 0) = I_0(x, y) \quad (4.2)$$

Anizotropik Difüzyon Filtresi denklemi (4.2)'de ifade edildiği gibidir. ∇ resme uygulanacak eğim operatörüdür. $\|\nabla I\|$ resmin eğim büyüklük değerini vermektedir. Δ ise resme uygulanacak Laplacian operatörünü ifade etmektedir. Formüldeki f fonksiyonu diffusion fonksiyonu olarak ifade edilir ve resimdeki köşe noktalarını tespit etmek için kullanılır.

$$f(\|\nabla I\|) = \frac{1}{1 + (\frac{\|\nabla I\|}{s})^2} \quad (4.3)$$

Denklemin 4.3'de ifade edilen köşe durdurma fonksiyonu ile resim üzerindeki noktaların köşe olup olmadığına karar verilir. s değeri sabit bir değer olup, köşe hassasiyet değeri olarak alınmaktadır.

$$I^{t+1} = I^t + f(\|\nabla I\|)\nabla I \quad (4.4)$$

Denklem 4.4’de ifade edilen denklemde bir resim üzerine uygulanan Anizotropik Difüzyon Filtresi formüle edilmiştir.



Şekil 4.2 CT-Image



Şekil 4.3 CT Resim Gaussian Yumuşatma



Şekil 4.4 CT Resim Anizotropik Difüzyon

Anizotropik Difüzyon Filtresi ve Gaussian Yumuşatma Filtresinin şekil 4.2'deki resim üzerindeki etkileri şekil 4.3-4.3'de gösterilmiştir. Gaussian Filtresi tüm resim üzerinde bir yumuşatma işlemi gerçekleştirmiştir, Anizotropik Difüzyon Filtresi ise köşe noktalarını koruyan bir yaklaşımla yumuşatma işlemini gerçekleştirmiştir.



5. KARACİĞER BÖLÜTLEME YÖNTEMLERİ

Medikal CT görüntüler üzerinde dokuların bölütlenmesi ve anlamlı birer nesneye dönüştürülmesi medikal görüntü işleme alanında önemli bir yer tutmaktadır. CT görüntüler üzerinde hedef alınan dokuların yüksek hassasiyet ile tespiti ve sınırlarının tam olarak ayrıştırılması medikal görüntü bölütlemesi alanında önemli bir zorluk olarak görülmektedir. CT görüntülerdeki bozulmaların yanı sıra anatomik olarak dokuların yerleşmesindeki nedenlerden dolayı, yüksek hassasiyetli bölütleme yapmak çoğu zaman mümkün olmamaktadır. Karaciğerin CT görüntülerden bölütlenmesi işleminde de bu gibi zorluklar yaşanmaktadır.




Şekil 5.1 Sağlıklı Karaciğer dokusu

Medikal görüntüde her bir dokunun kendine has bir piksel yoğunluk değeri bulunmaktadır, buna Hounsfield değeri de denilmektedir. Bu piksel yoğunluğu normal bir medikal görüntüleme işleminden geçmiş ve herhangi bir bozulmaya uğramamış sağlıklı bir insanın CT görüntülerde, dokuların kendine has Hounsfield değeri doğru olarak elde edilir (Şekil 5.1). Buna rağmen kaliteli bir CT görüntüde, hastanın karaciğer yapısına bağlı olarak, karaciğer dokusunda bozulma siroz gibi durumlarda (Şekil 5.2), karaciğer dokusunun Hounsfield değeri tamamıyla değişip, karaciğer dokusunda bölgesel veya tamamıyla bozulmuş bir bölge elde edilir. Bu durum dokunun bölütlenmesini zorlaştırıcı bir etken olacaktır.



Şekil 5.2 Hastalıklı Karaciğer dokusu

Karaciğer bölütlenmesindeki bir diğer zorluk, karaciğer dokusunun farklı dokular ile olan piksel yoğunluk benzerliğidir. Karaciğer dokusu CT görüntüde, pankreas dokusu ve kalp dokusunun bir kısmı ile aynı Hounsfield değerine sahip olmaktadır. Bu durum sağlıklı bir insanın CT görüntüsünde de aynı şekilde görüntülenmektedir (Şekil 5.3).



Şekil 5.3 CT- Doku Çeşitleri


CT görüntülerdeki bu gibi zorlukların çözümünde farklı bölütleme yaklaşımları önerilmektedir. Birinci bölümde bahsedilen bölütleme teknikleri ile kısmen bu problemlerin üstesinden gelinebilmektedir.

Birinci bölümde bahsedilen Bölgesel Tabanlı Bölütleme (Region Based Segmentation), Sınıfsal Tabanlı Bölütleme (Clustering Based Segmentation) ve Level Set Bölütleme (Level Set Segmentation) tekniklerinin bu gibi problemler üzerindeki yaklaşımı ve çözümü karşılaştırmalı olarak ele alınacaktır.

5.1 Bölgesel Tabanlı Bölütleme

Bölgesel tabanlı bölütleme yöntemi en temel ve basit bölütleme yöntemlerinin başında gelmektedir. Bu teknik resim üzerindeki bir bölgeye kullanıcı tarafından bir başlangıç noktası (seed point) verilerek belirli eşik değerleri arasındaki ve başlangıç noktasına bağlı noktalar kümesini sonuç olarak üretmektedir. Bu noktalar kümesinden elde edilecek bölgelerde bölütlenmiş bölgeler olarak adlandırılır.


CT görüntüler üzerinde bölgesel tabanlı bölütleme yöntemi ile tespit edilen bölgeler çoğu zaman istenen doğruluk oranı ile bölütlenememektedir (Şekil 5.4).



Şekil 5.4 Bölgesel Büyüme Bölütleme Yöntemi

CT görüntü üzerine uygulanan Bölgesel Büyüme Bölütleme (Region Growing Segmentation) tekniği sonucunda elde edilen bölge şekil 5.4'te gösterilmiştir. Elde edilen bölge incelendiğinde karaciğer dokusunun yanında farklı bölgelerin pankreas,

dalak ve bir takım kemik dokularının da seçildiği görülmüştür. Normalde elde edilmek istenen bölütleme alanı şekil 5.5’de gösterilmiştir.



Şekil 5.5 Doğru Bölütlenmiş Alan

Bölgesel Büyüme Bölütleme işlemi şekil 5.4’te görüldüğü üzere karaciğerden farklı birçok dokuyu da bölütlemiştir. Bu nedenden dolayı istenilen başarı oranına ulaşamamıştır. Bu yöntemin başarısız olmasının en büyük nedeni, algoritmanın işlem sırasında seçme kriterlerinin sadece komşu piksellerin yoğunluk dereceleri olmasıdır. Buna rağmen bölütleme algoritmaları içinde en hızlı sonuç veren tekniktir (Çizelge 5.1).

Algoritmaların 512 X 512 X 500 CT görüntü üzerinde karşılaştırılması (Çizelge 5.1).


Çizelge 5.1 Algoritmaların Karşılaştırılması

Algoritma	Doğruluk Oranı	İşlem Zamanı	Yöntem	Performans
Region Growing	%40	~3 sn.	Kök Nokta (Seed Point)	CT görüntü boyutu kadar işlem yükü gerekmektedir (250 Mb)
Sınıfsal Tabanlı Bölütleme Yöntemi (M.O.G.Y.T);	%35	~4dk.	Belirli Sınıf Sayısına Göre Sınıflandırma	CT görüntü boyutu kadar işlem yükü gerekmektedir (250 Mb)
Level Set and Curve Evolution	%75	~30 sn.	Kök Nokta (Seed Point) (Parametre Ayarı Gerekmemektedir)	Ön işlem çıktı resimleri hafızada önemli ölçüde yer tutar ~1.5gb
Önerilen Yöntem	%95	3 sn.	Kök Nokta (Seed Point)	CT görüntü boyutu kadar işlem yükü gerekmektedir (250 Mb)

5.2 Sınıflandırma Tabanlı Bölütleme

Sınıflandırma Tabanlı Bölütleme yöntemi CT görüntüleri farklı piksel yoğunluklarına göre ve farklı sınıf sayılarına göre ayırma işlemidir. Bu teknikte otomatik ya da kullanıcının belirleyeceği sınıf sayılarına göre pikseller gruplanır. Elde edilen bu gruplardan piksel yoğunluk derecesi, karaciğer piksel yoğunluk derecesine en fazla benzeyen grup, bölütlenerek karaciğer dokusu olarak adlandırılır (Şekil 5.6). Sınıflandırma yöntemi resimdeki pikselleri kendi içinde sadece yoğunluk değerlerine göre sınıflandırmaktadır. Bu durum birçok dezavantajı da beraberinde getirmektedir. Karaciğere ait olmayan birçok piksel, karaciğer sınıfında yer alacaktır. Sınıflandırma yönteminin bir başka dezavantajı da işlem süresi ve maliyetidir. Her bir piksel üzerinde yapılan sınıf belirleme adımları işlem süresini inanılmaz derecede arttırmaktadır (Çizelge 5.1).

Sınıflandırma yönteminde piksel konumu ve eğim parametreleri kullanılarak elde edilecek sınıflandırma daha başarılı sonuçlar üretecektir.



Şekil 5.6 Sınıflandırma Tabanlı Bölütleme

5.3 Level Set Bölütleme

Level Set Bölütleme yöntemi, bölgesel büyüme (region growing) algoritmasının daha gelişmiş bir modeli olarak tanımlanabilir. Level Set bölütleme algoritması tıpkı bölgesel


büyüme algoritmasında olduğu gibi bir başlangıç noktası (seed point) kullanarak görüntü üzerinde yayılır ve bölütleme işlemi gerçekleştirir. Level Set Algoritmasında bölütleme kademeli olarak kontur tabanlı gerçekleşmektedir. Kontur tabanlı genişleme görüntü üzerinde eğim ve kontur yayılım fonksiyonu tarafından gerçekleştirilmektedir. Kontur yayılım denklemi (5.1)'de görülmektedir.

$$\phi_t + \vec{F}|\nabla\phi| = 0 \quad (5.1)$$


Level Set bölütleme algoritması bu bakımdan bölgesel büyüme algoritmasından daha başarılı sonuç üretmektedir. Level Set bölütleme algoritması, bölütleme için CT resim üzerinde bir takım ön işlemler yapmayı zorunlu kılmaktadır. Bu ön işlemlerde orijinal resim üzerinde eğim tabanlı bir harita oluşturulur. Ve kontur Dağılımı bu harita üzerinden gerçekleştirilir. Bu ön işlemler sırası ile Yumuşatma Filtresi (Smoothing Filter), Eğim Büyüklük Filtresi (Gradient Magnitude Filter) ve Sigmoid Filtresi (Sigmoid filter) olarak sıralanmaktadır.

5.3.1 Yumuşatma Filtresi

Orijinal CT resim üzerine (Şekil 5.7) ilk aşamada Anizotropik Difüzyon filtresi (Şekil 5.8) uygulanarak resim yumuşatılıp, köşe noktaları keskin hale getirilir ve görüntü pikselleri belirli bir eşik değere çekilir.



Şekil 5.7 Orijinal Resim



Şekil 5.8 Anizotropik Difüzyon Filtresi Çıktısı

5.3.2 Eğim Büyüklük Filtresi


Eğim Büyüklük Filtresi, yumuşatılmış resim üzerinde eğim fonksiyonu çıktısı olan kernel uygulanarak (Şekil 6.11) eğim vektör değerleri elde edilir (Denklem 5.2). Eğim vektör değerleri bir görüntüde pikselin komşu pikseller ile olan değişim değeri ile hesaplanır denklem (5.3), (5.4), (5.5). Elde edilen Eğim Büyüklük Görüntüsü şekil 5.9'da gösterilmiştir.

$$\nabla f = \left[\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y} \right] \quad (5.2)$$

$$\frac{\partial f}{\partial x} = f(x + 1, y) - f(x, y) \quad (5.3)$$

$$\frac{\partial f}{\partial y} = f(x, y + 1) - f(x, y) \quad (5.4)$$

$$\|\nabla f\| = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2} \quad (5.5)$$



Şekil 5.9 Eğim Büyüklük Filtresi Çıktısı


5.3.3 Sigmoid Filtresi

Sigmoid Filtresi, görüntüdeki piksel yoğunluk aralıklarını belirli bir değere yükseltmeyi sağlayan bir filtredir. Sigmoid Filtresi temelde sigmoid fonksiyonunu kullanmaktadır (Denklem 5.6).

$$f(x) = \frac{1}{1+e^{-g(x)}} \quad (5.6)$$

Sigmoid filtresi, denklem 5.7 ile ifade edilebilir. Denklemdeki, *Output*, *Input* değişkenleri sırası ile girdi ve çıktı resimleridir. $Max_{intensity}$ ve $Min_{intensity}$ değerleri çıktı resimdeki hedeflenen minimum ve maksimum piksel yoğunluk değerlerini ifade etmektedir. Deneysel gözlemlerde, başlangıçta belirlenen bu yoğunluk değerleri arasındaki fark, çıktı resimde, girdi resme göre iki kat olarak belirlenebilir. a değişkeni girdi resmin ortalama piksel değeri iken, β değişkeni girdi resmin minimum ve maksimum piksel değerleri arasındaki farkın yarısına eşittir. ($Max(Input) - Min(Input)/2$).

$$Output = (Max_{intensity} - Min_{intensity}) \frac{1}{1+e^{-\frac{Input-\beta}{a}}} + Min_{intensity} \quad (5.7)$$



Şekil 5.10 Sigmoid Filtresi Çıktı


Eğim Büyüklük görüntüsüne, Sigmoid Filtresi uygulandığında şekil 5.10'da gösterilen resim elde edilir. Sigmoid filtresi, Level Set Algoritması için girdir görüntüsü oluşturacaktır. Şekil 5.11'de sigmoid girdi görüntüsü kullanılarak karaciğer bölütleme işlemi yapılmıştır.

Level Set bölütleme algoritması oldukça başarılı sonuçlar üretmektedir. Şekil 5.11'de görüldüğü üzere karaciğer dokusunun çoğu doğru bölütlenmiştir.



Şekil 5.11 Level Set Bölütleme Algoritması

Level Set algoritması, bölgesel ve sınıfsal tabanlı diğer algoritmalarından çok daha gelişmiş bir algoritma olduğu görülse de karaciğer dokusu üzerinde tam bir bölütleme işlemi gösterememiştir (Şekil 5.12).



Şekil 5.12 Karaciğer Bölgesi


Level Set algoritmasındaki eksikliklerin başında parametre ayarı gelmektedir, ön işlemler bazı parametrelere bağlı olarak farklı resimlerde farklı optimum sonuçlar üretmektedir. Bu bakımdan kullanıcı bu parametre değerlerini iyi ayarlamak zorundadır. Diğer bir eksiklik ön işlemlerin maliyetidir (Çizelge 5.1).

5.4 Karaciğer Bölütleme Problemleri

Karaciğer bölütleme yöntemleri, genel olarak karaciğer bölütleme algoritmalarının doğruluk-hassasiyet (precision) oranları ve çalışma zamanı (execution time) bakımından yetersiz kaldığı, incelenen bölütleme algoritmalarında görülmüştür. Bu konuda önerilecek olan algoritma problemlerin çözümünde yenilikçi bir yaklaşım sunmaktadır. Geleneksel karaciğer bölütleme algoritmalarındaki temel sorunlar iki farklı başlıkta ele alınabilir.

5.4.1 Doğruluk sorunu

Geleneksel karaciğer bölütleme algoritmalarındaki doğruluk sorunu, bölgesel ve sınıfsal tabanlı bölütleme yöntemlerinde oldukça belirgin bir şekilde karşılaşılmaktadır. Genelde bu soruna neden olan faktör karaciğer dokusunun, pankreas, kaburga dokusunu saran bölge ve kalbin bir kısmını oluşturan dokuların bağlantı noktalarındaki piksel yoğunluk değerlerinin benzer olmasıdır. Bu bağlantı noktaları ayrıştırılabilirse, doğruluk oranı çok daha yüksek bir bölütleme algoritması elde edilebilir (Şekil 5.13).



Şekil 5.13 3B-Karaciğer Bölüt Yüzeyi

5.4.2 Çalışma zamanı sorunu


Sınıfsal tabanlı ve Level Set geleneksel bölütleme yöntemlerinde çalışma zamanı sorunu açık bir şekilde görülmektedir. Güncel son teknoloji medikal görüntü bölütleme uygulamaları incelendiğinde, geleneksel yöntemlerin çalışma zamanı güncel yaklaşımlara göre oldukça yüksek kalmaktadır. Level Set algoritmasında, ön işlem için gerekli çalışma zamanı ve sınıfsal tabanlı bölütleme yönteminde resim taraması için gerekli çalışma zamanının fazla olması bu sorunlara neden olmaktadır.

6. KARACIĞER BÖLÜTLEMEDE YENİ YAKLAŞIM

Önerilen algoritma temelde, geleneksel yöntemlerde ortaya çıkan sorunların giderilmesi ve optimize edilmesi konusunda bir yenilik sunmaktadır. Yüksek doğruluk oranı ve işlem zamanı bakımından tatmin edici bir bölütleme yaklaşımı sağlamaktadır. Önerilen yöntemin akış şeması şekil 6.1’de görülmektedir.

Önerilen algoritmanın çalışma adımları şu şekilde sıralanabilir;

1. 3B CT görüntü, 3B Bölge Genişletme (Region Growing) algoritması ile işlenerek binary 3B görüntü oluşturulur.
2. Elde edilen 3B binary görüntüler 2B kesit haline getirilir.
3. 2B binary kesitlere Gaussian Filtresi ve Dilation/Erosion morfolojik ön işlemler uygulanır.
4. Ön işleminden geçirilen 2B binary görüntüler üzerine kontur bulma işlemi gerçekleştirilir.
5. Her bir kesit için 2B binary görüntüden elde edilen konturlar içerisinde, daha önce tespit edilmiş konturlar karşılaştırılarak büyüklük ve merkezi yakınlık derecesine göre belirli kriterleri baz alarak, bir kontur seçilir ve çıktı olarak 3B binary görüntüye eklenir.
6. Elde edilen 3B binary görüntüler üzerine 3B Bölge Genişletme algoritması uygulanır. Bu sayede karaciğer dokusu ile bağlantılı farklı dokuların resimden silinmesi sağlanır.
7. En son elde edilen 3B binary görüntü üzerinde, çıkıntı veya hatalı bölütlenmiş bölgelerin giderilmesi amacı ile bir temizleme işlemi uygulanır.




Şekil 6.1 Algoritma Akış Şeması

6.1 3B Bölge Genişletme


3B Bölge Genişletme bölütleme yaklaşımı temel olarak bir RGB ya da grayscale görüntü pikseli üzerinde bir başlangıç noktası (seed point) belirlenerek, bu başlangıç noktasına bağlı belirli bir eşik değeri sağlayan ($T_{min} < P_i < T_{max}$) bölgeleri bulmayı amaçlamaktadır. Çıktı resim olarak 3B Binary (3B Matris) bir görüntü oluşmaktadır.

3B Bölge Genişletme bölütleme yaklaşımında girdi resim 3B bir CT görüntüdür. Klasik Bölge Genişletme yöntemi 2B resim üzerinde bir dağılım yaparken, bu yöntem 3B bir dağılım gerçekleştirmektedir. Şekil 5.2'de 512 X 512 X 500 (En, Boy, Derinlik)

boyutlarına sahip resim üzerinde uygulanan 3B Bölge Geniřletme algoritmasının ıktısı grlmektedir.



Őekil 6.2 3B Blge Geniřletme ıktısı



Őekil 6.3 3B Dođru Karaciđer Yzeyi

Őekil 6.2’de elde edilen grnt 3B binary bir yzey grntsdr. Bu grntnn ierisinde, karaciđerden farklı birok doku da bulunmaktadır. Őekil 6.2-6.3 karŐılaŐtırıldıđında karaciđer evresindeki dokular aıka grnmektedir.


Yntemin dođru alıŐması aısından iki farklı sorun ortaya ıkmaktadır. Bunlar: eŐik deđer belirleme ve baŐlangı noktası konumlandırma sorunlarıdır.

6.1.1 Eşik Değer belirleme işlemi

3B Bölge Genişletme bölütleme yöntemindeki en büyük sorunlardan birisi eşik değer belirleme sorunudur. T_{min}, T_{max} değerleri bölütleme için ana parametre değerlerini oluşturur. Bu değerlerin belirlenmesi konusunda iki farklı yaklaşım bulunmaktadır.

6.1.1.1 Tam otomatik eşik değer belirleme işlemi

Tam otomatik değer belirleme işleminde Level Set algoritması kullanılabilir. 3B-Gray Scale CT görüntünün belirlenen başlangıç noktası ve bu başlangıç noktasının koordinat düzleminde karşılık gelen 2B-Gray Scale CT kesitinin üzerinde Level Set algoritması çalıştırılır. Level Set algoritmasının çıktı görüntüsü üzerinden minimum ve maksimum T_{min}, T_{max} değerleri belirlenebilir. Level Set algoritmasının çıktı binary resminin bölütlü noktaları ile 3B Gray Scale CT görüntü örtüştürülür ve örtüşen noktalardaki değerlerin minimum ve maksimum parametre değerleri alınır. Bu parametreler 3B Bölge Genişletme için eşik değeri oluşturur. Şekil 6.4'te karaciğeri doğru ifade eden eşik değer aralıkları görülmektedir.



Şekil 6.4 Doğru Belirlenmiş Eşik Değer Aralıkları (İşaretli Mavi Renk)

Bir diğer tam otomatik eşik değer belirleme işlemi 3B Gray Scale CT görüntü için bir histogram haritası oluşturmaktır. Belirtilen başlangıç noktasının piksel değerini

kullanarak histogram haritasında belirli bir sapma aralığında belirtilen pikselin minimum ve maksimum deęer aralıkları bulunabilir.

6.1.1.2 Kullanıcı tabanlı eşik deęer belirleme işlemleri

Kullanıcı tabanlı eşik deęer belirleme işlemleri, kullanıcı tarafından resim üzerinde seçilecek farklı eşik parametre deęerlerine göre minimum ve maksimum deęer aralıkları belirleme işlemleridir.

6.1.2 Başlangıç noktası konumlandırma

Başlangıç noktası konumlandırma işlemleri 3B Bölge Genişletme için önemli bir aşamadır. Doğru belirlenmiş başlangıç pikselin konumu ve deęeri, karacięeri oluşturan piksellerin deęer aralıklarını içermek zorundadır. Bu sebeple hatalı başlangıç piksel belirleme durumunda çevre piksellerden yararlanılabilir. Belirlenen başlangıç noktası gerek resimdeki bozulmalardan gerekse karacięeri ifade etmeyen piksel aralıklarında olmasından kaynaklı sorunlar oluşabilmektedir. Bu hataları gidermek için, başlangıç noktasını ifade eden pikselin, çevre pikseller ile olan ilişkisini deęerlendirmek gerekir. Başlangıç piksel koordinat deęerinin belirli bir aralıkta, çevresinde bulunan piksellerin ortalama deęerinin alınması ile bu sorun giderilebilir.


6.2 Ön İşlemler

2B İkili (Binary) kesitler üzerinde farklı ön işleme teknikleri uygulanmaktadır. Bu yöntemler resim üzerinde yumuşatma ve resimdeki istenmeyen çıkıntuların giderilmesine yardımcı olmaktadır. Bu algoritmalar temel görüntü işleme yöntemleri olan Gaussian Yumuşatma ve Dilation/Erosion algoritmalarıdır. Bunlara morfolojik operasyonlarda denilmektedir. Ön işlemler binary görüntüler üzerine uygulanacaktır. Bu bakımdan normal gray-scale resimlerden farklı bir yöntem izlenmektedir.


6.2.1 Gaussian Yumuşatma

Gaussian Yumuşatma yöntemi ile binary resim üzerindeki keskin bölgelerin giderilmesi sağlanmaktadır. Gaussian dağılım formülü (Denklem 6.1)'de ifade edilmiştir. Binary resim üzerine uygulanacak (7 X 7) boyutundaki kernel ile yumuşatılmış bir görüntü elde edilir.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\left(\frac{x^2+y^2}{2\sigma^2}\right)} \quad (6.1)$$



Şekil 6.5 2B Binary Resim




Şekil 6.6 2B Yumuşatılmış Binary Resim

Şekil 6.5'de binary görüntü üzerine uygulanacak Gaussian Yumuşatma işleminin sonucunda, yumuşatılmış daha pürüzsüz binary bir görüntü elde edilir (Şekil 6.6).

6.2.2 Dilation/Erosion


Dilation ve Erosion, resim üzerinde inceltme ve kalınlaştırma yapan temel morfolojik operatörlerdendir. İki yöntemde de belirli boyutlarda kernel kullanılmaktadır. Dilation işleminde kernel belirli aralıklarda binary resim üzerinde taranır, binary resim üzerinde taranan kernel ile binary resmin herhangi bir pikseli eşleşmesi (1*1 hit) durumunda, ilgili kernelin merkez koordinat noktasına karşılık gelen binary resim koordinat noktasının değeri değiştirilerek 1 (true) değeri atanır. Şekil 6.7’de örnek dilation işlemi özetlenmektedir. Örnek şekil 6.7’de, binary resim üzerine structure kernelin eşleşme-eşleşmeme (hit-miss) durumları özetlenmiştir. Şekil 6.7 incelendiğinde koordinat düzleminde bir tane eşleşen (1*1) değer olduğu görülmektedir. Eşleşen bu değer sayesinde kernelin merkezine karşılık gelen binary resmin koordinat noktası değiştirilerek 1 (true) yapılır.



Şekil 6.7 Dilation İşlemi

Erosion işleminde ise binary resim üzerinde taranan kernelin herhangi bir koordinat noktası eşleşmeme (0*1 miss) olması durumunda, kernelin merkezine karşılık gelen binary resmin koordinat noktası değiştirilerek 0 (false) yapılır. Erosion işleminde binary resim üzerinde bir inceltme işlemi yapılırken, Dilation işleminde binary resim üzerinde kalınlaştırma işlemi gerçekleştirilir.

Şekil 6.8’de gösterilen binary resim, şekil 6.6’daki yumuşatılmış binary resim üzerine uygulanan dilation ve erosion işlemleri sonucunda elde edilmiştir. Elde edilen resimde küçük çıkıntılar ve pürüzler giderilmiştir.




Şekil 6.8 Dilation/Erosion Binary Görüntü


6.3 Kontur Tespiti

Kontur, görüntü üzerinde bir bölgenin ya da özelliğın koordinatlarını belirleme işlemidir. Bu bölge resim üzerinde, diğer bölgelerden farklı özellikler barındıran pikseller kümesi olarak ifade edilebilir. Örneğın şekil 6.8’de ifade edilen binary görüntüde beyaz pikseller (ön plan), siyah piksellere (arka plan) göre ayırt edici bir özellik barındırır.

Binary görüntülerde kontur bulma işlemi, ön planda belirtilen piksellerin çevresinin belirlenme işlemidir. Binary görüntülerden kontur çıkarma işlemi resim üzerinde köşe bulma (edge detection) filtresi uygulanarak gerçekleşir. Elde edilen görüntü resimdeki çevre pikselleri ifade etmektedir. Daha sonra elde edilen bu köşe pikseller belirli bir hiyerarşik sıraya göre düzenlenerek kontur kümelerini oluşturur. Binary görüntüden kontur oluşturma görseli şekil 6.9-6.10’da ifade edilmiştir.



Şekil 6.9 Binary Görüntü



Şekil 6.10 Binary Kontur Görüntü

Binary görüntülerden köşe bulma işleminde Laplacian Filtresi kullanılır. Laplacian filtresi binary resim üzerindeki piksel değişimlerini tespit etmek için kullanılabilir. Bu değişim yerleri görüntüdeki köşe ya da çevre piksellerini ifade eder. Denklem (6.2)'de Laplacian Filtresi formüle edilmiştir. Denklem (6.2) 2. dereceden kısmi türev kullanarak, resmin (x,y) noktasındaki değişimi bulur.

$$L(x, y) = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2} \quad (6.2)$$

Laplacian filtresi, binary resim üzerinde belirli aralıklar ile taranan Laplacian kerneli'nin, her adımda binary resimde örtüşen noktalarının, konvolüsyon değerleri alınarak hesaplanır. Şekil 6.11'de resim üzerine uygulanan laplacian filtresi ifade edilmiştir.

0	-1	0
-1	4	-1
0	-1	0

Şekil 6.11 Laplacian Kernel

6.4 Kontur Seçimi

Binary görüntülerden elde edilen kontur resimler şekil 6.10'da gösterilmiştir. Şekil 6.10'daki binary kontur resim incelendiğinde 9 adet birbirinden bağımsız kontur bulunmaktadır. Tespit edilen bu konturlar, başlangıçta resimde birer piksel olarak ifade edilen noktalar kümesini oluşturmaktadır. Resim üzerinde uygulanacak bir takım bölütleme teknikleri ile bu konturların bireysel nesne olarak tespit edilmesi sağlanmaktadır.


Binary kontur resim üzerine uygulanacak Bölge Genişletme yöntemi ile her bir kontur bireysel olarak tespit edilebilir. Konturları tespit etme işlemi, binary resim üzerindeki bağlantılı piksellerin aynı küme içinde gruplandırılması ile oluşur. Elde edilen küme bağımsız birer kontur nesnesini ifade etmektedir, Binary resim üzerindeki her piksel bir kümeye dahil oluncaya kadar bu işlemler tekrarlanır.

Elde edilen kontur nesnelere içinden, karaciğer bölgesine ait olan konturun tespiti için kullanılacak eşitsizlik $C_i^n - C^{n-1} < Min_a$, $S_i^n - S^{n-1} < Min_\beta$ şeklinde formülize edilebilir. C_i^n , n. kesitteki i. konturun merkez moment koordinatı, S_i^n ise n. kesitteki i. konturun boyutu olarak ifade edilir. C^{n-1} ve S^{n-1} , tespit edilen bir önceki kesitteki en uygun konturun merkez noktası ve boyutudur. $C_i^n - C^{n-1} < Min_a$ sağlanması incelendiğinde, n. kesitteki i. konturun merkez koordinat noktası ile, bir önceki kesitte tespit edilen optimum konturun merkez koordinat noktası arasındaki euclidean uzaklık farkının Min_a dan küçük olması gerekmektedir. Min_a ise n. kesitteki


deki tüm konturların, (n-1). kesitteki en optimum kontur ile olan farklarının en küçük değerini ifade etmektedir. Konturların moment merkez koordinatları arasındaki fark euclidean uzaklık değerleri ile ölçülür.

$S_i^n - S^{n-1} < Min_\beta$ denkleminde ise n. kesitte tespit edilen konturlar içinden boyut olarak, (n-1). kesitte tespit edilen kontura boyut büyüklük değeri olarak en yakın olan konturun seçilme işlemidir. Min_β değeri kontur boyut büyüklük değerleri arasındaki farkın minimum değerini ifade etmektedir.

Kontur seçme formülü incelendiğinde, boyut ve merkezi yakınlık olarak birbirlerine en yakın olan konturların seçildiği görülmektedir.




Şekil 6.12 Kontur Görüntüler



Şekil 6.13 Optimum Kontur Görüntü


Kontur seçme formülü şekil 6.12'deki resme uygulandığında, şekil 6.13'deki optimum kontur içeren bir binary görüntü elde edilir. Kontur seçme işleminin tüm kesitlerde yapılması sonucunda birbirleri ile bağlantılı ve uyumlu kontur kümeleri elde edilir. Şekil 6.14'te bu kontur kümelerinden oluşan 3B Yüzey Haritası gösterilmiştir.



Şekil 6.14 3B Binary Yüzey (Birleştirilmiş kontur kümeleri)

6.5 Kontur Düzeltme

Kontur resimlerinin oluşturduğu yüzey haritası şekil 6.14'te gösterilmiştir. Bu görüntüler incelendiğinde bazı kesitlerde, karaciğer bölütünün farklı doku çeşitlerini içerdiği görülmektedir. Şekil 6.15'de hatalı olarak seçilmiş karaciğer bölütleri gösterilmiştir.



Şekil 6.15 Hatalı Karaciğer Bölütü

Karaciğer seçiminde hatalı olarak bölütlenen bölgelerin oluşmasının en büyük nedeni, bu bölgelerin karaciğer dokusu ile olan piksel yoğunluk benzerliğidir. Piksel tabanlı (Bölge Genişletme) veya eğim tabanlı (Level Set) geliştirilen algoritmaların çoğu bu durum karşısında yetersiz kalmaktadır.


Karaciğer bölütleme işleminde, hatalı seçilen bölgelerin tespit edilmesi ve silinmesi için eğim tabanlı bir kontur düzeltme yaklaşımı önerilmektedir. Bu yöntem binary kontur resimlerinin piksel bazında geometri ve eğim parametrelerini kullanarak hatalı bölütlü bölgeleri düzeltmektedir. Kontur düzeltme yaklaşımı, birbirleri ile bağlantılı olan kontur pikselleri arasındaki yönelim durumuna göre bir eğim haritası oluşturma işlemini temel almaktadır.

Binary kontur resimden, eğim haritası çıkartma işlemi her bir kontur pikselinin yönelim durumunun belirlenmesi ile gerçekleşir. Şekil 6.16'da örnek bir eğim haritasında piksel bazında yönelim dereceleri özetlenmiştir.


0	0	0	0	0	0	0
0	0	0	1	1	0	0
0	0	1	0	0	1	0
0	0	1	0	0	1	0
0	0	0	0	0	0	1
0	0	0	0	0	0	0

Şekil 6.16 Eğim Haritası

Şekil 6.17’de binary kontur görüntü üzerine eğim fonksiyonu uygulanması sonucu şekil 6.18’deki eğim haritası elde edilmiştir.



Şekil 6.17 Binary Kontur Görüntü



Şekil 6.18 Binary Kontur Eğim Haritası

Binary kontur resimlerdeki bozulma bölgelerinin tespiti için önerilen yöntem, kontur pikselleri arasındaki geometrik uzaklık ve ortalama eğim kullanılarak belirli bir yaklaşımda bulunmaktır. Hiyerarşik şekilde sıralanmış kontur pikselleri arasından piksel konumu ve indeks bakımından belirli kriterlere uygun iki piksel seçilir ve bu pikseller arasındaki ortalama eğim farklılıklarının derecelerine göre, bozulma bölgeleri tespit edilebilir.


$$GeometricPosition^i - GeometricPosition^j < \beta \quad (6.3)$$

$$IndexPosition^i - IndexPosition^j > \gamma \quad (6.4)$$

Hiyerarşik tüm kontur indeksleri birbirlerine göre belirli kriterleri sağlaması gerekmektedir. Denklem (6.3) ve (6.4) eşitliklerini sağlayan herhangi iki indeks bozulma bölgesi oluşturabilir. Denklemlerdeki *GeometricPosition* ve *IndexPosition*, i ve j. indekslerinin koordinat noktası ve indeks sırasıdır.

Denklem (6.4), herhangi iki indeks i ve j'nin indeks uzaklıkları belirli bir γ değerinden yüksek ise ve denklem (6.3), herhangi iki indeks i ve j'nin koordinat noktaları arasındaki değer farkı β değerinden düşük ise bu iki indeks arasında bir bozulma olabileceği ifade edilir. Testlerde belirli iki indeks arasındaki fark γ değeri 10 ve indeksler arasındaki eğim farkı değeri β , 30 olarak alındığında optimum sonuçlar üretilmektedir. Bu değerler farklı kontur varyasyonlarına göre değiştirilebilir.

İndeks ve geometrik farkları belirli değerlerde olan iki indeks 'in kesin olarak bozulma bölgesini ifade edip etmeyeceğini ortalama eğim grafiğine bakılarak karar verilebilir.



Şekil 6.19 Ortalama Eğim Grafiği

Şekil 6.19’da ifade edilen ortalama eğim grafiği, hiyerarşik olarak sıralanmış kontur indekslerinin, indeks bazında ortalama eğim değerini vermektedir. N. indeksin ortalama eğim değeri $\frac{\sum_{i=0}^n c_i^{eğim}}{N}$, formülü ile bulunur.


Denklem (6.3) ve (6.4)’deki eşitlikleri sağlayan herhangi iki indeks i ve j’nin, ortalama eğim grafiğindeki değerleri arasındaki fark $c_i^{eğim} - c_j^{eğim} < \theta$ ’dan küçük ise i ve j indeksleri arasındaki bölge bozulma bölgesi olarak ifade edilir. Bozulma bölgelerini oluşturan herhangi iki indeks arasındaki piksel koordinatları, kontur bölgesinden çıkartılır. Bu iki nokta daha sonra, Kübik Bezier eğrileri denklem (6.5) ile birleştirilerek yumuşak bir bağlantı elde edilmesi sağlanır. Kübik Bezier eğri denklemi incelendiğinde P0, P1, P2 ve P3 değerleri piksel koordinat noktalarını ifade ederken, u değeri değişimi ifade edip $0 \leq \mu \leq 1$ aralığında değerler almaktadır.

$$C(u) = P_0(1 - u)^3 + 3P_1u(1 - u)^2 + 3P_2u^2(1 - u) + P_3u^3 \quad (6.5)$$


Binary resim üzerindeki çıkıntıların giderilmesi ve yumuşatılması için önerilen bir diğer yaklaşım ise 3B binary görüntü üzerinde farklı açılardan işlem yapmaktır. Axial görüntüler üzerinde işlem yapılarak elde edilen binary görüntüler (Şekil 6.20-6.21), sagittal bakış (Şekil 6.22-6.23) açısına göre yorumlanıp tekrar işleminden geçirilerek binary resim üzerindeki hatalı seçilen bölgelerin giderilmesi sağlanır.




Şekil 6.20 Axial- Kesit Resim



Şekil 6.21 Axial-Binary Resim



Şekil 6.22 Sagittal-Kesit Resim




Şekil 6.23 Sagittal-Binary Resim

Şekil 6.20’de axial kesitler üzerinden işlem yapılarak elde edilen binary görüntüler, axial kesitte bulunan tüm piksel koordinat değerleri sagittal bakış açısına göre 2B olarak ele alınırsa şekil 6.22 sagittal binary kesit görüntüsü elde edilir. Sagittal binary görüntüler üzerinde yumuşatma algoritması uygulanırsa istenilen 3B binary görüntüler (Şekil 6.21, 6.23) elde edilir.

7. DENEYSEL SONUÇLAR

Geliştirilen karaciğer bölütleme algoritması ile, farklı doku çeşitlerine sahip hastaların CT Medikal görüntüleri üzerinden karaciğer bölütleme testlerinin sonuçları incelenmiştir. Testler bölütleme algoritmasını da içerisinde barındıran Medikal bir proje kapsamında geliştirilen Medikal Görselleştirme ve Analiz Yazılım Uygulaması ile gerçekleştirilmiştir (Şekil 7.1).



Şekil 7.1 Medikal Görselleştirme ve Analiz Uygulaması

Uygulama medikal resimler ve çıktıları 3-B modeller üzerinde 3-B ve 2-B bölütleme 3-B model üzerinde düzeltme, kesme, ölçüm vb. gibi son derece ileri uygulama araçları içeren, kapsamlı bir görüntüleme ve analiz yazılımıdır.


Tüm deneysel sonuçlar işletim sistemi Windows 8, Qt Platformunda, yazılım dili C++ Intel Core i7 4720, CPU 2.60 Ghz, 16 Gb Ram özelliklerini içeren bir bilgisayarda test edilmiştir (Çizelge 5.1)

Bölütleme algoritmasının 5 farklı hasta için ürettiği sonuçlar aşağıdaki çizelgede özetlenmiştir. Çizelge 7.1 incelendiğinde, karaciğer hacimlerinin tespit işlemi, karaciğeri ifade eden piksel koordinatları arasındaki uzaklık değeri ve axial kesitler arasındaki uzaklık değerlerinin çarpımı sonucunda elde edilmiştir. Doğru karaciğer hacimleri ise, radyolog ve doktorların her bir hasta için onayladığı karaciğer hacimlerini ifade etmektedir. Bu veriler haricinde 30 farklı hasta görüntüsü üzerinde çalışılmıştır. Bölütleme algoritması ortalama olarak doğruluk oranı % 95, işlem zamanı 3.0 sn. ölçüt değerleri ile başarılı bir bölütleme işlemi gerçekleştirilmiştir.


Çizelge 7.1 Önerilen Algoritmanın Test Sonuçları

	Tespit Edilen Karaciğer Hacmi	Doğru Karaciğer Hacmi	Doğruluk Oranı	İşlem Zamanı	Yöntem
Hasta-1	1711 ml	1709 ml	%99.8	3.0 sn.	Tek Kök Nokta
Hasta-2	1037 ml	1080 ml	%96	2.9 sn.	Tek Kök Nokta
Hasta-3	1514 ml	1512 ml	%99.8	3.4 sn.	Tek Kök Nokta
Hasta-4	1172 ml	1249 ml	%93	3.2 sn.	İki Kök Nokta
Hasta-5	1546 ml	1638 ml	%94	2.8 sn.	Tek Kök Nokta
30 Hasta Ortalama Sonuç	-----	-----	%95	3.0 sn	-----


Hasta-1



Gerçek Resim



Tespit Edilen Binary 3B Görüntü




Doğru Binary 3B Görüntü

Doğru Karaciğer Hacmi: 1711 ml / Tespit Edilen Karaciğer Hacmi: 1709 ml


Doğruluk Oranı: %99,8/ İşlem Zamanı: 3.0 sn.

Yöntem: Tek Seed(Kök) nokta kullanılarak tespit edilmiştir.


Hasta-2



Gerçek Resim



Tespit Edilen Binary 3B Görüntü




Doğru Binary 3B Görüntü

Doğru Karaciğer Hacmi: 1037 ml / Tespit Edilen Karaciğer Hacmi: 1080 ml


Doğruluk Oranı: %96 / İşlem Zamanı: 2.9 sn.

Yöntem: Tek Seed(Kök) nokta kullanılarak tespit edilmiştir.


Hasta-3



Gerçek Resim



Tespit Edilen Binary 3B Görüntü




Doğru Binary 3B Görüntü

Doğru Karaciğer Hacmi: 1514 ml / Tespit Edilen Karaciğer Hacmi: 1512 ml


Doğruluk Oranı: %99.9 / İşlem Zamanı: 3.4 sn.

Yöntem: Tek Seed(Kök) nokta kullanılarak tespit edilmiştir.


Hasta-4



Gerçek Resim



Tespit Edilen Binary 3B Görüntü



Doğru Binary 3B Görüntü

Doğru Karaciğer Hacmi: 1172 ml / Tespit Edilen Karaciğer Hacmi: 1249 ml


Doğruluk Oranı: %93/ İşlem Zamanı: 3.2 sn.

Yöntem: İki Seed(Kök) nokta kullanılarak tespit edilmiştir.


Hasta-5



Gerçek Resim



Tespit Edilen Binary 3B Görüntü



Doğru Binary 3B Görüntü

Doğru Karaciğer Hacmi: 1546 ml / Tespit Edilen Karaciğer Hacmi: 1638 ml

Doğruluk Oranı :%94 / İşlem Zamanı: 2.8 sn.

Yöntem : Tek Seed(Kök) nokta kullanılarak tespit edilmiştir.

8. SONUÇ

Bu tez çalışması kapsamında, klinik medikal görüntü işleme alanında CT görüntüleri üzerinden karaciğer dokusunun bölütlenmesi üzerine farklı teknikler karşılaştırmalı olarak ele alınıp, matematiksel ve uygulamalı olarak incelenmiştir. Geleneksel bölütleme tekniklerinin, karaciğer bölütlenmesi için çoğu durumda başarısız sonuçlar ürettiği gözlemlenmiştir. Bu teknikler gerek işlem zamanı gerekse işlem yükü olarak farklı açılardan eksiklikleri tespit edilmiştir. Tüm bu problemler ayrıntılı olarak incelenip, bu sorunların çözümü doğrultusunda yeni bir bölütleme yöntemi bu çalışma kapsamında önerilmiştir.

Geleneksel bölütleme yöntemlerinden bölgesel tabanlı Region Growing bölütleme yöntemi ile işlem zamanı açısından istenilen başarı oranı elde edilebilecek performans ve doğruluk açısından son derece başarısız bir bölütleme işlemi gerçekleştirilmektedir. Maximum Likelihood and Gaussian Density Estimation ve Bayesian gibi sınıfsal tabanlı bölütleme yöntemlerinde ise genelde iterasyonlardan kaynaklı yüksek işlem zaman maliyeti ve doğruluk oranı son derece düşük bölütleme işlemi gerçekleştirilmektedir. Level Set and Curve Evolution yönteminde bölgesel ve sınıfsal tabanlı bölütleme yöntemlerinden farklı olarak eğim tabanlı bir bölütleme yaklaşımı kullanılmaktadır. Bu yöntem doğruluk açısından diğer iki yöntemle göre son derece başarılı sonuçlar üretmiş olsa da işlem zamanı açısından son derece maliyetlidir. Ayrıca, farklı resim çeşitleri üzerinde farklı sonuç üreten (optimize olmayan) ve resim üzerinde bir takım ön işlemler yapmayı zorunlu tuttuğundan dolayı 3-B resimler için performans bakımından etkin bir bölütleme yöntemi olmadığı bu çalışma kapsamında tespit edilmiştir. Tez çalışması için önerilen özgün bölütleme yöntemi geleneksel (Region Growing, Level Set) gibi bazı algoritmaları içerisinde barındıran melez bir yöntemdir. Tüm bu yöntemler birleştirilerek önerilen özgün algoritmanın daha efektif, doğru ve otomatik çalışması için farklı bakış açıları ve farklı algoritmalar ile tekrar yorumlanıp başarılı bir karaciğer bölütleme algoritması oluşturulmuştur. Elde edilen bu algoritma doğruluk, performans ve işlem zamanı olarak profesyonel klinik uygulamalardaki yüksek doğruluk ile sonuçlar üretmiştir.

Ek olarak, önerilen özgün algoritma geliřtirilmeye açık farklı doku ve organlar için de bölütleme stratejilerin geliřtirilmesinde kolaylıkla kullanılacak uyarlanabilir ve esnek bir yapıya sahiptir. Bu bağlamda geliřtirilen algoritmanın farklı organ ve dokular için kullanılması planlanmaktadır.



KAYNAKLAR

- Ajala Funmilola, A., Oke, OA., Adedeji, TO., Alade, OM. and Adewusi, EA. 2012. Fuzzy k-means Clustering Algorithm for Medical Image Segmentation. *Journal of Information Engineering and Applications*, 2(6), 21-32.
- Amnon, S. 2008a. Bayesian decision theory. *dblp Computer Science bibliography*, 1-10, Jerusalem.
- Amnon, S. 2008b. Maximum Likelihood/Maximum Entropy Duality. *dblp Computer Science bibliography*, 12-15, Jerusalem.
- Anonymous. 2018a. Web Sitesi: <https://www.quora.com/How-do-I-read-a-CT-scan> Erişim Tarihi: 02.08.2018.
- Anonymous. 2018b. Web Sitesi: https://en.wikipedia.org/wiki/CT_scan Erişim Tarihi: 02.08.2018.
- Anonymous. 2018c. Web Sitesi: <http://www.livervision.org/> , Erişim Tarihi: 02.08.2018.
- Anonymous. 2018d. Web Sitesi: http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/-MARBLE/medium/segment/split.htm, Erişim Tarihi:02.08.2018.
- Anonymous. 2018e. Web Sitesi: <https://home.deib.polimi.it/matteucc//Clustering/tutorial/html/c-Means.html>, Erişim Tarihi: 02.08.2018.
- Anonymous. 2018f. Web Sitesi: <https://www.mathworks.com/company/newsletters/articles/the-watershed-transform-strategies-for-image-segmentation.html> Erişim Tarihi: 02.08.2018.
- Anonymous. 2018g. Web Sitesi: <https://www.mathworks.com/help/images/examples/marker-controlled-watershed-segmentation.html> Erişim Tarihi: 02.08.2018.
- Anonymous. 2018h. Web Sitesi: https://en.wikipedia.org/wiki/Gaussian_blur Erişim Tarihi: 02.08.2018.
- Bresson, X., Esedoğlu, S., Vandergheynst, P., Thiran, JP. and Osher, S. 2005. Global minimizers of the active Contour/Snake model. *UCLA CAM Report*, 04-05.
- Christ, PF., Elshaer, MEA., Ettlinger, F., Tatavrtıy, S., Bickel, M., Bilic, P., Rempfler, M., Armbruster, M., Hofmann, F., D’Anastasi, M., Sommer, WH., Ahmadi, SA. and Menze, BH. 2016. Automatic liver and lesion segmentation in ct using cascaded fully convolutional neural networks and 3B conditional random fields. In: Ourselin S., Joskowicz L., Sabuncu M., Unal G., Wells W. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016*. MICCAI 2016. Lecture Notes in Computer Science, vol 9901. Springer, Cham, 415–423.
- Elayaraja, P. and Suganthi, M. November 2014. Survey on Medical Image Segmentation Algorithms. *International Journal of Advanced Research in Computer and Communication Engineering*, 3(11), 8591-8592.
- Fernandez-de-Manuel, L., Rubio, JL., Ledesma-Carbayo, MJ., Pascau, J., Tellado, JM., Ramon E., Desco, M. and Santos, A. 2009. 3D liver segmentation in preoperative CT images using a level-sets active surface method, *International Conference of the IEEE EMBS*. Vol.1, 3625–3628, Minnessota.
- Gamarendi, JF., Malpica, N., Martel, J. and Schiavi, E., 2007. Automatic Segmentation of the Liver in CT Using Level Sets Without Edges. In: Martí J., Benedí J.M., Mendonça

- A.M., Serrat J. Pattern Recognition and Image Analysis. IbPRIA 2007., Lecture Notes in Computer Science, Springer, vol 4477, 161-168, Berlin, Heidelberg.
- Glombitza, G., Lamade, W., Demiris, AM., Göpfert, MR., Mater, A., Bahner, ML., Meinzer, HP., Richter, G., Lehnert, T. and Herfarth, C. 1999. Virtual planning of liver resections: image processing, visualization and volumetric evaluation. *International Journal of Medical Informatics*, 53(2-3), 225-237.
- Heimann, T., Ginneken, Bv., Styner, M., Arzhaeva, Y., Aurich, V., Bauer, C., Beck, A., Becker, C., Beichel, R., Bekes, G., Bello, F., Binnig, G., Bischof, H., Bornik, A., Cashman, PM., Chi, Y., Cordova, A., Dawant, BM., Fidrich, M., Furst, JD., Furukawa, D., Grenacher, L., Hornegger, J., Kainmüller, D., Kitney, RI., Kobatake, H., Lamecker, H., Lange, T., Lee, J., Lennon, B., Li, R., Li, S., Meinzer, HP., Nemeth, G., Raicu, DS., Rau, AM., van Rikxoort, EM., Rousson, M., Rusko, L., Saddi, KA., Schmidt, G., Seghers, D., Shimizu, A., Slagmolen, P., Sorantin, E., Soza, G., Susomboon, R., Waite, JM., Wimmer, A. and Wolf, I. 2009. Comparison and Evaluation of Methods for Liver Segmentation from CT dataset. *IEEE Transactions on Medical Imaging*, 28(8), 1251–1265.
- Li, X., Chen, H., Qi, X., Dou, Q., Fu, CW. and Heng, PA. 2018. H-denseunet: Hybrid densely connected unet for liver and liver tumor segmentation from ct volumes. *IEEE transactions on Medical Imaging*, *dblp Computer Science bibliography*, arXiv: 1709.07330, 1-13.
- Lu, F., Wu, F., Hu, P., Peng, Z. and Kong, D. 2017. Automatic 3D liver location and segmentation via convolutional neural network and graph cut. *Int. J. Comput. Assist. Radiol. Surg.* 12(2), 171–182.
- Malik, J. and Perona, P. 1990. P. Scale-space and edge detection using anisotropic diffusion. *IEEE transactions on Pattern Analysis and Machine Intelligence*, 12(7), 629-639.
- Masutani, Y., Uozumi K., Masaaki A. and Kuni O. 2006. Liver CT image processing: A short introduction of the technical elements. *European Journal of Radiology*, 58(2), 246-251.
- Meinzer, HP., Schemmer, P., Schobinger, M., Nolden, M., Heimann, T. and Yalcin, B. 2004 C-computer-based Surgery Planning for Living Liver Donation. 20th ISPRS Congress, *International Archives of Photogrammetry and Remote Sensing*, vol. 35, no. 5, 291-295, Istanbul.
- Merkow, J., Marsden, A., Kriegman, D. and Tu, Z. 2016. Dense volume-to-volume vascular boundary detection. In: Ourselin S., Joskowicz L., Sabuncu M., Unal G., Wells W. (eds) *Medical Image Computing and Computer-Assisted Intervention -- MICCAI 2016*. MICCAI 2016. *Lecture Notes in Computer Science*, Vol. 9902. Springer, Cham, 371–379.
- Numminen, K., Sipila, O. and Makisalo, H. 2005. Preoperative hepatic 3B models: Virtual liver resection using three-dimensional imaging technique. *European J. Radiology*, 56(2), 179-184.
- Oliveira, D., Feitosa, R. and Correia, MM. 2008. Automatic Couinaud liver and veins segmentation from CT images. In *Biosignals - International Conference on Bio-Inspired Systems and Signal Processing*. Volume 1, 249–252.
- Pratibha Thakur, Er., and Nishi Madaan, Er. 2014. A Survey of Image Segmentation Techniques, *International Journal of Research In Computer Applications and Robotic*, 2(4), 158-165.

- Ptucha, R. and Savakis, AE. 2014. LGE-KSVD: robust sparse representation classification. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 23(4), 1737–1750.
- Ravindraiah, R., and Tejaswini, K. July 2013. A Survey of Image Segmentation Algorithms Based On Fuzzy Clustering. *International Journal of Computer Science and Mobile Computing*, 2(7), 200-206.
- Saito, A., Yamamoto, S., Nawano, S. and Shimizu, A. 2016. Automated liver segmentation from a postmortem CT scan based on a statistical shape model. *International Journal of Computer Assisted Radiology & Surgery*;12(2), 1–17.
- Salem Saleh, A., Kalyankar, NV. and Khamitkar, SD. 2010. Image Segmentation by Using Threshold Techniques, *JOURNAL OF COMPUTING*, 2(5), 83-86.
- Soliman, A., Khalifa, F., Elnakib, A., Abou, E-GM., Dunlap, N., Wang, B., Gimel'farb, G., Keynton, R. and El-Baz, A. 2017. Accurate Lungs Segmentation on CT Chest Images by Adaptive Appearance-Guided Shape Modeling. *IEEE Trans Med Imaging*, 36(1), 263-276.
- Song, X., Cheng, M., Wang, B., Huang, S. and Huang, X. 2011. Computer-aided Preoperative Planning for liver Surgery based on CT Images. *Procedia Engineering*, 24, 133-137.
- Xiaopeng, Y., Hee Chul, Yu., Younggeun, Choi., Wonsup, Lee., Baojian, Wang., Jaedo, Yang., Hongpil, H., Ji Hyun, Kim., Jisso, S., Baik Hwan, C. and Heecheon, Y. 2014. A hybrid semi-automatic method for liver segmentation based on level-set methods using multiple seed points. *Computer Methods and Programs in Biomedicine*, 113(1), 69-79.

ÖZGEÇMİŞ

Adı Soyadı : Serhat CAN
Doğum Yeri : Çorum
Doğum Tarihi : 24.05.1991
Medeni Hali : Bekar
Yabancı Dili : İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise : Çorum Fatih Lisesi (2011).
Lisans : Ankara Üniversitesi Bilgisayar Mühendisliği (2015).
Yüksek Lisans : Ankara Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı (Eylül 2018)

Çalıştığı Kurum/Kurumlar ve Yıl

- Medi Vision (Özel Sektör) (2017- ...)
- Netcad Yazılım (Özel Sektör) (2015 - 2017)

Yayınlar (ICTACSE)

- Ajabshir, V., Can, S., Güzel, MS., Bostanci, E. ve Askerbeyli İ. 2017/10/11. Comparison of Genetic Algorithm and PSO Method for Optimization of Potential Fields Parameters. International Conference on Theoretical and Applied Computer Science and Engineering (ICTACSE, 2017), 46.

Hakemli Dergiler

- Ajabshir, V., Güzel, MS., Can, S. ve Bostanci, E. 2017/12. Optimization of potential field parameters using genetic algorithm. Global Journal of Computer Sciences: Theory and Research, 7, 34-43.

Ulusal Kongre Sunum

- Güzel, MS., Can, S., Erdem, H., Sentürk, B. ve Bostanci, E. 2017/6/23. A mobile robot navigation system using a map-building based approach. Proceedings of Academics World 69th International Conference, 17-20, Istanbul.