

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**TERSİNİR BÖLÜTLEME YAKLAŞIMI İLE İNTERNAL KAROTİD ARTER
YAPILARININ ÜÇ-BOYUTLU BÖLÜTLENMESİ**

DOKTORA TEZİ

Bilgisayar Yük. Müh. Ferhat BOZKURT

**MAYIS 2018
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**TERSİNİR BÖLÜTLEME YAKLAŞIMI İLE İNTERNAL KAROTİD ARTER
YAPILARININ ÜÇ-BOYUTLU BÖLÜTLENMESİ**

Bil. Yük. Müh. Ferhat BOZKURT

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"DOKTOR (BİLGİSAYAR MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 09 / 04 / 2018

Tezin Savunma Tarihi : 04 / 05 / 2018

Tez Danışmanı : Prof. Dr. Cemal KÖSE

Trabzon 2018

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**Bilgisayar Mühendisliği Anabilim Dalında
Ferhat BOZKURT Tarafından hazırlanan**

**TERSİNİR BÖLÜTLEME YAKLAŞIMI İLE İNTERNAL KAROTİD ARTER
YAPILARININ ÜÇ-BOYUTLU BÖLÜTLENMESİ**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 10 /04/2018 gün ve 1748 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
DOKTORA TEZİ
olarak kabul edilmiştir.**

Jüri Üyeleri

Başkan : Prof. Dr. Recep Alp KUT

Üye : Prof. Dr. Cemal KÖSE

Üye : Prof. Dr. Temel KAYIKÇIOĞLU

Üye : Prof. Dr. Murat EKİNCİ

Üye : Doç. Dr. Ümit Deniz ULUŞAR

The image shows five handwritten signatures in blue ink, each placed on a horizontal dotted line. The signatures are: 1. Recep Alp KUT (top), 2. Cemal Köse, 3. Temel Kayıkçioğlu, 4. Murat Ekinci, and 5. Ümit Deniz Uluşar (bottom).

**Prof. Dr. Sadettin KORKMAZ
Enstitü Müdürü**

ÖNSÖZ

Damar hastalıkları ölüm vakalarının en önemli nedenlerinden olmasından ötürü, hastaların muayenesinde daha fazla bilgi edinilmesi hayati bir önem arz etmektedir. Bu bakımdan tıbbi görüntüleme bu tür damar hastalıklarının tanısında kullanılan önemli ve hızlı büyüyen bir tekniktir. Bu çalışmada, tersinir yöntemle tek bir seferde BTA görüntülerinden kemik ve kıkırdak dokuların ayrıştırılması sonrasında bölütlenen karotid arterlerin sonuçlarının üç boyutlu olarak görselleştirilme uygulaması gerçekleştirilmiştir.

Çalışmalarında danışmanlığımı üstlenen, her türlü destek ve katkılarıyla çalışmamı yönlendiren çok değerli danışman hocam Sayın Prof. Dr. Cemal KÖSE'ye teşekkürlerimi sunarım.

Çalışma sürecinde değerli görüş ve katkılarını esirgemeyen sayın Prof. Dr. Temel KAYIKÇIOĞLU'na ve Prof. Dr. Murat EKİNCİ'ye teşekkür ederim.

Tez çalışmasında, değerli görüş ve önerileriyle çalışmalarında yol gösteren, kullandığım görüntüleri temin eden, gerekli tıbbi bilgileri anlatan, sayın hocam KTÜ Tıp Fakültesi Radyoloji Anabilim Dalı Başkanı Prof. Dr. Ahmet Sarı, değerlendirmeler sırasında kapılarını sürekli çalarak rahatsız ettiğim, Radyoloji bölümlerindeki sayın hocalarım Dr. Öğr. Üyesi. Şükrü Oğuz ve Arş. Gör. Dr. Hüseyin Alper Kızıloğlu'na en içten teşekkürlerimi sunarım.

Çalışmalarında bana destek olan değerli mesai arkadaşım Arş. Gör. Mete YAĞANOĞLU'na teşekkürü bir borç bilirim.

Öğrenim hayatım boyunca buralara gelmemi sağlayan sevgili babama, anneme ve kız kardeşime müteşekkir olduğumu belirtirim. Hayatıma anlam kazandıran, kızlarım Ecem Esma ve Ahsen Zehra'ya, tez çalışması sürecinde her daim bana destek veren ve tahammül eden çok sevdiğim eşim Gülhan ALAGÖZ BOZKURT'a sonsuz teşekkürlerimi sunarım.

Ferhat BOZKURT

Trabzon 2018

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum ‘‘Tersinir Bölütleme Yaklaşımı İle İnternal Karotid Arter Yapılarının Üç-Boyutlu Bölütlenmesi’’ başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Cemal Köse’nin sorumluluğunda tamamladığımı, verileri / örnekleri kendim topladığımı, deneyleri / analizleri ilgili laboratuarlarda yaptığımı / yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 04/05/2018

Ferhat BOZKURT

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	X
SUMMARY	X
ŞEKİLLER DİZİNİ.....	XI
TABLolar DİZİNİ.....	XIV
SEMBOLLER DİZİNİ.....	XVIII
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Tezin Amacı ve Yapısı	3
1.3. Bilgisayarlı Tomografi	4
1.3.1. BT Aygıtı.....	4
1.3.2. Görüntü Oluşumu	7
1.3.3. Bilgisayarlı Tomografi Anjiyografi.....	10
1.3.4. Kemik Çıkarma Bilgisayarlı Tomografi Anjiyografisi	11
1.3.5. Manyetik Rezonans Anjiyografi ile BTA'nın Karşılaştırılması.....	11
1.4. Karotid Arterlerin Anatomisi.....	12
1.4.1. Yaygın Hastalıklar.....	13
1.4.1.1. Arter Darlığı (Stenosis)	13
1.4.1.2. Anevrizma (Aneurysm)	14
1.4.1.3. İnme (Stroke).....	15
1.5. Literatür Çalışması	15
1.5.1. Eşikleme	16
1.5.2. İstatistiksel Model Analizi.....	18
1.5.3. Deforme Edilebilir Modeller	18
1.5.4. Örüntü Tanıma.....	20

1.5.5.	Bölge Büyütme	21
1.5.5.1.	Şekil-tabanlı Bölge Büyütme Model	22
1.5.5.2.	Klasik Bölge Büyütme Model	23
1.5.5.3.	ATLAS ve Bölge Büyütme	23
1.5.5.4.	Filtreleme Tabanlı Bölge Büyütme	23
1.5.5.5.	Hibrid Bölge Büyütme ve Düzey Kümesi	24
1.5.6.	Matematiksel Morfoloji Yaklaşımları	25
1.5.7.	Damar Özniteliğine Dayalı Modeller	26
1.5.7.1.	Tüp (boru) Benzeri Çok-Ölçekli Filtreler.....	26
1.5.7.2.	Merkez hattı (centerline) Modeller.....	27
1.5.7.3.	3B Genelleştirilmiş Silindir Modelleri	28
2.	YAPILAN ÇALIŞMALAR.....	29
2.1.	Verilerin Toplanması ve BTA verisi	31
2.1.1.	DICOM Dosya Yapısı.....	32
2.2.	Önişleme İşlemleri.....	33
2.2.1.	Pencereleme ve Seviyelendirme	33
2.2.2.	Ortalama Kayma Filtresi	33
2.3.	Tersinir Bölütleme Yaklaşımı	35
2.3.1.	Histogram Analizi.....	37
2.3.2.	OTSU Yöntemini Kullanarak Çoklu Eşikleme	40
2.3.3.	Bölütleme Yöntemleri	47
2.3.3.1.	Bölge Büyütme Yöntemi	47
2.3.3.1.1.	Tohumlandırılmalı Bölge Büyütme	50
2.3.3.1.2.	Doku Tabanlı Bölge Büyütme	51
2.3.3.1.3.	Otomatik Eşik Değer Seçimi	54
2.3.3.2.	Rassal Yürüyüş Yöntemi	60
2.3.4.	Kemik Bölütlemesi	62
2.3.5.	Damar Bölütlemesi	63
2.4.	Son İşleme Aşaması	64
2.4.1.	Morfolojik İşlem.....	65

2.4.2.	Şekilsel Bilginin Elde Edilmesi.....	66
2.4.3.	Damarın Gürültü ve Kemik Kalıntılarından Ayırt Edilmesi	70
2.5.	Danışmanlı Öğrenme.....	70
2.5.1.	Dokusal Öznitelikler.....	71
2.5.1.1.	Gri-seviye Histogramın İstatistiksel Öznitelikleri.....	71
2.5.1.2.	Haralick Doku Öznitelikleri	73
2.5.2.	Boyut İndirgeme	75
2.5.2.1.	Öznitelik Çıkarma Yöntemleri	77
2.5.2.1.1.	Temel Bileşenler Analizi	77
2.5.2.2.	Öznitelik Seçme Yöntemleri	80
2.5.3.	Makine Öğrenmesi ve Kullanılan Sınıflandırıcılar	83
2.5.3.1.	Yapay Sinir Ağları.....	83
2.5.3.2.	Destek Vektör Makineleri	85
2.5.3.3.	k-En Yakın Komşu Sınıflandırıcı.....	88
2.5.4.	Bölütlü Bölgelerin Sınıflandırılması	91
2.5.4.1.	Bölge-Tabanlı Aktif Kontur Bölütleme.....	92
2.5.4.2.	Sınıflandırıcı ile Karar-Verme Mekanizması	93
2.6.	Damar Takibi.....	96
2.7.	Görselleştirme.....	99
2.7.1.	3B Yeniden Yapılandırma.....	99
2.7.2.	3B Görselleştirme	102
3.	BULGULAR	104
3.1.	Karşılaştırma Yapılan Veri Setleri	104
3.2.	Performans Değerlendirme Ölçütleri.....	106
3.2.1.	İstatistiksel-tabanlı Ölçütler.....	106
3.2.2.	Alan-tabanlı Ölçütler	108
3.2.3.	Uzaklık-tabanlı Ölçütler	108
3.3.	Sınıflandırıcıların Performans Değerlendirmesi.....	111
3.4.	Bölütleme Sonuçlarının Değerlendirilmesi	112
4.	SONUÇLAR VE TARTIŞMA.....	125

5.	ÖNERİLER	129
6.	KAYNAKLAR.....	130
7.	EKLER	150

ÖZGEÇMİŞ



Doktora Tezi

ÖZET

TERSİNİR BÖLÜTLEME YAKLAŞIMI İLE İNTERNAL KAROTİD ARTER
YAPILARININ ÜÇ-BOYUTLU BÖLÜTLENMESİ

Ferhat BOZKURT

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Cemal KÖSE
2018, 157 Sayfa

İnternal karotid arterler yaşam için çok önemli olup, beyne oksijence zengin kanı taşıyan damarlardır. Bu damarlarda oluşan incelmeler, tıkanmalar kişide ciddi hasarlara yol açmakta ve ölüme bile sebebiyet verebilmektedir. Karotid arter stenozu genellikle aterosklerozun neden olduğu daralma veya karotid arter lümen dar geçitidir. Karotid arterler, kemik ve kemiksi yapılar ile yakın komşuluk göstermektedir. Damar değerlendirmesi yapılırken sıklıkla kemik doku ile karotid arterler birbirine karışmaktadır. Bu nedenle, damar yapısında bozulmaların olduğu potansiyel yerin devamında damar mı yoksa diğer yapılar mı olduğu yönünde şüpheler oluşmaktadır. Kontrast madde yüklü damarları bölütlemeye çalışırken ana mesele, damarlar ve kemikler arasında gerçekleşen yoğunluk örtüşmesidir. Bu tezin amacı, Bilgisayarlı tomografi anjiyografi görüntülerinden karotid arter bölütlemelerinin yapılarak hastalığın teşhisi konusunda bir karar destek sistemi oluşturmaktır. Bu çalışmada, tersinir yöntemle tek bir seferde BTA görüntülerinden kemik ve kıkırdak dokuların ayrıştırılması sonrasında bölütlenen karotid arterler sonuçlarının üç boyutlu olarak görselleştirilmesi gerçekleştirilmiştir.

Anahtar Kelimeler: Karotid arterler, kan damarları, damar bölütleme, görüntü işleme, makine öğrenmesi, 3B bölütleme, görselleştirme

PhD. Thesis

SUMMARY

3D SEGMENTATION OF INTERNAL CAROTID ARTERY STRUCTURES
WITH INVERSE SEGMENTATION APPROACH

Ferhat BOZKURT

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Cemal KÖSE
2018, 157 Pages

Internal carotid arteries, which carry oxygen-rich blood to the brain, are very vital for life. Congestions and thinning in these arteries can lead to serious damage in the human body that may even result in death. Carotid artery stenosis is usually narrowing caused by atherosclerosis or lumen bottleneck of the carotid artery. Carotid artery stenosis is usually narrowing caused by atherosclerosis or lumen bottleneck of the carotid artery. Carotid arteries show close proximity to bone and bony structures. Bone tissue and carotid arteries are often confused with each other when vessel evaluations perform. For this reason, it is usually a doubt whether the potential vessel disruption continues with veins or other structures. The main issue when trying to segment vessels full with contrast agent is the density overlap between vessel and bone. The purpose of this thesis is to make decision support system about diagnosis of the disease by extracting the carotid arteries from computerized tomography angiography images. In this study, bone and cartilage tissues are separated by using the inverse method from CTA images with only one scanning. Then, vessel segmentation is performed and the results are visualized in 3D.

Key Words: Carotid arteries, blood vessels, vessel segmentation, image processing, machine learning, 3D segmentation, visualization

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.1.	BT aygıtı [4].....	5
Şekil 1.2.	Helikal (Spiral) BT tarama prensibi [4]	6
Şekil 1.3.	Çok kesitli BT tarama prensibi [5,6].....	7
Şekil 1.4.	R: görüntü alanının çapı, piksel (axb) ve voksel (axbxd) [4].....	8
Şekil 1.5.	Hounsfield ölçeği [7]	9
Şekil 1.6.	Karotid arterlerin anatomisi [10].....	12
Şekil 1.7.	Damar anatomisi: (a) Atardamar (arter) yapısı, (b) Arter darlığı, (c) Stent takılan arter damar [8,11].....	14
Şekil 2.1.	Önerilen yöntemin akış diyagramı	30
Şekil 2.2.	DICOM dosya yapısı [6].....	31
Şekil 2.3.	DICOM veri seti yapısı [6]	32
Şekil 2.4.	Ortalama kayma filtresi ile, (a) filtre öncesi damar, (b) filtre sonrası damar	34
Şekil 2.5.	Kontrastsız ve kontrastlı aksiyel BTA görüntüleri: (a) boyun bölgesi kontrastsız, (b) boyun bölgesi kontrastlı, (c) şakak kemiği bölgesi kontrastsız, (d) şakak kemiği bölgesi kontrastlı görüntü [83,84].....	36
Şekil 2.6.	Lokal doku örneklerinin alınması	38
Şekil 2.7.	Örnek bir damar bölgesi ve lokal bölge histogramı	38
Şekil 2.8.	Farklı dokulara ait lokal histogramlar	39
Şekil 2.9.	Üç farklı dokuya ait lokal histogram grafikleri ve damar bölgesi	39
Şekil 2.10.	İkili (Otsu) eşik değeri ve çoklu eşik değerleri ile ayırt edilen gri seviye histogramların gösterimi [95].....	44
Şekil 2.11.	Görüntüdeki gri seviyelerin sınıflara ayırımı [88]	44
Şekil 2.12.	İki veya üç boyut için komşuluk gösterimi [97]	50
Şekil 2.13.	Aday piksel merkezli 5x5x5 alt hacim gösterimi.....	52

Şekil 2.14. Eş-oluşum matrislerinin hesaplanması için kullanılan 26 yönün gösterimi	53
Şekil 2.15. Bağlantılık için kullanılan a) 6 ve b) 26 komşuluğun gösterimi.....	54
Şekil 2.16. Bölge büyütme yöntemi ile bir ya da daha fazla tohum noktası ile BTA'da damar bölütlemesi	59
Şekil 2.17. Rassal yürüyüş yöntemi ile bir ya da daha fazla tohum noktası ile BTA'da kemik-damar bölütlemesi	62
Şekil 2.18. Bölge büyütme ve rassal yürüyüş yöntemi ile BTA'dan kemik bölütlemesi	63
Şekil 2.19. Bölge büyütme ve rassal yürüyüş yöntemi ile BTA'dan damar bölütlemesi	64
Şekil 2.20. Bir BTA'da tersinir yöntem sonrasında son işleme aşaması: a) orijinal veri, b) tersinir yöntem ile kemik dokunun çıkarılması, c) damar bölütlemesi, d) son işleme aşaması ile bazı gürültülerin giderilmesi	65
Şekil 2.21. Bölütleme sonrası görüntüye uygulanan morfolojik işlemin sonucu.....	66
Şekil 2.22. Bölütleme sonrası bölütlü bölgelerin şekilsel bilgisinin elde edilmesi.....	68
Şekil 2.23. Bir BTA'da tersinir yöntem sonrası uygulanan son işleme aşamasının gösterimi: a) orijinal veri, b) tersinir yöntem ile kemik dokunun çıkarılması, c) damar bölütlemesi, d) morfolojik işlemin uygulanması, e) damarların orijinal görüntüde gösterimi.....	69
Şekil 2.24. Tersinir yöntem sonrası bazı görüntülerde oluşan gürültü ve kemik kalıntılarının gösterimi.....	70
Şekil 2.25. GSBGM'nin oluşturulmasında $d=1$ ve $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° için kullanılan pikseller.....	74
Şekil 2.26. n örnek ve d öznitelikten oluşan bir verinin temsili gösterimi.....	75
Şekil 2.27. TBA ile 10 öznitelik için optimum temel bileşen noktasının gösterimi	80
Şekil 2.28. Öznitelik seçimi süreci, b) Öznitelik seçme ve performans değerlendirme akış diyagramı	82
Şekil 2.29. Sınıflandırmada kullanılan YSA'nın yapısı.....	84
Şekil 2.30. Lineer ayrılabilirlik durumunda en uygun ayırıcı aşırı düzlem [128]	86
Şekil 2.31. Birbirinden doğrusal olarak ayrılamayan veriler [128,130].....	86

Şekil 2.32. k-en yakın sınıflandırma örneği [135]	89
Şekil 2.33. Bölgesel doku öznelikleri ile eğitimi tamamlanmış sınıflandırıcının test edilmesi: (a), (b), (c), bölgesel doku örnekleri ile özneliklerin çıkarılması, eğitim için etiketlenmesi (d), (e) girdi bir BTA'da sorgulanan bölgelerin sınıflandırıcı ile tanınması	90
Şekil 2.34. Bölge-tabanlı aktif kontur ve sınıflandırma ile karotid arter bölütlemesinde uygulanan yöntemin genel blok diyagramı	91
Şekil 2.35. Tersinir bölütleme ile damar bölütlemesi yapılmış bir görüntü üzerinde son işleme aşamasının uygulanması: (a) orijinal verinin ön-işlemden geçirilmesi, b) tersinir yöntem ile kemik dokunun çıkarılması, c) damar bölütlemesi, d) morfolojik işlemin uygulanması, e) sınıflandırıcı ile karotid damar ve karotid damar dışı gürültülerin birbirinden ayırt edilmesi f) sonuç damarların orijinal görüntüde gösterimi.....	94
Şekil 2.36. Tersinir bölütleme ile damar bölütlemesi yapılmış bir görüntü üzerinde son işleme aşamasının uygulanması: (a) orijinal verinin ön-işlemden geçirilmesi, b-c) tersinir yöntem ile kemik dokunun çıkarılması, d) damar bölütlemesi, e-f) morfolojik işlemin uygulanması ve sonrasında sınıflandırıcı ile karotid damar ve karotid damar dışı gürültülerin birbirinden ayırt edilmesi f) sonuç damarların orijinal görüntüde gösterimi	95
Şekil 2.37. Bölge-tabanlı aktif kontur ve sınıflandırma ile BTA görüntülerinden karotid arter bölütlemesi [139]	96
Şekil 2.38. Bir BTA diliminde damar bölütlemesinde gerçekleştirilen tüm işlemler: (a) orijinal verinin ön-işlemden geçirilmesi, b) tersinir yöntem ile kemik dokunun çıkarılması, c) damar bölütlemesi, d) morfolojik işlemin uygulanması, e) şekilsel bilginin elde edilmesi, f) sınıflandırıcı ile karotid damar ve karotid damar dışı gürültülerin birbirinden ayırt edilmesi g) damar merkezlerinden damar takibinin yapılması, h) sonuç damarların orijinal görüntüde gösterimi	97
Şekil 2.39. Bölütlü damar en kesitlerinden damar merkezleri ile süreklilik esaslı damar takibinin gösterimi	98
Şekil 2.40. Aort bölgesinden damar takibi başlangıç noktasının bir BTA tabakasındaki: a) aksenal, b) koronal ve c) sagittal görünümü	98
Şekil 2.41. 2B görüntü kümesini kullanarak 3B voksel tabanlı hacimsel veri oluşturma.....	99
Şekil 2.42. 3B yeniden yapılandırmanın a-) yumuşatma öncesi, b-) yumuşatma sonrası.....	102
Şekil 2.43. VTK ile görselleştirme ve ITK-SNAP ile bölütlü artelerin aksenal, koronal ve sagittal düzlemlerinin gösterilmesi	103

Şekil 3.1.	Yöntemimiz ile bölütlemiş görüntünün doğruluğunu karşılaştırmak için kullanılan alanlar [157]	107
Şekil 3.2.	Maksimum uzaklık farkı (Hausdorff uzaklığı) [158].....	110
Şekil 3.3.	Farklı sınıflandırıcıların geçerlilik ölçüleri grafiği	111
Şekil 3.4.	Damar bölütlemesinde BB ve RY yöntemlerinin bölütleme sonuçlarının kıyaslanması: a) orijinal BTA, b) yakınlaştırılmış görüntü, c-d) BB ve RY bölütleme sonucunun (mavi) ve manuel işaretleme (yeşil) gösterimi, e-f) BB ve RY bölütlemenin manuel olanla kıyaslanması yeşil: örtüşen (overlap), mavi:fazla (over), kırmızı: altında (under) bölütlemeyi gösterir	113
Şekil 3.5.	Görüntülerdeki örnek farklı damar noktaları ve bölütleme sonuçları.....	116
Şekil 3.6.	MICCAI'2009 ve Farabi verilerine ait damar bölütlemelerinin ekran görüntüleri	120
Şekil 3.7.	Kafatası bölgesindeki bir BTA görüntüsüne doku tabanlı bölge büyütme yönteminin tersinir yöntemle uyarlanması ile aşırı bölütlemenin azalma durumu: a) öncesi b) sonrası.....	121
Şekil 3.8.	Kafatası bölgesindeki bir BTA görüntüsüne doku tabanlı bölge büyütme yönteminin tersinir yöntemle uyarlanması ile aşırı bölütlemenin azalma durumu: a) öncesi b) sonrası.....	122
Şekil 3.9.	Kafatası tabanı ile Willis çemberi arasındaki Farabi verilerine ait damar bölütlemelerinin ekran görüntüleri.....	124
Ek Şekil 1.	Bir BTA'nın 150-155 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri.....	150
Ek Şekil 2.	Bir BTA'nın 156-161 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri.....	151
Ek Şekil 3.	Bir BTA'nın 169-173 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri.....	152
Ek Şekil 4.	Bir BTA'nın 174-178 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri.....	153
Ek Şekil 5.	Bir BTA'nın 190-194 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri.....	154
Ek Şekil 6.	Bir BTA'nın 195-199 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri.....	155

- Ek Şekil 7. Bir BTA'nın 157-165 arasındaki farklı dilimlerde tersinir yöntem sonrası gerçekleştirilen damar bölütleme görüntüleri 156
- Ek Şekil 8. Bir BTA'nın 197-202 arasındaki farklı dilimlerde tersinir yöntem sonrası gerçekleştirilen damar bölütleme görüntüleri 157



TABLULAR DİZİNİ

Sayfa No

Tablo 1.1. Farklı dokular için HU değerleri [8,9]	9
Tablo 2.1. Tohum seçimi için çoklu seviye eşikleme seviye grupları ve ortalama aralıkları ..	46
Tablo 2.2. Gri-seviye histogramın istatistiksel öznitelikleri	72
Tablo 2.3. GSBGM'den hesaplanan Haraclık öznitelikleri	74
Tablo 2.4. 10 tane öznitelik için en önemli temel bileşenleri sıralanması	80
Tablo 2.5. Genetik arama yöntemi ile sınıflandırma için seçilen öznitelikler	82
Tablo 3.1. MICCAI'2009 veri seti içeriği	104
Tablo 3.2. Farabi veri seti içeriği	105
Tablo 3.3. Damar için hata matrisi tanımı	106
Tablo 3.4. Farklı sınıflandırıcıların geçerlilik ölçü sonuçları	111
Tablo 3.5. Boyut indirgeme işlemi yapılmadan önce sınıflandırıcıların doğruluğu ve süreleri	112
Tablo 3.6. Boyut indirgeme işlemi sonrası sınıflandırıcıların doğruluğu ve süreleri	112
Tablo 3.7. Damar bölütlemeye BB ve RY yöntemlerinin başarı kıyaslaması	113
Tablo 3.8. Damar bölütlemeye, BB yönteminin 56 görüntü üzerinde başarı değerlendirilmesi	114
Tablo 3.9. Damar bölütlemeye, RY yönteminin 56 görüntü üzerinde başarı değerlendirilmesi	114
Tablo 3.10. Tersinir bölütleme ile kemik/damar bölütlemesine farklı yöntemlerin uygulanmasından elde edilen uzaklık-tabanlı başarı karşılaştırması	115
Tablo 3.11. Tersinir bölütlemenin uygulanması ile farklı damar noktalarındaki uzaklık ve alan tabanlı ortalama başarı sonuçları	115
Tablo 3.12. Farabi 15 BTA verisine uygulanan tersinir yöntemin performans değerlendirilmesi	117
Tablo 3.13. MICCAI'2009 veri seti için önerilen yöntemin mevcut çalışmalarla kıyaslanması	118

Tablo 3.14. Doku tabanlı bölge büyütme yönteminin tersinir yöneme uyarlanması ile MICCAI'2009 veri seti için performans değerlendirmesi	119
Tablo 3.15. Literatürde konu ile ilgili farklı BTA veritabanları ile yapılmış diğer çalışmalar ..	119
Tablo 3.16. Kafatası bölgesindeki bir BTA'daki aşırı bölütlemenin tersinir yöntemle azalmasının performans değerlendirmesi.....	121
Tablo 3.17. Kafatası bölgesindeki bir BTA'daki aşırı bölütlemenin tersinir yöntemle azalmasının performans değerlendirmesi.....	122
Tablo 3.18. Damar bölütlemeye, tersinir yöntemin uygulanması ile 80 görüntü (kafatası tabanı ile Willis çemberi arasında) üzerindeki başarı	123
Tablo 3.19. Damar bölütlemeye, doku tabanlı bölge büyütme yönteminin tersinir yöneme uyarlanması ile 80 görüntü (kafatası tabanı ile Willis çemberi arasında) üzerindeki başarı değerlendirmesi	123

SEMBOLLER DİZİNİ

BB	Bölge Büyütme
BDEB	Beklenen Değeri En Büyükleme
BT	Bilgisayarlı Tomografi
BTA	Bilgisayarlı Tomografi Anjiyografi
DAA	Doğrusal Ayırteden Analizi
DVM	Destek Vektör Makinesi
EKA	Eksternal Karotid Arter
GA	Genetik Algoritma
GSBGM	Gri Seviye Birlikte Görülme Matrisi
GSHM	Gri Seviye Histogram Momentleri
ITK	Insight Segmentation and Registration Toolkit
İKA	İnternal Karotid Arter
KÇBTA	Kemik Çıkarma Bilgisayarlı Tomografi Anjiyografisi
k-EYK	k-En Yakın Komşuluk
MR	Manyetik Rezonans
MRA	Manyetik Rezonans Anjiyografi
MRG	Manyetik Rezonans Görüntüleme
OKA	Ortak Karotid Arter
RY	Rassal Yürüyüş
TB	Temel Bileşen
TBA	Temel Bileşenler Analizi
VA	Vertebral Arter
VTK	Visualization Toolkit
YSA	Yapay Sinir Ağları
2B	İki Boyut
3B	Üç Boyut

1. GENEL BİLGİLER

1.1. Giriş

Damar hastalıkları ölüm vakalarının en önemli nedenlerinden olmasından ötürü, hastaların muayenesinde daha fazla bilgi edinilmesi hayati bir önem arz etmektedir. Bu bakımdan tıbbi görüntüleme bu tür damar hastalıklarının tanısında kullanılan önemli ve hızlı büyüyen bir tekniktir. İnsan boynunun her iki yanında bulunan, halk arasında ‘Şah damarı’ olarak bilinen karotid arterler, internal (iç) ve eksternal (dış) olarak iki ana dal ve sonrasında bunlara ait çeşitli dallanmalarla seyreder. Karotid arterlerin iç kısmında plak adı verilen yağ içeriği yüksek yapılanmanın gelişmesi sonucu damarlarda tıkanmalar ve daralmalar yaşanmaktadır. Hastalardan alınan görüntülerin incelenerek bu daralmaların ve tıkanıklıkların erken tespiti hastalığın tedavisinde hayati önem taşımaktadır. Damarlardaki bu bozulmaların tespit edilememesi, beyne giden kan akışının kesintiye uğramasına sebebiyet verebilmektedir. Beyne giden kan akışının birkaç dakikadan fazla kesintiye uğraması sonucu beyin hücreleri ölmeye başlar. Bu durumun uzun süre devam etmesi ileri safhalarda inme, beyin hasarı, felç, uzun dönemli sakatlık ve ölüme sonuçlanabilir.

Anjiyografi, lümenin yani kan damarlarının görselleştirilmesi işlemidir. Bu, bir kontrast maddenin hastaya intravenöz olarak enjekte edilmesiyle ve ardından bir bilgisayarlı tomografi taramasıyla yapılabilir. Bu sayede, doktorlara X-ray hacimsel verisi olarak sunulan vücudun bir görünümünün alınması sağlanmaktadır. Kontrast maddesi, damarların çevredeki yumuşak dokudan ayrılmasını sağlamak için kullanılır. Ancak, bu kaçınılmaz surette başka bir soruna yol açar. Kemik dokusunun yoğunluğu o kadar fazla değişmektedir ki, bazı kısımlar kan damarları ile örtüşecek parlaklık seviyesinde olacak ve dolayısıyla görselleştirme sırasında damarların ayırt edilmesi zorlaşacaktır. Bu, verileri görselleştirmeden önce bir kemik bölütlemesinin yapılması gerektiğinin anlamına gelir. Bu amaçla, görüntü işleme tekniklerini uygulamadan görüntülerde kemik kalmayacak şekilde damar görüntülemenin yolları vardır. Fakat bu yöntemler, vücudu daha yüksek dozda radyasyona maruz bırakır. Ayrıca zaman alıcı olabilir ve daha fazla maliyet gerektirebilir.

Damar değerlendirmesi yapılırken sıklıkla kemik doku ile karotid arterler birbirine karışmaktadır. Bu nedenle, damar yapısında bozulmaların olduğu potansiyel yerin devamında damar mı yoksa diğer yapılar mı olduğu yönünde şüpheler oluşmaktadır.

Kontrast madde yüklü damarları bölütleme çalışırken ana mesele, damarlar ve kemikler arasında gerçekleşen yoğunluk örtüşmesidir. Vücuttaki farklı iskelet parçalarının parlaklık seviyesi, büyük ölçüde değişkenlik gösterir. Bilgisayarlı Tomografi (BT) görüntülerinde kemik ve kıkırdak için HU değerleri yaklaşık 200'den 3000'e kadar uzanırken, kontrastlı kan damarları 100 ile 500 HU arasındadır. Bu, iki dokunun tek başına eşikleme teknikleriyle kolayca ayrılamayacağı anlamına gelmektedir. Damarlar görünür olduğunda, görüntüler iskelet (kemik) yapının en yumuşak bölümünü (yumuşak kemik veya kıkırdak dokular) de gösterecektir. Ayrıca, kemik ve damarlar arasındaki ince boşluk, bazı alanlarda işlemi daha da karmaşık hale getirmektedir. Örneğin, boyundan başa giden karotid damarlar karotid kanalı üzerinden temporal kemikten geçmektedir. Dolayısıyla bu gibi yerlerde milimetrik seviyelerde damarlar kemik ile çevrili şekildedir. Benzer şekilde omurganın arasından geçen ve beynin arka kısmını besleyen Vertebral arterlerde de benzer durum vardır, damar kısmen kemik ile kapatılmış durumdadır.

Bundan ötürü damarları görsel inceleme yaparken kemikleri tamamen kaldırabilmek son derece önemlidir. Bu şekilde, stenoz, plak veya anevrizmalar gibi patolojiler için semptomlar daha kolay tespit edilebilir. Kemik çıkarma bilgisayarlı tomografi anjiyografisi (KÇBTA) yönteminde olduğu gibi, vücudun iki farklı görüntüsünü alarak problemi çözmek mümkündür. Yalnızca tek bir tarama yapmakla karşılaştırıldığında, iki görüntü alınması gerektiği için hasta iki kat daha fazla radyasyona maruz kalacaktır. Dahası hastanın uzunca bir süre tamamen hareketsiz kalması uygun olmayabilir, rahatsız edici olabilir. Örneğin; bu yöntem Gratama van Andel ve diğerleri [1] tarafından kullanılmış ve daha sonra Morhard ve diğerleri [2] tarafından normal BTA ile karşılaştırılmıştır. Diğer bir yöntem ise van Straten ve diğerleri [3] tarafından sunulan ve tartışılan çift enerjili taramaların kullanılmasıdır. Manyetik rezonans görüntüleme (MRI), çok fazla görüntü işleme olmadan damarların iyi bir şekilde gösterilmesini sağlar. Ancak, günümüzün bilgisayar gücü ile çeşitli nedenlerden dolayı bu problemin yazılım odaklı çözümü mümkündür. Günümüzde otomatik bilgisayar destekli karotid bölütleme işlemi gerçekleştirilmek için güçlü ve giderek artan bir talep vardır. Bu destek, az radyasyon kullanmanın ve taşımının çok uzun sürmemesi konusunda taraflara iyi bir uzlaşma sağlar. KÇBTA veya çift enerji teknikleri kullanılmadan, vücudun maruz kaldığı radyasyon miktarının azaltılması bu konunun ana motivasyonudur.

1.2. Tezin Amacı ve Yapısı

Çalışmanın amacı, tek bir BT taramasından daha fazlasının olmaması için doktorlar tarafından kullanılacak kadar iyi, otomatik karotid arter bölütlemesini görüntü işleme teknikleriyle yapabileceği bir yöntem geliştirmektir. Bilgisayarlı Tomografi Anjiyografi görüntülerinden karotid arter bölütlemelerinin yapılarak hastalığın teşhisi konusunda bir karar destek sistemi oluşturmaktır.

Bu çalışmada, tersinir yöntemle tek bir seferde BTA görüntülerinden kemik ve kıkırdak dokuların ayrıştırılması sonrasında bölütlenen karotid arterlerin sonuçlarının üç boyutlu olarak görselleştirilmesi amaçlanmaktadır.

Damar yapılarında bozulmaların olduğu yerlerin tespitinde ya da damar yapılarının kemik doku ile yakın komşuluk gösterdiği yerlerde, doktorun karar verme sürecindeki şüphelerin tersinir yöntemle karotid arter yapılarının üç boyutlu olarak görselleştirilmesi ile giderilmesi hedeflenmektedir.

Tezin birinci bölümünde, Bilgisayarlı Tomografi sisteminden ve BTA'da görüntü oluşturma prensibinden bahsedilmiştir. Kemik çıkarımında kullanılan, kemik çıkarma bilgisayarlı tomografi anjiyografisinden ve BTA'ya alternatif diğer görüntüleme MRI tekniği ile karşılaştırması yapılmıştır. Buna ilaveten birinci bölümde; karotid arterlerin anatomisinden, yaygın damar hastalıklarından ve literatürdeki otomatik ve yarı-otomatik kan damarları bölütleme yöntemleri kategorilere ayrılarak anlatılmıştır.

Tezin ikinci bölümünde, yöntemle yönelik çalışmalardan bahsedilmiştir. Tersinir yaklaşım ile yeni bir otomatik bölütleme yöntemi geliştirilmiştir. Tersinir yöntem yaklaşımıyla öncelikle kemik bölgesi bölütlenmiş ve çıkarılmıştır, daha sonra damarlar bölütlenmiştir. Bölütleme yöntemi, öncesi ön işleme ve sonrası son işleme adımlarıyla daha kararlı hale getirilmiştir. Yöntemin uygulanması için verinin temin edilmesi ve eğitilmesi yapılmış, ayrıca literatürde kabul görmüş bir veri seti üzerinde de yöntem uygulanmıştır.

Tezin üçüncü bölümünde, tersinir yöntem ile otomatik bölütlemeden elde edilen sonuçların, karşılaştırması yapılacak veri setlerindeki manuel bölütlemeler ile kıyaslanması ve değerlendirilmesi yapılmıştır.

Son olarak, tezin dördüncü ve beşinci bölümlerinde bu çalışmanın sonuçlarından ve tartışmalardan, son bölümde ise çalışma ile ilgili önerilerden bahsedilmiştir.

1.3. Bilgisayarlı Tomografi

Tomografi sözcüğü, “Tomos” Yunanca da kesit ve “Graphia” görüntü kelimelerinden türetilmiştir. Cormack tarafından 1963 yılında teorik edildikten sonra Godfrey N.Hounsfield tarafından 1967’de ilk başarılı klinik çekimi yapılan bu yöntem, ülkemizde ilk defa 1976’da Hacettepe Üniversitesi Tıp Fakültesinde kullanılmıştır.

Bilgisayarlı Tomografi (BT), bilgisayar teknolojisinin X-ışını ile birleşmesinin bir ürünüdür. BT, radyoloji alanında vücudun herhangi bir bölgesini incelemek üzere X-ışınları kullanılarak görüntü elde edilen bir teşhis yöntemidir. İstenilen bölgenin taranması ile vücut kesitler şeklinde görüntülenir. Bir kesit düzlemindeki her bir noktanın X-ışınını zayıflatma değerinin bilinmesiyle sayısal BT kesiti oluşturulur. Bir kesit düzlemin etrafındaki her yönünden X-ışını geçirilmesi ile elde edilen çok sayıdaki ölçüm değerinin bilgisayarla işlenmesi ile sayısallaştırılmaktadır. Kesit görüntülere, her bir sayısal değerlerin karşılığı olan gri tonlara boyama ile ulaşılmaktadır.

BT görüntüleri, vücudun ince dilimini görüntülenmesi ve dokuların X-ışının tutma oranlarının doğrudan ölçülebilmesinden ötürü röntgenden daha ayrıntılıdır. BT görüntüleri, doğrudan dokunun X-ışınlarını zayıflatma değerlerinden oluşmasından dolayı, doku kontrastını çok daha duyarlı yansıtmaktadır. Bu yöntemde kullanılan enerji X-ışını olduğu için, röntgende olduğu gibi görüntülerdeki açık gri tonlar, koyu tonlara göre X-ışınlarının daha fazla tutulduğu bölgeleri temsil etmektedir.

1.3.1. BT Aygıtı


Bir BT aygıtı, tarama (scanning) bölümü, bilgisayar sistemi ve görüntüleme bölümü olmak üzere üç temel bölümden oluşmaktadır.

1. Tarama bölümü: Bu bölüm hasta masası ve gantriden oluşmaktadır. Gantri, içerisinde detektörler, detektör elektroniği ve X-ışını tüpünün bulunduğu eni dar kare şeklinde bir kutudur. Bu kutu ortasında, hastanın girdiği yuvarlak açıklığa gantri açıklığı denir. Bu açıklığın çevresinde tüp ve dedektör zinciri bulunmaktadır. Kesit alma sırasında bu tüp hastanın çevresinde dönmektedir. Kesitler arasında istenilen aralık ve seçilen kesit

kalınlığına göre, hasta masası her kesitten sonra hareket eder. X-ışınları hasta dokularını geçerek dedektörler üzerine düşer, burada X-ışınlarının miktarı ölçülerek sayısallaştırılır.

2. Bilgisayar sistemi: Bu bölüm detektörlerden gelen dijital verileri işleyen hesaplama gücü yüksek sistemlerden oluşur. Bu bölümde, dijital veriler kesiti oluşturacak voksellerin değerlerine dönüştürülmektedir.

3. Görüntüleme bölümü: Bu bölümde sistemin kumanda konsolu bulunmaktadır. Bu komuta ünitesinde bir kayıt sistemi ve yüksek çözünürlüklü bir monitör bulunur. Bu bölümde, sayısal değerlerden oluşan görüntüler ortaya çıkar ve görüntüler işlenir. Bu görüntüler içerisinden seçilenler film üzerine geçirilir.




Şekil 1.1. BT aygıtı [4]

Modern aygıtların günümüzde çok hızlı bir şekilde tarama yapabilmesi, vücudu kesit kesit değil, bir blok halinde taramasından ötürüdür. Helikal (spiral) BT ve Çok kesitli BT olmak üzere iki tip BT taraması mevcuttur. Helikal (spiral) BT 'de hasta masası devamlı kayar bu arada ise tüp inceleme esnasında sürekli döner. Bir nefes tutma süresinde, bir defada


40-80 cm'lik bir alanın taranabildiği söylenebilir. Helikal teknolojisine ilaveten geliştirilen çok kesitli BT'de ise tek detektör halkası kullanmak yerine, yan yana sıralanan detektör halkaları ile bir detektör bloku kullanılmaktadır. Halka sayısı bu detektör bloklarında 64-128'e kadar çıkabilir. Bu sayede aygıtın taradığı hacim artar.

Görüntü kalitesi BT sayesinde en üst seviyeye ulaşabilmiştir. Günümüzde geliştirilen yeni yöntemler hızlanmaya yoğunlaşmaktadır. Hızlanmayı, vücudu blok olarak taradıkları için, kesit kesit tarama yapan alışlagelmiş BT'ye göre inceleme süresini çok kısaltarak yapabilmişlerdir. Bu hızlanma, hareketin istenmeyen etkilerini de ortadan kaldırır.

İstenilen bölgenin incelenmesinde kişiye kontrast madde verildiğinden, inceleme süresinin kısalması ile kullanılan kontrast miktarının azaltılması yönünde yararlı bir etki oluşturmaktadır. Buna ilaveten, blok görüntüleme yapıldığından daha sonra elde edilecek iki veya üç boyutlu rekonstrüksiyon görüntülerinin kalitesi daha yüksek olabilmektedir.



Şekil 1.2. Helikal (Spiral) BT tarama prensibi [4]



Şekil 1.3. Çok kesitli BT tarama prensibi [5, 6]


1.3.2. Görüntü Oluşumu

Bir BT görüntüsü kesitlerden oluşmuştur. Bir kesit görüntü oluşumunda yapılan işlemler sırasıyla aşağıdaki gibi özetlenebilir.

- Öncelikle, dar bir X-ışını demeti, X-ışını tüpünün kesit düzlem etrafında 360 derece dönerek gönderilmesiyle başlanır.
- Vücuda gönderilmeden önce X-ışını ölçülür, vücutta dokuyu geçtikten sonra tekrar bir ölçüm yapılmaktadır. Detektörlerin karşısına gelen dokunun ne oranda X-ışınını

tuttuğu aradaki farkın hesaplanması ile belirlenmektedir. Güçlü bilgisayar işlemleriyle, bu çok sayıdaki ölçümden görüntü oluşturulur.


- BT’de de bütün dijital görüntülerde olduğu gibi, görüntü piksel adı verilen küçük resim elementlerinden oluşur. Görüntünün iki kenarındaki piksel sayısının çarpımına tekabül eden görüntü matrisi boyutu, genellikle 512x512 boyutundadır.
- BT görüntülerinde uzman tarafından belirlenen bir görüntü kalınlığı vardır. Dolayısıyla, BT görüntüleri iki boyutlu değildir. Üçüncü boyutta bir görüntü yüksekliği vardır. Görüntü, tabanı piksel olan ve yüksekliği kesit yüksekliği olan bir dikdörtgenler prizmasından oluşur. Bu prizmalara, hacim (volüm) elementi eş anlamına gelen voksel adı verilir. BT’de ölçümler hacimsel yapıdan ötürü, piksel üzerinden değil voksel üzerinden yapılır. Örneğin, bir BT aygıtının 512x512 görüntü matrisinin olduğunu düşünülürse ve uzmanın kesit kalınlığını $5mm$ aldığı varsayılırsa, $25cm$ ’lik D görüntü çapına sahip bir görüntünün piksel boyutu yaklaşık olarak $0.5x0.5mm^2$ ve voksel hacmi ise $0.5x0.5x5mm^3$ olacaktır. Modern aygıtlarda kesit (slice) kalınlıkları $0.5mm$ ye kadar düşürüldüğünde, vokseller küp halini almaktadır.



Şekil 1.4. R: görüntü alanının çapı, piksel (axb) ve voksel ($axbxd$) [4]

- Dedektörler aracılığıyla elde edilen dijital veriler güçlü bilgisayar işlemleri ile vokselin X-ışını tutma değeri sayısal verisine dönüştürülür. Bu dönüşüm, bir ucu +3095, diğer ucu -1000 olan ve referans noktası suyun X-ışınına sıfır kabul eden cetvele göre yapılmaktadır. Bu yöntemi geliştiren İngiliz fizikçinin adından ötürü bu cetvele, Hounsfield cetveli ya da Hounsfield ölçeği adı

verilmektedir. Bu cetvele göre, sistem bilgisayarı tüm voksellere bir sayı vermektedir. Bu sayı, yoğunluğu sudan düşük olanlara eksi, yüksek olanlara artı değerdedir. Görüntü oluşumunda Hounsfield cetveline göre, voksellerin sayısal değerlerini baz alarak bu değerlere denk gelen siyah, beyaz ve gri tonlara boyama yapılmaktadır. Bunun için gri skala denilen eksi ucu siyah, artı ucu beyaz olan gri bir cetvel kullanılır. Bir vokselin içine girebilen tüm dokuların ortalama değeri vokselin sayısal değerini oluşturur. Bir BT görüntüsüne bakıldığında görülen piksel rengi, ilgili vokselin ortalama değeri olmaktadır.



Şekil 1.5. Hounsfield ölçeği [7]

Tablo 1.1. Farklı dokular için HU değerleri [8, 9]

Doku	HU
Kemik	200 - 3000
Damar (kontrast madde ile)	100 - 500
Karaciğer	40 - 60
Damar (kontrast maddesiz)	40
Gri cevher	37 - 45
Beyaz cevher	20 - 30
Kas	10 - 40
Böbrek	30
Omurilik sıvısı	15
Su	0
Yağ	-50 - (-100)
Hava	-1000

- $HU = 1000 \times (\mu - \mu_{water}) / \mu_{water}$ şeklinde hesaplanır, burada μ , belirli bir voksel'deki doğrusal sönümlenme katsayısını ve μ_{water} , su için doğrusal sönümlenme katsayısını temsil eder. Farklı dokular için yaklaşık HU değerleri Tablo 1.1'deki gibidir.

1.3.3. Bilgisayarlı Tomografi Anjiyografi

Bilgisayarlı Tomografi Anjiyografi (BTA) görüntüsü, kan damarlarının daha iyi teşhisini sağlamak için ilave bir ön adım olan kontrast maddesinin eklenmesiyle yukarıda tarif edildiği gibi standart bir BT tarayıcısı ile elde edilir. BTA gibi kontrastlı BT görüntüleri belirli organların ve dokuların daha iyi bir ayırım yapılmasına ve vurgulamasına imkan verir. Kontrast madde ağızdan alınabildiği gibi enjeksiyon yolu ile de verilebilir. Bilgisayarlı Tomografi Anjiyografi (BTA), Manyetik Rezonans Anjiyografi (MRA)'nin yanında tanı radyolojisi alanındaki en önemli teknolojilerden biridir. Bu iki teknik, özellikle boyun ve kafa bölgesindeki arterlerin görüntülenmesinde son zamanlardaki BTA'daki ilerlemelerle çoğu vasküler teşhis işlemlerinde yaygın olarak kullanılmaktadır.

BTA hızlı ve güçlü bir teknolojidir. Yüksek çözünürlüklü 3 boyutlu görüntülerin elde edilmesiyle, hem vasküler lümeni hem de damar duvarını çevreleyen yapıların değerlendirilmesine imkân verir. BTA, hem kan damarlarının hem de dokuların detaylı görüntülerini üretmek için bir BT tarayıcı kullanan, minimal invaziv bir tıbbi testtir. İyot açısından zengin kontrast malzeme genellikle kolun damarına yerleştirilen küçük bir kateterden enjekte edilir. Ardından, kontrast vücuttaki çeşitli organlara kan damarları aracılığıyla iletilirken bir BT taraması gerçekleştirilir. Normal x-ışını görüntüleme (örneğin röntgen) kullanımından farkı, vücudun farklı yönlerden taranmasıdır. Bunu yapmanın avantajı, taranan alanın 3B gösterimini oluşturma imkânı sağlamasıdır. Bu veriler, herhangi bir vücut dokusu türünü iyi görüntülemek için yazılımsal işlenebilir.

Kemikler ve kırık gibi diğer sert dokulardan X-ışınının geçme zorluğundan ötürü, BT taramaları bu dokular için iyi tanımlanmış görüntüler verebilir. Kaslar veya beyin gibi daha yumuşak dokular, Manyetik Rezonans (MR) görüntüleme ile daha net görülür.

1.3.4. Kemik Çıkarma Bilgisayarlı Tomografi Anjiyografisi

Kemik çıkarma bilgisayarlı tomografi anjiyografisi (KÇBTA), görselleştirme sırasında çok fazla görüntü işleme gerektirmeden kemiğin çıkarılmasına olanak tanır. Hasta aynı pozisyonda iki kez taranır: bir kez normal şartlarda ve bir kez de vasküler sisteme kontrast madde enjekte edilerek yapılır. Böylece damarlar, eşleştirmeden (registration) sonra, ilk görüntüyü ikinciden çıkararak ayrı ayrı görselleştirilebilir. Ancak bunu yapmanın bazı dezavantajları vardır. Yalnızca tek bir tarama yapmakla karşılaştırıldığında, iki görüntü alınması gerektiği için hasta iki kat daha fazla radyasyona maruz kalacaktır. Dahası, hastanın uzunca bir süre tamamen hareketsiz kalması uygun olmayabilir, rahatsız edici olabilir.

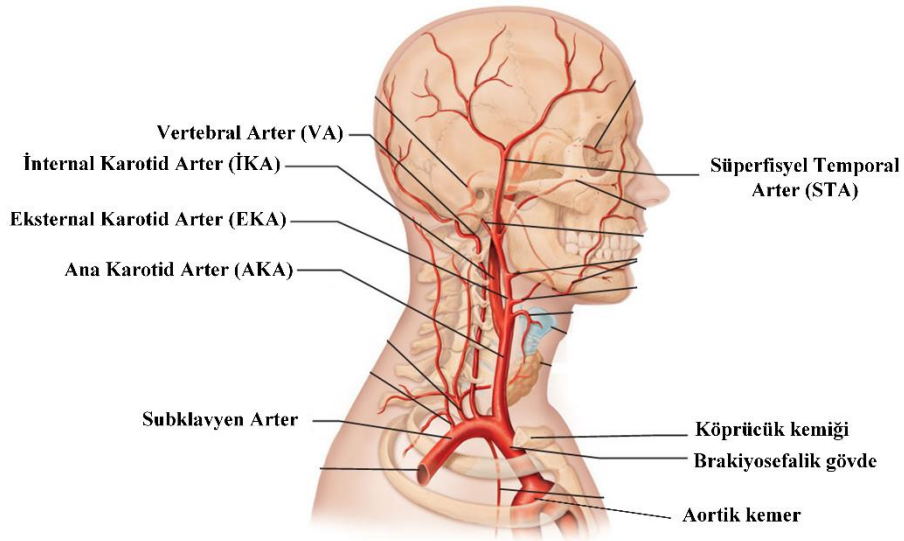
1.3.5. Manyetik Rezonans Anjiyografi ile BTA'nın Karşılaştırılması

Manyetik rezonans görüntüleme, vücudun üç boyutlu gösterimini oluşturmak için yeni bir yoldur. Vücut taraması için X-ışını kullanmak yerine, hidrojen atomlarını belirli bir şekilde yönlendirmek için çok güçlü manyetik alanlar kullanılır. Manyetik alan salındığında, atomlar orijinal yönlerine dönecek ve böylece enerji kaybedilecektir. Enerji radyo dalgalarına dönüştürülür. Bu radyo dalgaları toplanabilir ve bir görüntüye dönüştürülebilir. Bu nedenle, MRI yöntemi bugün bildiğimiz kadarıyla canlı dokulara zararsızdır.

Bu tezde yalnızca BT taramalarından gelen görüntüler işlediğinden, bu aşamadan sonra MR daha fazla açıklanmayacaktır. Ancak, MRA'nın BTA yerine neden her zaman kullanılmadığından bahsetmek önemlidir. Her şeyden önce, MRI tarayıcıları nispeten yeni olduğundan, genellikle BT tarayıcılarından daha pahalıdır. Ayrıca, BT tarayıcıları kadar iyi çözünürlükte sonuçlar üretmemektedirler. BT ile kesit alınan bir bölgedeki her yapı görüntülenebilmektedir. Bu, BT'ye önemli bir üstünlük sağlar. Bir BT taraması saniyelerde (~30-60 sn) yapılabilirken, bir MR taraması dakikalar (~20-40 dk) sürebilir. Bu uzun zaman zarfında hastanın tamamen sakin ve sürekli yatar pozisyonda olmasını beklemek herkes için uygun olmayabilir. Örneğin, bazı hastaların ileri seviye destek almaları gerektiği durumlarda, iletişim kurulamayan ve sürekli solunum destek ünitesine bağlı olan hastaları MR ile incelemek çok zordur. Son olarak, BT ve MR birbirinden çok farklı görüntüler üretir. BT görüntüleri, kemik gibi yoğun dokuların görüntülenmesinde daha kullanışlıdır. Beyin gibi daha yumuşak dokuların görüntülenmesinde ise MR daha uygundur.

1.4. Karotid Arterlerin Anatomisi

Karotid arterler, boyun, beyin ve yüz gibi vücudun üst kısmına oksijen sağlanmasında insan vücudunda ana rol oynamaktadırlar. Kan akışı, vücudun ana arteri olan kemere benzer şekildeki damar Aort yoluyla kalpten başlar. Ardından yol boyunca dallanma ile yukarıya doğru devam eder. Aortik kemer, sol subklavyen, sol ana karotid ve brakioyosefalik gövdenin kökeni olup, sağ ana karotid ve sağ subklavyenin hepsinde ortaya çıkar. Subklavyenler, omuz bölgesine kan sağlayan arterlerdir. Ana Karotidler Arter (AKA) kanı yukarı doğru taşır ve yaklaşık olarak dördüncü servikal vertebra seviyesinde, İnternal Karotid Arter (İKA)'e ve Eksternal Karotid Arter (EKA)'e çatallaşma (bifurkasyon) yapar. Her iki dal da yukarıya doğru ilerlerken, internal karotid daha derin (daha içsel) bir yol izler ve sonunda karotid kanalı yoluyla beynin ön kısmını beslemek için kafatasına gider. Eksternal karotid arter (EKA) yüzeye daha yakın seyreder, boynu ve yüzü besleyen çok sayıda dalı gönderir. Ayrıca, Vertebral Arterler (VA) adında iki küçük arter vardır, bunlar omurganın arasından geçen ve beynin arka kısmını besleyen arterlerdir.



Şekil 1.6. Karotid arterlerin anatomisi [10]

Boyun, karotid damarları da dahil olmak üzere vücudun en önemli kan damarlarını içerir. Görevleri ise baş kısmının çoğu bölümünü kanla beslemektir. Ana karotid damar, karotid bifurkasyon denilen bir noktada internal ve eksternal karotid damarlara ayrılır. Bu bölüm özellikle stenoza (damar darlığı) maruz kalır ve beyne giden kan akışının azalmasına sebebiyet verir. Internal karotid damar, beyne doğru içeri giren damardır. Bu damar aslında, karotis kanalı aracılığıyla temporal kemikten ilerleyerek geçer, dolayısıyla bu zorlu bölge bölütleme sırasında bu damarı kritik bir bölüm haline getirir. Son olarak karotid damarlar, Willis Dairesine bağlanır. Çoğu farklı kan damarları serebral alanlara gönderilmeden önce buradan geçer. Eksternal karotid damar çoğunlukla kafatasının yanı sıra, yüz organlarına kan tedarik eder. Boyun bölgesindeki karotid arterler nispeten kemikten rahatlıkla ayırt edilebilir. Vertebral arterler ise omurga boyunca kısmen kemikle kapatılmış olduğundan damarın kemikten ayırt edilmesi daha zor bir işlemdir.

1.4.1. Yaygın Hastalıklar

Aşağıdaki bölüm, en yaygın damar sorunlarından bazılarını açıklamaktadır. Anjiyografi yaptırmak için bunların hepsi birer sebeptir.

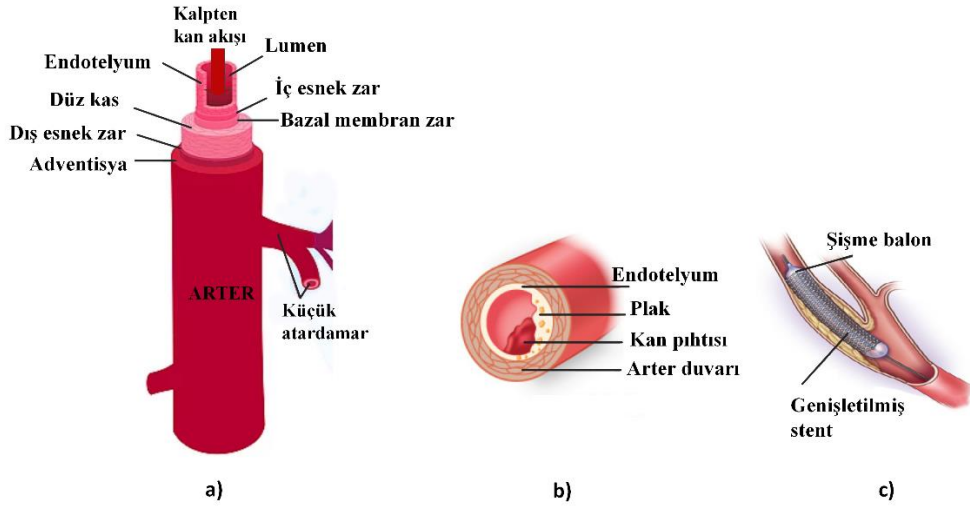
1.4.1.1. Arter Darlığı (Stenosis)

Stenoz, kan damarları ve solunum parçaları gibi boru organlarının daralmasıyla, etkinliğinin azalmasına veya işlev kaybının tamamen kaybolmasına neden olur. Arteryel stenoz, damarların iç duvarlarındaki plak oluşumundan kaynaklanır. Bu karotis damarlarda olduğunda, kan akışının büyük bölümleri tıkalı olabilir. Stenoz ciddi bir aşamaya gelene ve geçici bir iskemik atak (küçük inme) yaratan bir pıhtı oluşana kadar belirtiler nadiren fark edilir. Stenoz, bir kan damarının gerçek lümenini daralttığından, tıbbi görüntüleme ile örneğin bir BT anjiyografi yaparak tespit edilebilir.

Kalbe kan temin eden arterler gibi (koroner arterler) karotid arterlerde de, damarların iç tarafında plak olarak adlandırılan yağ ve kolesterol birikimlerinin oluşturduğu ateroskleroz gelişebilir. Zamanla karotid stenoz ortaya çıkabilir. Plak arteri daraltır, beyindeki kan akışını düşürür ve beyin hücreleri oksijen ve glikozdan yoksun olduğunda inmeye neden olabilir. Stenosis aşağıdaki durumlarda şu senaryolara neden olabilir: Arter aşırı derecede daralır, bir

parça plak kopar ve beynin küçük arterlerine veya kan pıhtısı oluşur ve daralmış bir arteri bloke eder.

Risk faktörleri; kalıtım, yaş, sigara içme, yüksek tansiyon, şeker hastalığı veya yüksek kötü kolesterol seviyesidir. Karotid arter hastalığının ön belirtileri olmayabileceğinden, risk altındaki kişilerin doktorları tarafından periyodik olarak muayene edilmesi önerilir. En yaygın tanı yöntemi karotid arteriyogramdır. En ciddi tedavi türü ameliyattır (karotid endarterektomi olarak adlandırılır), ancak genellikle tıp bilimi cerrahiden kaçınmayı ve bu durumda stent yapma gibi minimal invaziv tedavileri kullanmayı tercih etmektedir. Stent hem atardamarın geniş açılmasını, hem de plak parçalarının beyne gitmesini (küçük iğneler kullanarak) tutarak inmeyi engeller.



Şekil 1.7. Damar anatomisi, (a) Atardamar (Arter) yapısı, (b) Arter darlığı, (c) Stent takılan arter damar [8, 11]

1.4.1.2. Anevrizma (Aneurysm)

Anevrizma, kan damarı duvarlarının zayıflamasından kaynaklanır ve yan tarafında balon benzeri bir şekil olarak görülür. Anevrizma, yırtıldığı ve kanamaya neden olduğu bir orana kadar büyüyebilir. Bu, anevrizmaların sıklıkla görüldüğü serebral alanda meydana gelirse, sonuçları şiddetli olabilir. Anjiyografide daha büyük anevrizmalar kolayca tespit edilebilir.

1.4.1.3. İnme (Stroke)

İNme, ya bir kan damarının tıkanması ya da kanamadan kaynaklanır. İnme bir hastalığa kıyasla kritik bir durumdur, beyne giden kan akışı kesildiğinde ortaya çıkar. Daha küçük inmeler geçici olabilir ve birkaç dakika içinde kaybolur, diğerleri tıbbi tedavi yapılmazsa kalıcı olabilir. Bu durum beyne büyük zarar verebilir veya en kötü ihtimalle ölüme sonuçlanabilir.

1.5. Literatür Çalışması

Bu bölümde, damar bölütlemesinde kullanılan farklı yaklaşımlar sunulmaktadır. Bu tez kapsamında ilgi alanı karotid damarların segmentasyonuna odaklanmıştır, ancak alıntılanan eserler sadece bu alanla sınırlı değildir. Bilim insanları, insan vücudunun farklı vasküler ağlarının (örneğin; kardiyak, retinal, akciğer, karaciğer veya göze ait) bölütlemesinde de, çok benzer problemler ile karşı karşıya kalmaktadır. Damar bölütlemesi ile ilgili literatürdeki mevcut çalışmalar, aşağıdaki bölütleme yaklaşımlarını esas alarak 7 kategoride sınıflandırılmıştır; 1) eşikleme, 2) istatistiksel model analizi, 3) deforme edilebilir modeller, 4) örüntü tanıma, 5) bölge büyütme, 6) matematiksel morfoloji ve 7) damar özneliğine dayalı modeller.

Kirbas [12], mevcut algoritmaları ve teknikleri altı kategoriye ayırarak irdelemektedir.

1. Örüntü tanıma teknikleri
2. Model tabanlı yaklaşımlar
3. Takip tabanlı yaklaşımlar
4. Yapay zeka
5. Yapay sinir ağları
6. Boru (tüp) benzeri nesnelere belirlenmesi

Lesage ve diğerleri [13], anjiyografik görüntülerin bölütlemesini üç yönde tartışmışlardır:

1. Kullanılan damar modelleri

2. Varolan damara özgü öznelilikler
3. Çıkarım şemaları

Bazı derlemeler belirli bir uygulama veya yöntem için çalışmaları incelerken, yukarıdaki her iki çalışmada yazarlar belirli bir uygulama (serebral, retinal, kalp, akciğer vb.) ve yöntem (DÇA, MRA, BTA, MYP, 2B veya 3B vb.) bakılmaksızın bölütleme yöntemlerine odaklandılar. Örneğin, Suri ve diğerleri [14], MRA görüntüleri üzerine ön filtreleme teknikleri ve bölütleme algoritmalarına odaklandılar. Felkel ve diğerleri [15], BTA veri setlerinde damarların bölütlenmesi ve damar takip algoritmaları üzerine araştırmalar yaptılar. Koroner ve retinal damarlar için bölütleme yönteminin bir incelemesi [16] ve [17] 'da ayrı ayrı sunulmuştur.

Bu bölümde, bu tez ile alakalı Kirbas [12] ve Lesage ve diğerleri [13] tarafından verilen iki inceleme birleştirilmiştir. Ayrıca, son zamanlardaki üç boyutlu damar bölütleme çalışmalarına ve özellikle üç boyutlu BTA bölütlemelerine önem verilmiştir.

1.5.1. Eşikleme

Eşikleme, görüntüyü yoğunluk değerlerine göre bölümlenmek için kullanılan bir tekniktir. Bu bölümlenme yapmak için en kolay yollardan biridir. Çoğu zaman, sonuç ikili bir maskedir. Eşiğin altındaki tüm değerler sıfıra ayarlanır ve eşik değerden büyük olanlar bir ayarlanır. İki eşik kullanılıyorsa, bir değer genellikle iki eşikte yer alan yoğunluklara ve geri kalanına sıfır atanır. Rastgele sayıda eşiğin kullanılması mümkün olsa da, sonuç bir maskeden farklı bir şekilde ele alınmasını gerektirdiğinden, yararlı değildir.

Eşikleme, bölütleme için kullanılan piksel tabanlı bir yöntemdir. Mevcut pikselin etrafındakileri göz ardı ederek oluşur. Doku türü için piksel yoğunluklarının ataması iyi bilinir ve sabit ise, statik eşikleme uygulanabilir.

Global uyarlanabilir eşikler, yalnızca belirli bir eşiği seçmek için her görüntüyü tamamen analiz ederek sonuçlanır. Belirli bir görüntü için hangi eşik değerlerinin kullanılacağına karar vermenin otomatik yolları vardır. Otomatik uyarlamalı eşikleme algoritmaları ilkesi [18] çalışmasında, altı yaklaşımdan; isodata, Otsu, minimum hata, pun, moment koruma ve fuzzy'den bahsedilmiştir. En iyi bilinen Otsu metodu, ortaya çıkan iki sınıftan sınıf-için varyansı en aza indirerek, histogramdan optimal eşiği belirler. Zhao ve

diğerleri [19], BTA'dan kemik çıkarma işlemi için eşikleri otomatik olarak bulmak için bir yöntem önermektedirler. Bununla birlikte yaklaşım, damara verilmiş kontrastlı ve kontrastsız iki resme sahip oldukları gerçeğine dayanmaktadır. Eşikleme hızlı ve kullanımı kolay olsa da, yöntemin bazı sınırlamaları vardır. Bazen bir eşik değeri resmin bir kısmı için iyi çalışır, ancak geri kalanı için yetersiz olabilir. BTA görüntülerinde problem, farklı doku tiplerinin çok benzer olabilmesinden kaynaklanmaktadır. Bu nedenle, istenen bölütlemenin çok fazla veya çok azını içermeyen bir tek eşik değerine karar vermek zordur. Kemik ve damarları arasındaki yoğunluk çakışması bir karışıklık ile sonuçlanır.

Serebral anjiyografik görüntülerde vasküler yapı oranı, toplam hacmin yaklaşık %1 seviyesindedir ve bu da diğer anatomik yapıların çok altındadır [20]. Damar nesnelere ve arka plan arasındaki görüntü kontrastı oldukça dengesizdir. Görüntü histogramında, nesne tepesi ve arka plan tepesi arasındaki vadi, derin ve açık değildir. Bu nedenle, Otsu yöntemi doğrudan uygulandığında optimal eşik tam olmayabilir. Bu problemi gidermek için Zhang ve diğerleri [21], MRA görüntüsünü alt bloklara ayırmayı ve damarları çıkarmak için Otsu algoritması ile yerel eşikler belirlemeyi önerdiler.

Park ve diğerleri [22], üç boyutlu MRA görüntülerinde karotid arterini bölütlemek için bağlantı temelli bilgilerle yerel uyarlamalı eşik değerlerini kullanmışlardır. Her dilim için yerel bir eşik değeri, bir sonraki dilimin yeni ilgi alanı olan ilgi alanı histogramından hesaplanmıştır.

Wang ve diğerleri [23], yakın zamanlı çalışmalarında beyin MRA görüntülerinden serebral damarların otomatik çıkarımı ve hacimsel ölçümü için bir eşik bölütleme algoritması sunmuşlardır. Bu algorithmada, Gauss ve tek yönlü normal dağılımlar karşılaştırarak uygun global eşik değeri belirlenmiştir. Serebral damarları çıkarmak için, iki istatistiksel dağılımın olasılık yoğunluk fonksiyonunu karşılaştırarak bir eşik değeri belirlemektedirler.

Literatürdeki bazı çalışmalarda, global veya yerel eşikleme ile voksellerin gradyanını karşılaştıran gradyan tabanlı algoritmalar geliştirilmiştir. Wilkinson ve diğerleri [24], yerel uyarlanabilir eşikleme için Gürbüz Otomatik Eşik Seçimi (Robust Automatic Threshold Selection- RAST) algoritmasına dayanan yeni çok ölçekli hareketli pencere yöntemi geliştirdi [25]. RAST algoritmasının temel sınırlamaları, bölütleme sonucunu güçlü bir şekilde etkileyen parametre seçimi ve optimizasyonudur [26].

1.5.2. İstatistiksel Model Analizi

İstatistiksel modellerle damar bölütlemesi genellikle yoğunluk dağılımının analizine dayanır. Genellikle bir görüntünün yoğunluk dağılımının, her bir anatomik yapının kesin bir model ile yakınlştırılabildiği, istatistiksel model dağılımlarının sonlu bir karışımı olduğu varsayılır. Analizleri kolaylaştırmak için, görüntüdeki doku familyasının sayısı belirlenmelidir. Dağılım sayıları tamamlandıktan sonra, Beklenti Maksimizasyonunu (Expectation Maximization-EM) uygulamak ve böylece bir iterasyon prosedürü ile dağıtımın bilinmeyen parametrelerini (ağırlık, ortalama ve standart sapma) tahmin etmek mümkündür. Son olarak, sınıflandırma kurallarına göre bölütleme gerçekleştirmek için global bir eşik değeri seçilir. Görüntü elde edilmesi ve yöntemindeki değişiklikten ötürü, karışım dağılımı modellerinin serebral damar görüntülerde kullanılması zordur. Serebral damar dağılımlarını sunmak için bazı karışım dağılım modelleri önerilmiştir. Gan ve diğerleri [20], üç boyutlu anjiyografi görüntülerinden Gauss dağılımlarının sonlu karışım modelini önermişlerdir. Diğer çalışmalarda, tek Gauss dağılımının gerçek dağılımlara tam olarak uymadığını ileri sürülmüştür. Chuang ve diğerleri [27], MRA görüntülerine dağılımı temsil etmek için bir Maxwell Gauss uniform karışım modelini uygulamışlardır. Gao ve diğerleri [28], Gaussian ve Rayleigh karışım modelini, Wang ve diğerleri [23], MRA görüntüleri için Gauss ve Gumbel dağılımlarını kullanmışlardır.

İstatistiksel yöntemlerin güçlü ve zayıf yanları global olarak EM algoritmasından kalıt almaktadır. Bölütleme sonuçları, büyük ölçüde dağıtım modellerine bağlı olduğundan EM'nin iklendirme ile belirlenen iterasyon prosedürü zaman alıcı olabilir. Ayrıca, her zaman garanti edilemeyen EM algoritmasının yakınsamasına dikkat edilmesi gerekir. Bu, örneğin maksimum iterasyon sayısı gibi bir sonlandırma koşulu ile sağlanabilir.

1.5.3. Deforme Edilebilir Modeller

Geodesic aktif kontur, ilk olarak 1997 yılında ortaya konuldu [29]. Bir şekilden ve bir konumdan türetilen ilk kontur, bölümlenecek yapıların sınırlarında duruncaya kadar deforme olur. Herhangi bir yerden iklendirilen konturun istenilen nesne sınırlarına gelmesi ve durması deformasyonlara uğratılarak yapılır. Genel olarak, konturun gelişimi, yumuşaklık ve düzgünlük gibi geometri özelliklerini korumak için başlangıç nesnesi içinde tanımlanan

1) iç kuvvetler tarafından, ve yoğunluk, homojenlik, gradyan gibi görüntü özniteliklerine bağlı 2) dış kuvvetler tarafından yönetilir.

Deforme olabilen modeller genellikle iki ana kategoride sınıflandırılır: parametrik ve geometrik modeller. Parametrik modeller, modelin doğrudan etkileşim ve kontrolüne izin veren konturların açık bir temsiline sahiptir. Öte yandan geometrik modeller, daha yüksek boyutlu bir skaler fonksiyonun düzey kümesi (level set) ile üstü kapalı bir temsile sahiptir. Parametrik modellerden farklı olarak düzey kümesi, deformasyon prosedürü sırasında bölünme (splitting) veya birleşme (merging) gibi nesne topolojisi varyasyonuna daha iyi uyum sağlayabilir.

Hernandez ve diğerleri [30], serebral damar yapıların bölütlemesi için Geodesic Aktif Bölgeler (GAB) kullanarak otomatik bir yöntem sunmuşlardır. Bu yöntemi üç boyutlu anjiyografi ve BTA görüntülerinden anevrizmaların bölütlemesinde uygulamışlardır. Enerji minimasyonu fonksiyonelliği, istatistiksel bölge tabanlı bilgileri dahil eder. Bu işlem farklı görüntüleme yöntemleri üzerindeki diğer organların bölütlemesinde de uygulanmıştır.

Sanz-Requena ve diğerleri [31], X-ışını koroner anjiyografisi ile intra vaskular ultrason görüntüsünden damar konturlarını çıkarmak ve damar patolojilerini değerlendirmek için GAB yöntemini kullandılar. Özellikle, bu modelde Gradyan vektör akışı harici kuvvet olarak kabul edildi. Lümen, intima ve plak gibi ultrason görüntülemeye farklı vasküler alanları tahmin etmek için, GAB yöntemiyle elde edilen konturları yine temel alan bir bilgi tabanlı yaklaşımla birleştirildi.

Firouzian ve diğerleri [32], anevrizmayı BTA görüntülerinden saptamak ve bölütlemek için düzey kümesi (level set) temelli bir yaklaşım uyguladılar. Bu çalışmada, anevrizmanın içinde seçilen bir tohum merkezinden, başlangıçtaki sıfır seviye eğrisi, yoğunluk, gradyan büyüklüğü ve yoğunluk varyansından türetilen dış kuvvetler hesaba katılarak gerçek kontura doğru evrilme yapılmaktadır. Anevrizmayı bitişik damarlardan ve bağlı kemiklerden ayırmak için önceden tanımlanmış bir İlgi Bölgesi (İB) gereklidir.

Wu ve diğerleri [33], serebral, karaciğer ve aort ağacı içeren BTA görüntülerinden farklı damar ağaçlarının çıkarımı için düzey kümesi kullanmayı önermişlerdir. Çalışmalarında, konturları gerçek damar kenarlarına doğru itmek için bir itme kuvveti, kontürlerin eğriliğini en aza indirmek için bir yumuşatma kuvveti ve vasküler bölgelerdeki konturu genişletmek için bir balon kuvveti olmak üzere üç tür güçten bahsedilmiştir. Enine

kesitlerin son işlemde geçirilmesi için bölümlenmiş konturu ayarlamak adına bir daire veya elips yerleştirme yöntemini önerilmişlerdir.

Li ve diğerleri [34], düzey kümesi yöntemine yeni bir formül sunmuştur. Bölgelerin kontürlerinin bir başlangıç alanından bölütlemesini mümkün kılmış ve deformasyonun yinelemeleri sırasında konturların düzenliliğini otomatik olarak sürdürmüşlerdir.

Chang ve diğerleri [35], üç boyutlu anjiyografi görüntülerinde beyin damarları ağını ve anevrizmayı çıkarmak için yüklü bir akışkan modeli önermişlerdir. Modelinde, deforme edilebilir kontur elektrostatik yasalara uyar. Önceden tanımlanmış bir ilgi bölgesinden elektrik güçleri Poisson denklemi tarafından yönetilen deforme edilebilir konturun evrimine rehberlik eder. Düzey kümesi bölütleme yöntemi ile karşılaştırıldığında, bu yaklaşım bulanık veya yüksek frekanslı gürültü ile bozulmuş damar görüntülerini bölütlemeye daha etkili olmuştur.

Düzey kümesinin en büyük avantajları topolojik adaptasyon, alt piksel hassasiyeti ve gürültü dayanıklılığıdır. Önceki şekil bilgisini birleştirerek, sınır boşluklarıyla ilgili problemleri çözmeyi sağlarlar. Bununla birlikte, deforme olabilen modellerin çoğu, özellikle parametrik modellerde başlatma işlemine karşı duyarlıdır ve sıklıkla kullanıcıyla bir etkileşim gerektirir. Kullanıcı etkileşimi ile başlangıç kontur konumu ve uygun parametre seçimi dezavantaj olarak görülebilir. Bu başlangıç değerlerine olan duyarlılığı azaltma da başlı başına bir araştırma konusudur. Buna ilaveten, nihai nesne sınırları başlangıçtakilerden çok uzak olmadığı zaman deformasyonun evrimi maliyetli bir süreç olabilir.

1.5.4. Örüntü Tanıma

Örüntü tanıma, örüntü tanımlama ve işlemeyi analiz eden bir veri madenciliği ve makine öğrenimi dalıdır. Çoğu durumda, bir örneğin tanınması, bir dizi örnek arasında en olası sınıfı eşleştirerek yapılır. Her bir örneğe eğitim adımıyla bir etiket atandıysa, bu yöntem denetimli öğrenme olarak kabul edilir. k-En Yakın Komşuluk (k-EYK), Destek Vektör Makineleri (DVM) bunlara birer örnektir. Bunun aksine, eğitim adımları sırasında veri örüntüleri etiketlenmediğinde bu yöntem denetimsiz öğrenme olmaktadır. Denetimsiz öğrenim teknikleri, beklenti maksimizasyonu ve kümeleme yaklaşımlarını içerir (örneğin, k-ortalamlar ve karışım modelleri).

Destek Vektör Makineleri (DVM), istatistiksel öğrenme teorisinden esinlenen tekniklerdir. DVM' nin amacı, verileri ayırmak ve iki sınıf arasındaki mesafeyi maksimize etmek için bir sınır bulmaktır.

Caldairou ve diğerleri [36], MRA görüntülerinden serebral damar ağının bölütlemesini gerçekleştirdiler. Bu yöntem, DVM ve bağlı bileşen yaklaşımını birleştirir. Yöntem, denetimli öğrenme ve sınıflandırma olmak üzere iki aşamadan oluşur. Denetimli öğrenme, görüntülerden tüm alt yapıları (damar ya da artefakt) toplayarak ve bunları bir bölütleme referansı ile etiketleyerek SVM modeli oluşturularak gerçekleştirilir.

Bogunovic ve diğerleri [37], üç boyutlu anjiyografi görüntülerinden IKA bifürkasyonunu otomatik olarak tanımlamak için SVM tabanlı bir yaklaşım önermişlerdir. GAB algoritması kullanılarak bölütleme aşamasından sonra, atardamar ağacının topolojisi, merkez çizgileri hesaplanarak oluşturulur. Bu çalışma, bifürkasyon noktasına, ana damarının ve her bifürkasyonun dallarının tanımlanmasına ve geometrik özelliklerine odaklanmaktadır. IKA'daki bifürkasyonunu saptamak için bir sınıflandırıcının eğitildiği bir makine öğrenme yaklaşımı uygulanmaktadır.

Vermandel ve diğerleri [38], MRA görüntülerinden 3B yapılarını bölütlemesi için bulanık mantık kuramını kullanmışlardır. Çalışmalarında, damar bölgenin başlangıç konturundan tanımlanan bulanık alanın varsayımını getirmişlerdir. Bir vokselin damar yapıya ait olup olmadığını belirlemek için, bulanık alandaki her vokselin üyelik derecesini gri seviyelerin dağılımını göz önüne alarak elde etmişlerdir. Sonuçlar tatmin edici olmasına rağmen, bazı damarlarda kopuk dallar olduğundan bir son işleme (post-processing) adımı gereksinim duymuşlardır.

Forkert ve diğerleri [39], ayrıca TOF-MRA görüntülerinden damar iyileştirme, bölütleme ve yapı ayrımını gerçekleştirmek için bulanık tabanlı bir algoritma sunmuştur. Yöntemlerinde, bölütleme için görüntüleri ön-işleme, bulanık mantık füzyonu ve son işleme aşamalarından geçirmişlerdir.

1.5.5. Bölge Büyütme

Çıkarım yapılacak yapılara ait seçilmiş tohumlardan başlayarak, bölge büyütme tekniği, önceden tanımlanmış bir kritere dayanarak komşu pikselleri / vokselleri dahil ederek

aşamalı olarak ilerler. Bölütleme sonucu, tohum noktalarının başlatılması ve dahil etme kriteri olmak üzere iki önemli unsura dayanır.

Genellikle, serebral damar bölütlemesinde damar ağacının kökünde tohum noktaları tanımlanır. Bu tohumlar interaktif (etkileşimli) olarak seçilebilir veya otomatik olarak yerleştirilebilir. Dahil etme kriteri genellikle bitişik piksellerin mekansal yakınlığına ve homojenliğine dayanır [40]. Enjekte edilen kontrast madde sayesinde, damar bölgelerin yoğunluğu çevredeki arka plan yapılarından daha parlak ve homojendir [41]. Bu, kan damarlarına ait piksel veya vokseller için sağlam dahil etme kriterlerinin tanımlanmasına izin verir.

Görüntüdeki mevcut gürültü veya yoğunluk değişkenliği nedeniyle, filtreleme gibi bazı son işleme (post processing) yöntemleri bazen bölütleme doğruluğunu sağlamak için gereklidir. Damarların tıbbi görüntülerden doğru şekilde bölütlenmesi amacıyla bölge büyütme bölütleme yöntemini diğer işlemler ile birleştiren bazı çalışmalar aşağıdaki gibidir.

1.5.5.1. Şekil-tabanlı Bölge Büyütme Model

Masutani ve diğerleri [42], 1998 yılında şekil tabanlı bölge büyüme modeli kavramını sunmuştur. Önerilen algoritmada, başlangıç ikili (binary) şekil elde etmek için basit bir eşikleme gerçekleştirilir. Tohum daha sonra manuel olarak tanımlanır ve küme, matematiksel morfolojik element ile giderek büyür. Yayılım, bölütleme sonucundaki delikleri doldurmak için bir kapatma (closing) ve yumuşatma (smoothing) işlemiyle yinelenir. Seçilen yapısal element sayesinde, bifürkasyonları ve damar bölütleme kopukluklarını yayılma ile tespit etmeyi mümkün kılar. Masutani'nin çalışmasına benzer bir çalışmada Sekiguchi ve diğerleri [43], MRA görüntülerinden serebral damar bölütlemesi için dal (branch) bazlı bölge büyütme yöntemini önermektedirler.

Jiang ve diğerleri [44], yakın zamanda Sekiguchi ve diğerleri [43]'nin çalışmasını geliştirdiler. Yaklaşımlarında, Hessian matrisine dayanan bir damar geliştirme uygulandı ve bunu spektrum analizi izledi. Böylece damar yapının ilk tespit edilmesi sağlandı. En yüksek gri değere sahip olan nokta, dal-tabanlı bölge yetiştirme yöntemi işlemi [43] için tohum olarak seçildi. Önerilen yaklaşım ile 2B retinal damar görüntülerde iyi sonuçlar elde edilmiştir. Üç boyutlu BTA karaciğer görüntülerinden damarlardaki bifürkasyonları bölütlediler.

1.5.5.2. Klasik Bölge Büyütme Model

Boskamp ve diğerleri [45], üç boyutlu BTA ve MRA görüntülerinden damarları çıkarmak için klasik bölge büyütme yaklaşımından faydalandılar. Kriterleri bir eşik değerine dayanmaktadır, gri değerleri bu eşik üzerindeyse tüm komşu vokseller bölgeye dahil edilmektedir. Eşik değer, eşik-hacim (threshold-volume) diyagramı analiz edilerek belirlendi. Bu çalışmada, damar yapısının karışan yapılardan izole edilmesi ön-maskeleme yöntemi ile post-processing aşamasında gerçekleştirilmiştir. Maske sınırı, damarlarda ve karışan yapılarda bulunan iki işaretleyiciden gelen havza (watershed) yaklaşımıyla tanımlanmıştır. Önerilen yöntem intrakraniyal, koroner ve abdominal arterler gibi tek arterler için test edilmiş ve doğrulanmıştır. Temel sınırlama, karmaşık damar ağı için tespit edilmesi zor olan bir ön-maskenin gerekliliğidir.

1.5.5.3. ATLAS ve Bölge Büyütme

Passat ve diğerleri [46], MRA görüntülerinden oluşturulan beyin atlasında bölge büyütme yöntemini uyguladılar. Bu atlas, aynı görüntünün çeşitli bölütleme sonuçlarının kaydedilmesiyle oluşturulmuştur. Damar anatomik bilgileri depolamak amacıyla atlas, başlangıç görüntüsünü, arterler (atardamar), toplardamar (veins), damarlar, hem arteriyel hem de venöz damarlar, veya hiç damar olmayan yapılar olmak üzere dört ana bölgeye ayırmıştır. Bölge büyütmesinde, arteriyel ve venöz ağaçları oluşturmak için ayrı ayrı uyarlamalı (adaptif) eşik değerleri kullandılar. Damar ağaçlarının topolojisini korumak için, büyüme işleminde sadece basit noktaların eklenmesine izin verdiler. Bu çalışmanın sonuçları, atlas bazlı bölge büyütmenin bölütleme sonucunu etkili bir şekilde geliştirebileceğini doğrulamıştır.

1.5.5.4. Filtreleme Tabanlı Bölge Büyütme

Cao ve diğerleri [47] ve Chen ve diğerleri [48], BTA görüntülerinden 3B koroner damarları bölütleme için minimum yol bazlı bölge büyütme yöntemini önerdiler. Bu algoritma, önceden tanımlanmış bir enerji işlevini en aza indiren yolu arayarak bölge büyütme işlemini icra eder.

2B anjiyogram görüntülerinden koroner ağacı çıkarmak için, Wang ve diğerleri [49] ve Li ve diğerleri [50] benzer bir algoritma önerdiler. Wang ve diğerleri, Hessian matrisine dayanan çok ölçekli bir filtre kullanmaktadır. Li ve diğerleri ise, bölge büyümeden önce bir işlem öncesi araç olarak [51] 'deki damar filtresini seçtiler. İyileştirici filtreler ile, küçük damarlar özellikle iyileştiriliş ve daha fazla damar tespit edilmiştir. Çok yakın zamanda, Kulathilake ve diğerleri [52], aynı uygulama ile bölge büyümesine dayanan başka bir yaklaşım sunmuştur. Görüntü kalitesini iyileştirmek için öncelikle medyan filtreleme ve normalizasyon işlemleri icra edilir. Çalışmalarının yeniliği, olası damar yapı bölgelerini tasvir eden bir maske görüntünün oluşturulmasıdır. Maske görüntüsü, arka plan yapıları hareketsiz kalırken, anjiyogramlarda damarların hafifçe hareket ettiği varsayımıyla, birbirini izleyen iki görüntü çerçevesini (frame) iteratif olarak karşılaştırarak elde edilir. Sunulan maske görüntüsü, damar dışı bölgelerin bölütlemesini en aza indirmeye imkân verdi.

Almiani ve diğerleri [53], MRA görüntülerinden damar çıkarımı için modifiye edilmiş bir bölge tabanlı teknik tanımladılar. İlk olarak, izole noktaları tespit etmek için, görüntü iyileştirme yöntemleri bir güç-kanunu (power-law) dönüşümü ve özel bir filtreleme ile uygulanmıştır. Bir ilgi bölgesi (ROI) merkezinde bir nokta seçtikten sonra, piksel yoğunluğunun ortalaması hesaplanmıştır ve merkez noktasının yoğunluğu ile ortalama arasındaki farktan bir homojenlik kriteri çıkarılmıştır. Bu şekilde bölütleme sürekliliği için bölge büyütmenin devam durumu sağlanmıştır.

Son zamanlarda Orkisz ve diğerleri [54], pulmoner damar ağaçlarını BT görüntülerinden ayırmayı önerdi. Bu çalışmada, pulmoner damar ağacının bir tanımlaması ilk olarak uyarlamalı çok-ölçekli morfolojik operasyonlarla gerçekleştirilmiştir. Daha sonra damar fonksiyonu ile bir damar iyileştirme işlemi gerçekleştirildi. Damar görüntüsündeki maksimum yoğunluk pikseli, varyasyon bölge büyütmesini (Variational Region Growing) başlatmak için tohum noktası olarak seçilmiştir. Bu yöntem, bronş duvarları etrafındaki çoğu damar ağacını başarılı şekilde bölütlemiştir.

1.5.5.5. Hibrid Bölge Büyütme ve Düzey Kümesi

Chang ve diğerleri [55], üç boyutlu anjiyografi görüntülerinden serebral anevrizma bölütlemesi için bir algoritma önermektedir. Bir akışkan modeline dayanarak 2B bölge büyütme algoritmasını ve ardından 3B deforme edilebilir konturu uyguladılar. Seçilen bir

tohumdan başlayarak bölge büyütme, belirtilen bir homojenlik kriteri ile bir başlangıç 2B bölütleme elde edilmesini sağladı. Bölütleme sonucu; kütle merkezi, damarın sınırları ve damarın büyüklüğünü hesaplamak için kullandılar. Tüm bu bilgilere dayanarak, doğru bölütleme sonuçları vermek için 3B deforme edilebilir kontur modeli daha sonra icra edilmiştir.

Martinez ve diğerleri [56], torakal aortayı BTA görüntülerinden ayırmak için düzey küme ve bölge büyütme algoritmasını içeren bir hibrid yöntem önermektedir. Torasik (göğüs) aortun oldukça basit şekli, elips benzeri damar bölgeyi Hough-transformasyonunu kullanarak görüntünün birinci dilimi üzerinde konumlandırmayı mümkün kılmıştır. Bölge merkezi daha sonra 3B görüntü hacmini bölütlemek için tohum noktası olarak seçilmiştir. Kusursuz bir bölütleme sonucu elde etmek için bölge büyütme sonrası düzey kümesi yöntemi uyguladılar.

Sonuç olarak, bölge büyütme bölütleme yöntemi, özellikle koroner, akciğer ve retina damarlarının çıkarımı için yaygın olarak kullanılan klasik bir yöntemdir.

1.5.6. Matematiksel Morfoloji Yaklaşımları

Matematiksel morfoloji, görüntüleri yoğunluğuna ve şekline göre filtrelemek, bölütlemek ve ölçmek için bir takım yararlı operatörlerle bir dizi matematiksel araç sağlar. En basit araçlar eşiklemeye dayalıdır. Diğer araçlar, genişleme (dilation) ve aşınma (erosion)'dan üretilebilir. Bunlar; açınım (opening), kapanım (closing) ya da havza (watershed) bölütleme ve “hit-or-miss” transformasyonu gibi daha ileri yöntemleri kapsamaktadır. Bu morfolojik operatörler genellikle, belirli bir şekil ve boyutta bir yapılandırma elementi (structuring element) ile kurulur.

Passat [57]'in üç boyutlu MRA görüntülerinden beyin damar yapılarının matematiksel morfoloji tabanlı bölütlenmesindeki yöntemi literatüre katkıda bulunmuştur. Dört yararlı yöntem önermektedir. Bunlardan ikisi; uyarlamalı eşikleme ile bölge büyütme ve gri ölçek yönteminde “hit-or-miss” in kombinasyonunu oluşturan, global serebral damar yapılarının bölütlenmesi içindir [57]. Diğer iki yöntem; havza ve homotopi indirgeme araçlarına dayanan topolojik yeniden yapılandırma ile beynin yerel damar yapılarının bölütlenmesine uygulanmıştır [58].

Babin ve diğerleri [59, 60], düşük çözünürlüklü görüntüler ve yüksek piksel yoğunluğu değişkenleri için bile uygun yenilikçi bir 3B anjiyografi bölütleme yöntemini uyguladılar. Bu yöntem, farklı boyut ve kontrasttaki damarlar için özel olarak uyarlanmış olan değişken farklı diferansiyel yapısal elementler ile gerçekleştirilen morfolojik profillerin [61, 62] genelleştirilmesine dayanmaktadır.

Dufour ve diğerleri [63], matematiksel morfolojiye dayanan tam bir damar filtreleme ve bölütleme yöntemini önermişlerdir. Filtreleme için, diferansiyel damar tanımlayıcıları [51] ile birleştirilmiş varyant matematiksel morfoloji kullandılar [64]. Bölütlemeye, bir eşikleme dizisinden elde edilen ikili düzey kümesini kullanarak gri seviye bir görüntünün karakteristiklerini modellemek için, bağlı filtreleme uyguladılar. Ayrıca, bu yöntem az kullanıcı etkileşimine ihtiyaç duyar ve bölütlünecek görüntü ile ön-bölütlü (pre-segmented) görüntünün birlikte kayıt altında olması gerekir. Bu yöntem özellikle serebral atlas oluşumu ve atlas bazlı bölütleme için yararlıdır.

1.5.7. Damar Özniteliğine Dayalı Modeller

Passat ve diğerleri [58], geometrik bir model kullanarak bölütleme yaklaşımı geliştirdiler. İlk aşamada, voksellerin damara aidetliği üzerine bir olasılık modeli geliştirilmiştir. Nihai uyarlamalı eşikleme adımı için, sadece sıfırdan büyük olasılıkları olan vokseller dikkate alınır. Bu tip bir model ilginç olsa da, tamamen geometrik olduğu için çok çeşitli patolojik durumları hesaba katmakta zorlandığı söylenebilir.

1.5.7.1. Tüp (boru) Benzeri Çok-Ölçekli Filtreler

Geometrik bir bakışla, 3B hacimlerdeki damar yapılar tüp-benzeri nesnelere olarak düşünülebilir. Prensipinde, bu boru şeklindeki nesnelere, bir ana doğrultuda uzar ve sonra diğer iki dikey yönde incilir [65]. Bu özelliği ortaya çıkarmak için, arka planı zayıflatırken boru şeklindeki yapıları (damarları) geliştirmek için çeşitli filtreler eklenmiştir. Bu işlemi gerçekleştirmek için Frangi ve diğerleri [51], Hessian filtreleme yöntemini önermektedir.

Sato ve diğerleri [66], üç boyutlu Hessian matrisinin özdeğerlerinin bir kombinasyonuna dayanan bir filtre önermişlerdir. Bu tür kombinasyonlar, tek filtre yanıtı

arasından maksimum alınarak tasarlanmıştır. Bu sözde damar fonksiyonu, hat (line) şekil yapısını tespit etmek ve geliştirmek için yaygın olarak kullanılmıştır.

Krissian ve diğerleri [67], üç boyutlu anjiyografi görüntülerinden serebral damarların saptanması ve yeniden yapılandırılması için çok-ölçekli yaklaşım uyguladılar. Ayrıca, bir Gauss dağılımına göre yoğunluğu değişen bir silindirik model tasarladılar. Belirli bir ölçekte tepki, damarın enine kesiti içindeki bir daire boyunca radyal doğrultudaki yoğunluğun birinci türevinin birleştirilmesiyle elde etmektedirler. Çalışmada modelin normalleşmesinden sonra, bir damarın yarıçapı ile tespit edildiği ölçek arasındaki ilişkiyi çıkardılar. Çok ölçekli yanıt böylece damarların iskeletini çıkarmaya ve damar ağını eksenlerden ve ilişkili ışıklardan yeniden oluşturmaya izin verir.

Hessian filtrelemenin dezavantajları; zaman alıcıdır ve bifürkasyonları saptamada başarısızdır. Orłowski ve Orkisz [68], çoklu filtrelemenin hesaplama etkinliğini iyileştirmek için bir yöntem önermişlerdir. Matris diyagonalindeki elemanların toplamını kontrol ederek, Hessian özdeğerlerini hesaplanmadan önce olası damara ait olmayan bazı vokseller atılır. Bu optimizasyon ile, hesaplamanın yarı süresinden kazanç sağladılar. Yumuşak dokuların benzer şekliyle etkileşimini ortadan kaldırmak için Yang [69], damar yapısını güçlendirmek ve diğer dokuları hafifletmek için bir görüntü gri-skala faktörü eklemiştir. Sonuçlar beyin MRA ve BTA verileri üzerinde denenmiştir.

1.5.7.2. Merkez Hattı (centerline) Modeller

Geometrik modeller kategorisindeki çalışmaları içerir. Karmaşık 3B yüzey bilgisine bakılmaksızın, iskelete dayalı bir varsayım, damar ağacının basitçe merkez çizgileri olarak tanımlanan bir 1B eğrisine indirgenebilmesidir. Bu kategorideki çoğu çalışma, merkez noktayı damar boyunca bir kök noktasından takip eden yarı otomatik yaklaşımlardan oluşmaktadır. Takip prosedürü, tahmin ve düzeltme olmak üzere iki aşama içerir. Merkez hattındaki ardışık nokta konumlarının tahmini temel olarak damar yönünün değerlendirilmesiyle gerçekleştirilir. Yön tahmin metotları; Hessian-temelli teknikleri [70], eylemsizlik (inertia) momentlerini [71] ve gradyan vektör dağılımını [72] içerir.

Tahmin edilen merkez pozisyonu ikinci adımda düzeltilir. En yaygın yöntem, 2B kesitin tahmini etrafında bölütlenmesi ve kesit alanın kütle merkezinin düzeltilmesidir [73]. Damarın başlangıç ve varış noktaları bilindiğinde başka yaklaşımlar geliştirilmiştir.

Örneğin, minimal yol teknikleri (Dijkstra-benzeri yol), damar iskeleti çıkarmak için yaygın olarak kullanılmaktadır [74, 75]. Ayrıca, Lacoste ve diğerleri [76], 2B anjiyogramlardan koroner arterlerin bölütlemesi için Markov işaretli nokta işlemlerini kullanmayı önermişlerdir. Ancak bu yöntem, 2B görüntü analizi ile sınırlıdır.

1.5.7.3. 3B Genelleştirilmiş Silindir Modelleri

Geometrik modeller kategorisindeki çalışmaları içerir. Genelleştirilmiş silindir modelleri silindirik nesnelere temsil etmek için kullanılır. Model, bir uzay eğrisi olan merkez hattı boyunca genişleyen 2B kesit çizgilerinden oluşur. Klasik enine kesitsel formlar arasında daireler, elipsler ve parametrik eğriler bulunur.

Flasque ve diğerleri [77], 3B anjiyografik görüntülerindeki serebral arterlere uygulanan boru şeklindeki (tubular) yapıları saptama üzerine yöntem önermişlerdir. Modelleri bir silindir merkez hattı ve bir dizi 2B kesitten oluşmaktadır. Merkez çizgiyi yüksek doğrulukla bulmak için yoğunluk olmayan bir geometrik model oluşturdular.

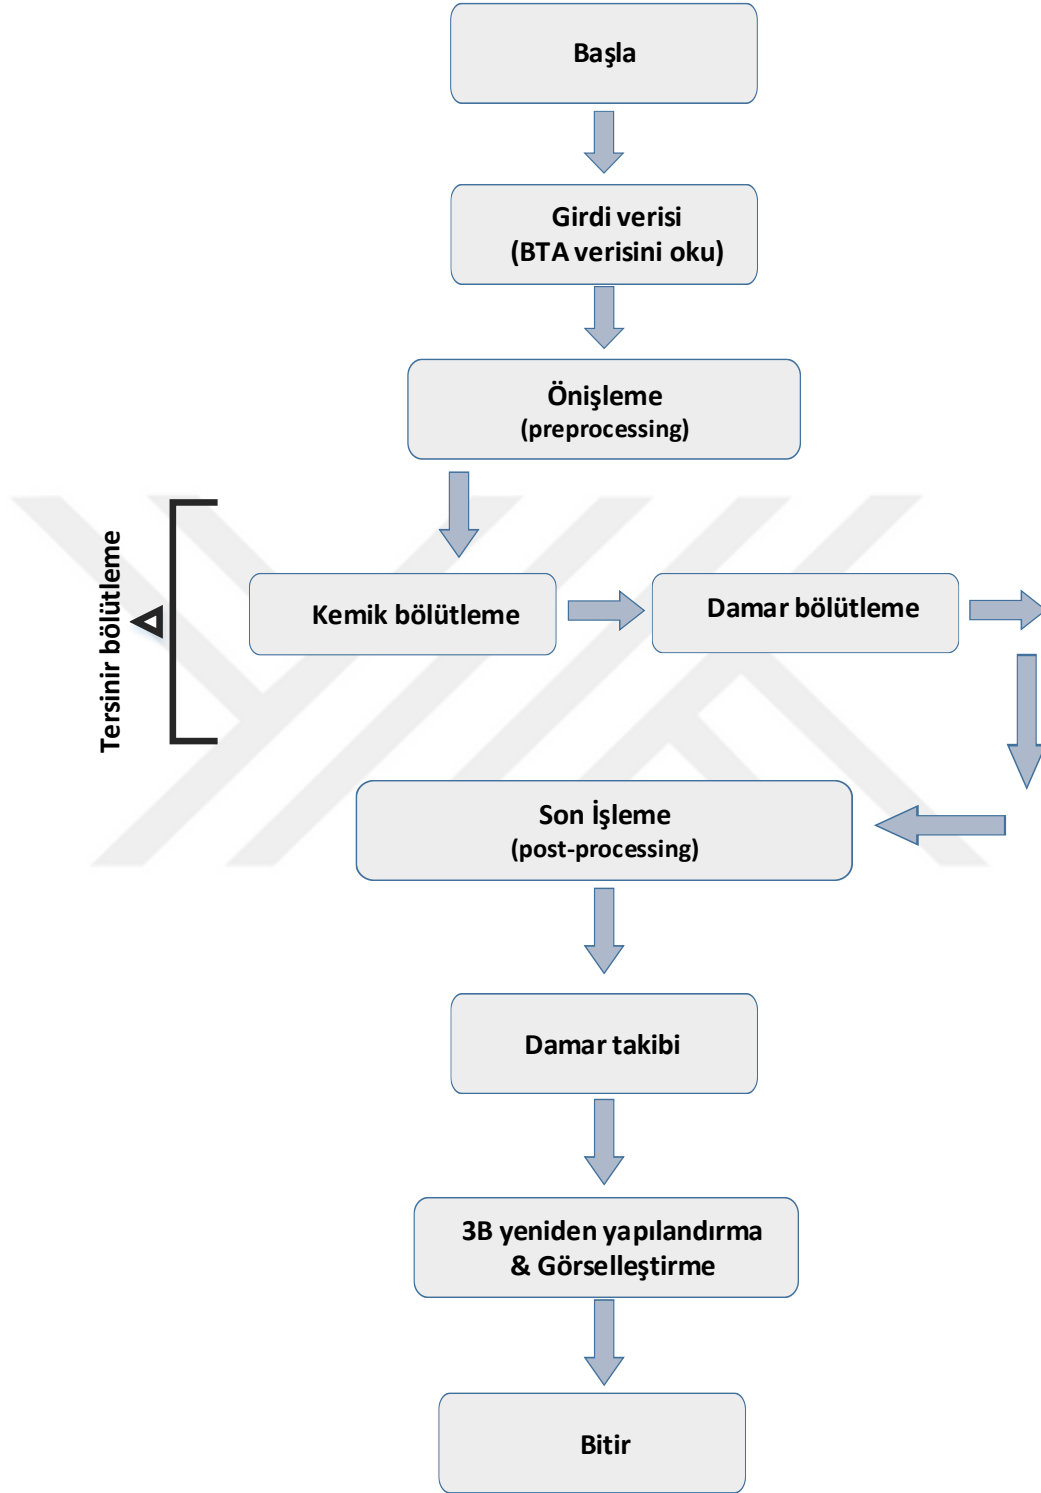
Kumar ve diğerleri [78], damar bölütlemesi ve merkez hattı çıkarımı üzerine algoritma önerdiler. Bu algoritmada, takip yönü Hessian matrisinin analizi ile elde edilir ve iki boyutlu bölütleme bir Canny kenar algılama filtresi uygulanarak gerçekleştirilir.

Merkez hattı ve silindir modelleri iki ana varsayımı temel alır; damarlar çok iyi bir kontrasta sahiptir ve oldukça basit bir ağaç yapısı ile birbirine bağlanır. Bu bağlamda, daha çok BTA görüntülerine uygulanan bu yöntemin, literatüre katkısı oldukça fazladır.

2. YAPILAN ÇALIŞMALAR

Bu bölümde, üzerinde çalıştığımız veri setleri ve yöntemin aşamaları anlatılmaktadır. Önerilen yöntemin akış diyagramı Şekil 2.1'deki gibidir. Bu aşamalarda yapılan çalışmalar kısaca şu şekilde özetlenebilir.

- Bu tez kapsamında kullanılacak BTA verileri ilgili kurumdan temin edilmiştir.
- Alınan verilerin dosya yapısı incelenmiştir.
- BTA görüntülerinin, görüntüleme araçları ile incelenmesi, sonrasında radyoloji uzmanından kan damarları, kemik bölgesi gibi farklı dokuları öğrenmeye yönelik gerekli anatomi bilgisi alınmıştır. Bu amaçla uzman kişiden damar çıkarımında problem teşkil eden yerler ile ilgili bilgiler alınmıştır.
- Verideki damar bölgelerinin bir kısmının radyoloji uzmanı tarafından ve daha sonrasında uzman kontrolünde BTA görüntüleme aracıyla işaretlenmesi, eğitim verisinin oluşturulması gerçekleştirilmiştir.
- Literatürde karşılaştırma yapabilecek başka bir veri seti araştırılıp temin edilmiştir.
- Görüntüler, ön işleme aşamasından geçirilmiştir.
- Tersinir yaklaşım ile yeni bir otomatik bölütleme yöntemi geliştirilmiştir. Tersinir yöntem yaklaşımıyla öncelikle kemik bölgesi bölütlenmiş ve çıkarılmıştır, daha sonra damarlar bölütlenmiştir.
- Bölge büyütme ve rassal yürüyüş bölütleme yöntemleri kullanılmıştır.
- Yöntem içerisinde tohumlandırma için kullanılacak eşik aralıkları belirlenmiştir.
- Bölge büyümesi için benzerlik kriteri, ortalama yoğunluk veya dokusal özellikler ile belirlenmiştir.
- Üç boyutlu tohumlandırılmalı dokusal bölge büyütmesi uygulanmış olup, eşik değerinin otomatik belirlenmesi üzerine odaklanılmıştır.
- Kemik bölütlemesi ve sonrasında damar bölütlemesi bu yöntemler ile gerçekleştirilmiştir.
- Son işleme (post processing) aşaması uygulanmıştır.
- Damar merkezini referans alarak damar takibi aşaması uygulanmıştır.
- Bölütleme sonuçlarının, üç boyutlu yeniden yapılandırılması ve görselleştirilmesi yapılmıştır.
- Temin edilen tüm veri setlerine tersinir yöntem uygulanmıştır.

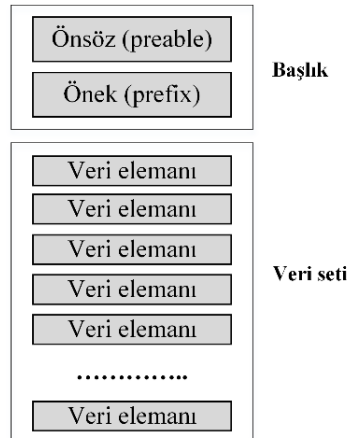


Şekil 2.1. Önerilen yöntemin akış diyagramı

2.1. Verilerin Toplanması ve BTA Verisi

Bu tezde kullanılan veritabanı, Karadeniz Teknik Üniversitesi Farabi Hastanesi Radyoloji bölümünden temin edilmiştir. Bu veritabanı, Karadeniz Teknik Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurul Başkanlığı'ndan yönetmelik dışı klinik araştırmalar kapsamında akademik amaçlı kullanılmak üzere 24237859/58 sayılı ve 13.01.2015 tarihli etik kurul izni ile temin edilmiştir. Bu tez kapsamında; Farabi veri seti bu bölümden farklı yaş ve cinsiyet grubundaki 15 farklı hastaya ait BTA verisi alınarak oluşturulmuştur. Görüntüler, çözünürlüğü 0.5mm x 0.5mm olan Siemens firmasına ait Somatom Definition Flash CT Scanner cihazıyla standart bir karotid anjiyo (yetişkin için) tarama protokolüyle alınmıştır. Tüm hastalara kontrast madde olarak 320 mg / ml Iodixanol verildi. Bu veri seti hasta verilerinden rastgele seçildi, kontrast madde ve dilim sayısı düşük değişkenlik göstermektedir.

DICOM formatında kaydedilen bu görüntüler 12 bit gri seviyededir. 12 bit derinliğinde (4096 gri ton) görüntüde, görüntü piksel yoğunluk değeri 0-4096 arasındadır. Her BTA verisi çok sayıda 2B dilim görüntüden ibarettir. Girdi verisi DICOM formatında yaklaşık olarak 350-400 görüntüden oluşur. Her görüntü, 512x512 piksel gri ölçek değeri içermektedir. Örneğin bir BTA verisi, $0.5 \times 0.5 \times 0.49 \text{mm}^3$ boyutunda 512x512x390 voksellere sahiptir.




Şekil 2.2. DICOM dosya yapısı [6]

2.1.1. DICOM Dosya Yapısı

DICOM formatı, uluslararası alanda kabul edilmiş dosya biçimini ve bir ağ protokolünü ifade eder. Medikal görüntüleme, tıbbi verinin depolanmasını, iletilmesini, yazıcıya gönderilmesini sağlar. DICOM görüntü biçimi, görüntünün elde edilmesine dair protokol adı, kesit aralığı, modalite (yöntem) gibi parametreleri içerir [79].

DICOM dosyasının başlık ve veri kümesinden oluşan iki bölümü vardır. Şekil 2.2, temel dosya yapısını göstermektedir. Başlık (header), 128 byte önsöz (preamble) ve 4 byte önek (prefix) 'ten oluşur. Bu dosya üstbilgisinin (başlık) amacı, DICOM dosyasında bulunan verilere erişimi kolaylaştırmak için yaygın olarak kullanılan bir dizi bilgisayar görüntü dosyası formatları ile uyumluluk sağlamaktır. Şekil 2.3'de görüldüğü gibi veri seti, daha büyük bir nüfusun bir bölümünü temsil eder ve 4 parçadan oluşan veri elemanlarından oluşur. Bunlar, veri elemanı etiketini (tag), değer temsilini (value representation-VR), değer uzunluğunu ve değer alanını içerir.

Veri elemanı etiketi, grup sayısını eleman sayısı izleyen sıralı (XXXX,YYYY) formatında bir çift 16 bit işaretli sayıdan oluşur. Veri elemanını tekil olarak tanımlar. Değer temsili (VR), değer alanındaki veri türünü ve biçimini açıklayan iki baytlık bir karakter dizisidir. Değer uzunluğu, değer alanının uzunluğunu gösteren 16 veya 32 bit işaretli bir tam sayıdır. Değer alanı ise, saklanan bilginin tutulduğu yerdir [6].



Şekil 2.3. DICOM veri seti yapısı [6]

2.2. Önışleme işlemleri

Bölütleme işlemine başlamadan önce, görüntüler önışleme aşamasından geçirilmektedir. Önışleme aşamasında, Pencereleme&Seviyelendirme ve ortalama kayma fitresi uygulanmaktadır.

2.2.1. Pencereleme ve Seviyelendirme


Pencereleme, BT taramalarının değerlendirilmesinde değerlendirilen belirli doku veya anormallikleri tespitinde kontrastı arttırmak için, sıklıkla kullanılan bir tekniktir. Gri-düzey haritalama, kontrast germe, histogram modifikasyonu ya da kontrast iyileştirme olarak da bilinen pencereleme, bir görüntünün BT görüntüsü gri tonlama bileşeninin BT sayıları ile manipüle edildiği süreçtir. Bunu yapmak belirli yapıları (dokuları) vurgulamak için resmin görünümünü değiştirecektir. Görüntünün parlaklığı, pencere seviyesi ile ayarlanır, kontrast ise pencere genişliği üzerinden ayarlanır [80].

BTA'da damarın gri seviye dağılımı biraz disipline sahiptir ve damarların yoğunluğu küçük bir Gauss dağılımı izler. Ayrıca, damar sınırları yumuşak gradyanlı dağılıma sahip olmasından ötürü, farklı yapılar genellikle birleşmiş haldedir ve sadece pencerelemenin genişliğini küçülterek ayırt edilebilir. Bu aşamada, görüntü veri kümesi içinde çok çeşitli yoğunluk aralıkları olduğundan, görüntülerde bölütleme yapmadan önce mümkün olduğu kadar ortak bir dinamik aralığına ve kontrast ayarına getirmek için görüntülerin kontrastı normalleştirilmekte ve iyileştirilmektedir. Örneğin bu sayede, yumuşak dokunun atılması hedeflenerek damar nesnelere benzemeyen nesnelere kaldırılmıştır.

2.2.2. Ortalama Kayma Filtresi

Son zamanlardaki bölütleme çalışmaları karotid arterlerin etrafındaki çevreleyen yapılardan daha homojen olduğunu göstermiştir. Bu aşamada, damar yapıların kenarlarına herhangi bir zarar vermeden damar yolu boyunca lümen bölgesinin yoğunluk homojenliğini arttırmak amacıyla, bir ortalama kayma fitresi kullanılmaktadır. Şekil 2.4'de ortalama kayma fitresinin uygulanmasıyla arter yapılarının belirginleştiği filtre öncesi ve sonrasında görülmektedir.

Ortalama kayma, parametrik olmayan yinelemeli bir algoritma veya genelleştirilmiş bir çekirdek (kernel) yaklaşımı kullanılarak parametrik olmayan yoğunluk gradyanı tahminidir [81]. Görüntü filtreleme yöntemlerinden biri olan ortalama kayma yöntemi, birleşmiş konum-renk uzayında çalışmaktadır. Ortalama kayma ile görüntüde belirli bir yakınlığa sahip bölgeler için yumuşatma sağlanır. Ortalama kaydırma filtresi, her bir pikselin değerini, parametrik olmayan bir olasılık yoğunluk tahmini yöntemiyle bulunan en olası yerel değerle değiştirir. Ortalama kaydırma filtresi; ikili, gri tonlamalı, RGB ve çok kanallı görüntüler ile çalışabilir. Birleşmiş konum-renk uzayından ötürü görüntüdeki her bir piksel, 3 adet renk değeri ve 2 adet konum değerini içeren 5 elemanlı bir vektör şeklinde temsil edilmektedir [82].



Şekil 2.4. Ortalama kayma filtresi ile, (a) filtre öncesi damar, (b) filtre sonrası damar

d boyutlu vektörler olan x_i ve z_i ($i = 1, \dots, n$), orijinal ve birleşmiş konum-renk uzayındaki filtrelenmiş görüntü piksellerini temsil etmektedir. Ortalama kaydırma yöntemi iteratif olduğundan aşağıdaki gibi tanımlanabilmektedir.

- $k = 1$ ve $y_{i,1} = x_i$ olarak alınmaktadır.
- (2.1) denkleminde $y_{i,k+1}$ hesaplaması yapılır. İşlem yakınsamasında sonra $y = y_{i,c}$ olarak alınmaktadır.

$$y_{k+1} = \frac{\sum_{i=1}^n x_i g\left(\left\|\frac{y_k - x_i}{h}\right\|^2\right)}{\sum_{i=1}^n g\left(\left\|\frac{x - x_i}{h}\right\|^2\right)} \quad (2.1)$$


- Filtrelenmiş piksel için, $z_i = (x_i^s, y_{i,c}^r)$ alınır. (Burada s ve r terimleri sırayla vektörün konum ve renk değerlerini ifade etmektedir).

Yakınsama kriteri, ardışık kernel konumlarının y_{k+1} ile y_k arasındaki farkın belirli bir hata değerinden küçük olmasıyla sağlanır. Burada $g(x)$, normal ya da Epanechnikov profiline sahip bir kernel fonksiyonudur ve ayrı ayrı, konum ile renk bant genişlikleri $h = (h_s, h_r)$ vardır [82].

2.3. Tersinir Bölütleme Yaklaşımı

Kemik çıkarma işlemini BTA ile yapmak yerine, görüntü işleme tekniklerinden bölütleme yöntemleri ile bu işlem yapılabilir. Tersinir bölütleme yaklaşım ile bu tez kapsamında öncelikle damar bölütlemesinde problem olan kemik ve kemiğe benzer yüksek yoğunluk seviyesine sahip bölgelerin bölütlemesi yapılmaktadır. Her ne kadar bu işlem aşırı işlem ve zaman gerektirse de, hastanın iki kez vücudunun BTA ile taranarak kontrast madde ve kontrast maddesiz taramasının karşılaştırmasından daha verimli olacağı düşünülmüştür. Bu bağlamda, tez kapsamında öncelikle problem olan kısım kemiğin tersinir yöntemle çıkarılması üzerine çalışmalar yapılmıştır. Mevcut yöntemde, uzmanlar damar-kemik ayırımını tam olarak yapabilmek için, öncelikle normal şartlarda hastaya bir kontrast maddesiz BTA taraması yapılır, bir kez de tarama vaskülere sisteme kontrast madde verilerek yapılır. Şekil 2.5 (a)'da bir boyun bölgesindeki BTA görüntüsünün kontrastsız, Şekil 2.5 (b)'de kontrastlı şekli görülmektedir. Bu şekilden karotid damarlarının ve bir internal karotid bölgesindeki kitlenin tespit edilebildiği görülmektedir. Şekil 2.5 (c)'de ise Şakak bölgesindeki bir BTA görüntüsünün kontrastsız, Şekil 2.5 (d)'de kontrastlı şekli görülmektedir. Bu şekillerden damarların, eşleştirmeden (registration) sonra ilk görüntüyü ikinciden çıkararak görselleştirilebilir olduğu görülmektedir. Tersinir yöntem ise kişiye bir

kez kontrast madde verilerek elde edilen tek taramadan elde edilen görüntülerden damarların çıkarılması üzerine inşa edilmiştir. Bunun sebebi, hastanın iki kez radyasyona maruz kalması kabul edilebilir değildir. Ayrıca hastanın uzun süre sabit aynı pozisyonda tamamen hareketsiz kalması ve sonrasında görüntülerden sağlıklı bir şekilde eşleştirme yaparak karar vermek mümkün olmayabilir.



Şekil 2.5. Kontrastsız ve kontrastlı aksiyel BTA görüntüleri: (a) boyun bölgesi kontrastsız, (b) boyun bölgesi kontrastlı, (c) şakak kemiği bölgesi kontrastsız, (d) şakak kemiği bölgesi kontrastlı görüntü [83, 84]

İnsan vücudunda çok bölgede kontrast madde ile zenginleştirilmiş damar yapılarının iskelet yapıdan ayırımı sağlıklı bir şekilde yapılamaz. Özellikle BTA, vasküler sistemde stenoz derecesini değerlendirmeye imkan sunar, ancak damarın kemik ve kalsifikasyon yapılarına karşı ayırımına gereksinim duyar. Boyun ve baş bölgesinde mevcut damarları

bulmaya yönelik işlem gerçekten zor bir işlemdir, bunun yerine engel olan kemiklerin çıkarılması ile daha iyi değerlendirme ve görselleştirmeye imkân sağlayabilir.

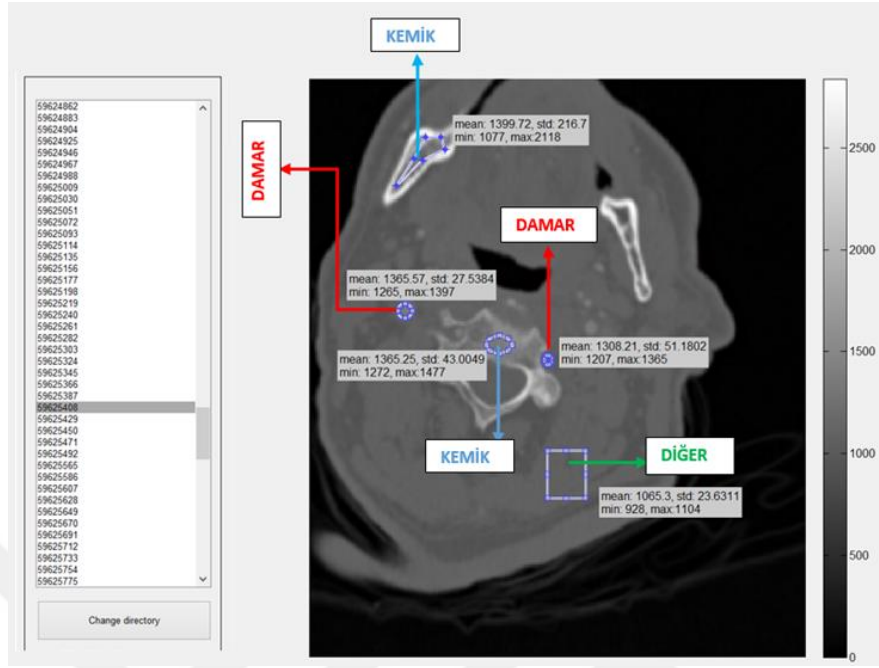
Tersinir yaklaşımla ilk olarak kemiklerin bölütlenmesi ve çıkartılmasından sonra damar bölütlenmesi yapılmaktadır. Tersinir yaklaşımda, öncelikle damar bölütlenmesinde problem olarak kaşımıza çıkan kemik bölgesinin bölütlenmesini ve elimine edilmesi yapılmaktadır. Bu eliminasyon işleminden sonra, damar bölütlenmesi yaparak hedef bölgenin çıkarımı yapılmaktadır. Tersinir yöntemle, kemik ve damar yapılarının bölütlenmesi bölge büyütme (region growing) ve rassal yürüyüş (random walk) bölütleme yöntemleri ile yapılmaktadır [85, 86].

Bahsi geçen yöntemlere geçmeden önce, bu aşamada bölütlemeye bir sonraki aşamalarda kullanılacak lokal doku örneklerinin alınması, dokuların histogramlarının analiz edilmesi ve tohum seçimi için gerekli olacak eşik değerlerinin belirlenmesi işlemleri yapılmıştır.

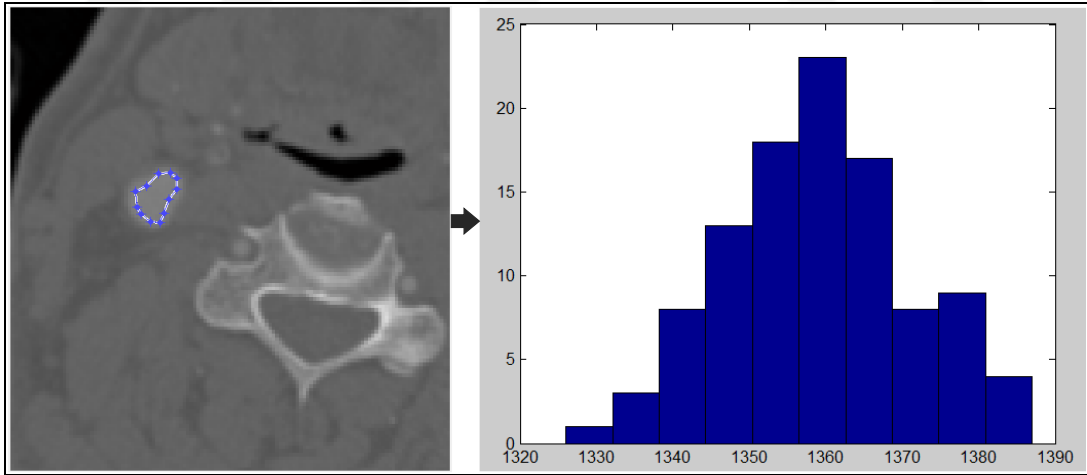
2.3.1. Histogram Analizi

Bir lokal histogram örneği, görüntü içerisinde yatan özel bir ilgi alanı, uzaysal (spatial) alt kümesidir. Başka bir ifadesi; lokal bir bölgedeki piksellerin gri seviyelerine ilişkin bağıl sıklık ölçütüdür. Bir görüntüdeki lokal bölge; kare, daire ya da serbest olarak seçilmiş piksel bölgesidir. Şekil 2.6’da görüldüğü gibi, farklı görüntü ve katmanlardaki çeşitli dokulardan örnekler alınmaktadır. Bu alınan damar bölgesi dokusuna ait lokal bölge histogramı Şekil 2.7’deki gibidir. Bu tez kapsamında dokunun tanınması için bütün dokulardan elle örnekler alınmıştır.


Lokal histogramlar, üç sınıfa ait damar, kemik ve diğer dokulardan (yumuşak doku, organlar vs.) alınan örnekler ile oluşturulmuştur. DICOM görüntülerden manuel olarak serbest şekilde örnek doku alınması yapılmıştır. Örneklerden alınan piksellerin orijinal değerleri damar, kemik ve diğer olmak üzere dinamik dizilerde saklanmıştır. Daha sonra bu dizilerden Şekil 2.8’deki gibi damar, kemik ve diğer dokuların histogram grafikleri çıkarılmıştır.



Şekil 2.6. Lokal doku örneklerinin alınması



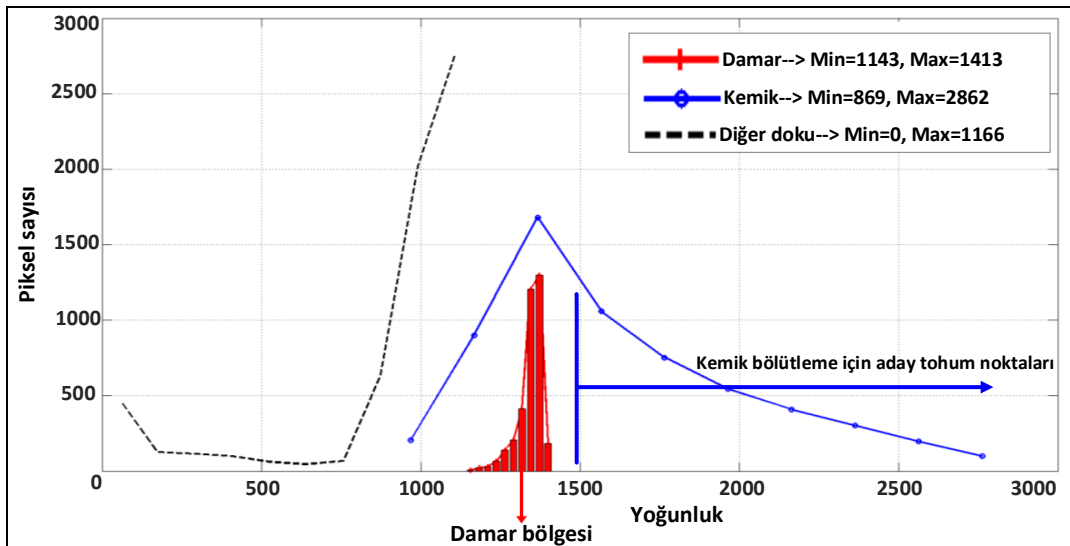
Şekil 2.7. Örnek bir damar bölgesi ve lokal bölge histogramı



Şekil 2.8. Farklı dokulara ait lokal histogramlar

Bu lokal histogramlar, tersinir bölütlemeye için gerek duyulan eşik değerlerinin belirlenmesinde kullanılmaktadır. Ayrıca bu lokal doku örnekleri, ilerleyen bölümde görüntüden dokusal öznelik çıkarımında kullanılmaktadır.

Şekil 2.9'de, tüm veri setinden farklı hastalardan ve farklı katmandaki görüntülerden damar, kemik ve diğer doku örneklerinden yaklaşık olarak 20000 piksel örneği alınarak oluşan lokal görüntü histogramlarından, bölütlemesi yapılacak ilgili damar bölgesi görülmektedir. Şekil 2.9'deki grafiğe bakarak damar bölgenin kemik ve kemiğe benzer dokuların yoğunluk seviyesinin aralığında kaldığını söylemek mümkündür.



Şekil 2.9. Üç farklı dokuya ait lokal histogram grafikleri ve damar bölgesi

2.3.2. OTSU Yöntemini Kullanarak Çoklu Eşikleme

Tezin bu aşamasında, bölütleme işleminde tohum seçimi için gereksinim duyulan tohum eşik seviye değerlerinin belirlenmesi yapılmaktadır. İlk aşamada bu eşik değer aralıkları kullanıcı tarafından Şekil 2.9'deki grafiğe göre deneysel olarak en optimum değerler ile ayarlanmış ve tüm görüntülere uygulanmıştır. Farklı görüntüler, farklı parlaklık seviyelerinde olabileceğinden tüm görüntülere uyacak sabit eşik değerleri sağlıklı sonuç vermeyebilmektedir. Bunun yerine veri setindeki her bir BTA verisi için otomatik olarak eşik değer belirlenmesi üzerine yoğunlaşmıştır. Şekil 2.10 (a)'daki gibi Otsu yöntemi ile iki seviye eşikleme ile tek bir eşik değeri ile tüm görüntüleri damar-kemik olarak ayırmak mümkün değildir. Bir başka ifade, iki-seviye eşikleme ile elde edilen sabit bir T eşik değerini baz alarak bu değer altındaki parlaklık değerini damar ve üstündekileri de kemik tohum noktaları olarak almak mümkün görülmemektedir. Bu bilgi ile görüntüyü ikiden fazla gri seviye grubuna ayırmamız gerektiği anlaşılabilir, Şekil 2.10 (b)'deki gibi çoklu eşiklemeye ihtiyaç duyulmuştur. Bu amaçla yöntemi otomatikleştirmek için, çoklu görüntü eşikleme problemini çözüme Otsu yöntemi buna uyarlanmıştır. Çoklu görüntü eşikleme için, sınıf içi değişimliliği minimize eden ya da sınıflar arası değişimliliği maksimize eden çözümün bulunması ile en uygun eşik değerler belirlenmiştir. Burada yapılan işlem, interaktif (etkileşimli) bölütleme için gerek duyulan tohum noktalarının belirlenmesinde eşik seviye değerlerinin çoklu eşikleme ile belirlenmesidir. Burada yapılan işlem genel eşiklemeye dayalı bölütleme ile karıştırılmamalıdır. Tek başına eşiklemeye dayalı bölütleme BTA görüntülerinden damar bölütlemesinde başarısız olmaktadır. Bunun sebebi, damarlar görünür olduğunda, görüntülerde iskelet (kemik) yapının en yumuşak bölümünü (yumuşak kemik veya kırık dokular) de görünür olmaktadır. Kemik bölütlemesi yapılmak istendiğinde, kemiğin parlak seviyesi düşük bölgelerinde örneğin süngerimsi kemik bölgeleri dahil edilmediğinden kemik bölgelerinde delikli bölgeler oluşmaktadır. Ayrıca, kemik ve damar arasında yakınlık olan yerlerde karışıklıklara sebebiyet vermektedir.

Otomatik eşikleme, görüntü bölütlemesinde önemli bir tekniktir. Otomatik eşiklemenin temel fikri, gri seviye dağılımlarına göre ilgilenilen nesnelere görüntünün arka planından ayırmak için otomatik olarak optimum gri seviye eşik değerini seçmektir. Otomatik eşikleme teknikleri, global ve yerel eşikleme şeklinde başlıca kategorize edilebilir. Global eşikleme, tüm görüntünün histogramından tek bir eşik değeri seçer. Yerel eşikleme,

birden çok eşik değerini seçmek için yerel gri düzey bilgilerini kullanır. Her biri görüntüdeki küçük bir bölge için optimize edilmiştir. Global eşikleme daha basit ve uygulanması daha kolaydır, ancak düzgün parlaklık dağılım gösteren görüntülerde iyi sonuçlar verir. Yerel eşikleme yöntemleri, düzgün parlaklık dağılımı göstermeyen görüntü ile başa çıkabilir, ancak yavaş çalışır. Global eşikleme teknikleri arasında, Otsu yöntemi genel gerçek dünya görüntüleri için en iyi eşikleme yöntemlerinden birisidir. Otsu [87] tarafından önerilen ve görüntü eşikleme alanında yapılan ilk çalışmalarından biri olan ikili eşikleme yöntemi kümelemeye dayalı eşikleme yöntemidir. Görüntünün gri seviye histogramının iki tepeli olmaması, sınıfların çok farklı boyutlarda olması ve görüntülerin değişken ışık koşullarında alınması gibi durumlarda Otsu uygun eşik değerini bulamamaktadır. Görüntü eşikleme alanındaki çalışmalarda sıklıkla kullanılmakta ve referans olarak alınmaktadır [88].

Bu yöntemde; $I(x, y)$ gri-seviyeli bir görüntüyü, (x, y) görüntün uzamsal koordinatlarını, $L = \{0, 1, 2, \dots, L-1\}$ gri-seviyeleri temsil eden pozitif tamsayı kümesini ve $M \times N$ görüntünü boyutlarını temsil eder. Boyutları $M \times N$ olarak tanımlanan bir görüntünün gri seviyelerinin tekrarlanma sıklığı (gri seviye frekansları) f_0, f_1, \dots, f_{L-1} şeklinde tanımlanırsa i . gri seviyenin olasılık dağılımı olarak ifade edilen p_i , denklem (2.2) ile hesaplanır.

$$p_i = \frac{f_i}{M \times N}, \quad \sum_{i=0}^{L-1} f_i = M \times N, \quad i = 0, 1, \dots, L-1 \quad (2.2)$$

Seçilen bir t eşik değerine göre görüntü, arka plan ve nesne olmak üzere iki sınıfa ayrılmaktadır. Denklem (2.3) ve (2.4)'e göre bu iki sınıfın olasılık yoğunlukları hesaplanmaktadır.

$$\omega_o(t) = \sum_{i=0}^t p_i \quad (2.3)$$

$$\omega_B(t) = \sum_{i=t+1}^{L-1} p_i = 1 - \omega_o(t) \quad (2.4)$$

Bu iki sınıfın yoğunluklu ortalama gri seviye değerleri denklem (2.5) ve (2.6) ile ifade edilmektedir.

$$\mu_o(t) = \sum_{i=0}^t i.p_i / \omega_o(t) \quad (2.5)$$

$$\mu_B(t) = \sum_{i=t+1}^{L-1} i.p_i / \omega_B(t) \quad (2.6)$$

Bu yöntemde, en uygun eşik değerinin belirlenmesi arka plan (B) ve nesne (O) piksellerine ilişkin ağırlıklandırılmış toplam sınıf içi varyansların (değişimlerin) minimize edilmesi ile gerçekleşmektedir. Ölçüm değeri ile aritmetik ortalamanın farklarının karelerinin ortalaması, değişinti şeklinde ifade edilir [89]. Nesne ve arka plana ait sınıfların değişimleri sırasıyla denklemler (2.7), (2.8) ile hesaplanır [90].

$$\sigma_o^2(t) = \sum_{i=0}^t p_i.(i - \mu_o(t))^2 / \omega_o \quad (2.7)$$

$$\sigma_B^2(t) = \sum_{i=t+1}^{L-1} p_i.(i - \mu_B(t))^2 / \omega_B \quad (2.8)$$

Bu eşitliklere göre küçültülmesi gereken ağırlıklandırılmış toplam sınıf içi varyans ($\sigma_{snmf_ici}^2$) denklemler (2.9), (2.10) ile tespit edilmektedir [90].

$$\sigma_{snmf_ici}^2(t) = \omega_o(t).\sigma_o^2(t) + \omega_B(t).\sigma_B^2(t) \quad (2.9)$$

$$t = \text{ArgMin}_{t \in G} \sigma_{\text{smf_ici}}^2(t) \quad (2.10)$$

Otsu metodunda, sınıf içi değişiminin minimum, dolayısıyla sınıflar arası değişiminin maksimum olması istenir. Başka bir ifadeyle sınıf için değişimlerin minimize edilmesi aynı zamanda sınıflar arası değişiminin ($\sigma_{\text{smf_ara}}^2(t)$) en büyüklenmesine anlamına geldiğinden bu yöneme ilişkin en uygun eşik değeri (2.11), (2.12), (2.13) denklemleri ile hesaplanmaktadır [90].

$$\sigma_{\text{smf_ara}}^2(t) = \omega_o(t) \cdot [\mu_o(t) - \mu_T]^2 + \omega_B(t) \cdot [\mu_B(t) - \mu_T]^2 \quad (2.11)$$

$$\mu_T = \sum_{i=0}^{L-1} p_i \cdot i \quad (2.12)$$


$$t = \text{ArgMax}_{t \in G} \sigma_{\text{smf_ara}}^2(t) \quad (2.13)$$

Sınıf içi ve sınıflar arası varyansın toplamı, toplam varyansa (σ_T^2) eşittir ve denklem (2.14) ile ifade edilir [90].

$$\sigma_T^2 = \sigma_{\text{smf_ici}}^2(t) + \sigma_{\text{smf_ara}}^2(t) \text{ ve } \sigma_T^2 = \sum_{i=0}^{L-1} p_i \cdot (i - \mu_T)^2 \quad (2.14)$$


Gri seviye bir görüntüyü ikiden fazla gri seviye grubuna ayırma işlemine çoklu eşikleme denir [91]. Görüntün bu sayede bir takım gri seviye grubuyla temsil edildiği söylenebilir. Çoklu görüntü eşikleme; sınıflandırma, bölütleme ve nesne ayırt etmeyi içeren birçok görüntü işleme uygulamasında kullanılan bir tekniktir. Sadece görüntü histogramı temel alarak, gerçek zamanlı sistemlerde kullanılmak amacıyla analiz ve değerlendirme imkanı sunan eşikleme yöntemleri basit ve verimli bir işlemdir [88]. Literatürde görüntü eşikleme amacıyla birçok amaç fonksiyonu geliştirilmiştir [18, 92, 93]. İkili eşikleme amaçlı

geliştirilen Otsu'nun [87] varyans fonksiyonu en popüler olanıdır. Bu yöntemler, görüntünün histogramından çıkarım yapılarak tespit edilmektedir, ayrıca bu yöntemler çoklu görüntü eşikleme amaçlı kullanılmak üzere genişletilebilir niteliktedir [87, 94].



Şekil 2.10. İkili (Otsu) eşik değeri ve çoklu eşik değerleri ile ayırt edilen gri seviye histogramlarının gösterimi [95]

Çoklu görüntü eşikleme, I görüntüsü $M \times N$ adet $L = \{0, 1, 2, \dots, L-1\}$ gri seviyeli piksele sahipse, $K-1$ adet $(t_1 < t_2 < \dots < t_{K-1})$ eşik değerine sahip $T = (t_1, t_2, \dots, t_{K-1})$ eşik değerleri kümesini kullanarak K adet sınıfa (C_1, C_2, \dots, C_K) kümeleme işlemidir. Burada sınırları belirtilen; $t_0 = g_{\min}$ görüntüdeki minimum gri seviyeli pikselin değeri, $t_K = g_{\max}$ ise görüntüdeki maksimum gri seviyeli piksel değeri olarak tanımlanmaktadır ($g_{\min} = 0, g_{\max} = L-1$).



Şekil 2.11. Görüntüdeki gri seviyelerin sınıflara ayırımı [88]

Çoklu görüntü eşikleme problemini çözmeye Otsu yöntemi buna uyarlanabilir. Bu durumda, sınıfların olasılık yoğunlukları denklem (2.3),(2.4)'ten uyarlanarak şu şekilde ifade edilir [88].

$$\omega_k = \sum_{i \in C_k} p_i \quad (2.15)$$

$$\omega_k(t_{k-1}, t_k) = \sum_{i=(t_{k-1}+1)}^{t_k} p_i \quad (2.16)$$

Sınıfların yoğunluklu ortalama gri seviye değerleri, denklem (2.5) ve (2.6)'dan uyarlanarak denklem (2.17) ve (2.18)'deki gibi ifade edilir [88].

$$\mu_k = \sum_{i \in C_k} i \cdot p_i / \omega_k \quad (2.17)$$

$$\mu_k(t_{k-1}, t_k) = \sum_{i=(t_{k-1}+1)}^{t_k} i \cdot p_i / \omega_k(t_{k-1}, t_k) \quad (2.18)$$

Sınıflara ait değişimler (varyans) denklem (2.7) ve (2.8)'den uyarlanarak denklem (2.19) ve (2.20)'ye göre hesaplanır [88].

$$\sigma_k^2 = \sum_{i \in C_k} p_i \cdot (i - \mu_k)^2 / \omega_k \quad (2.19)$$

$$\sigma_k^2(t_{k-1}, t_k) = \sum_{i=(t_{k-1}+1)}^{t_k} p_i \cdot (i - \mu_k(t_{k-1}, t_k))^2 / \omega_k(t_{k-1}, t_k) \quad (2.20)$$

Sınıflar içi ve sınıflar arası değişimler sırasıyla denklem (2.9) ve (2.11) dikkate alınarak bulunur [88].

$$\sigma^2_{smf_ici}(T) = \sum_{k=1}^K \omega_k \cdot \sigma_k^2 \quad (2.21)$$

$$\sigma^2_{smf_ara}(T) = \sum_{k=1}^K \omega_k \cdot (\mu_k - \mu_T)^2 \quad (2.22)$$

Çoklu görüntü eşikleme için, sınıf içi varyansı en küçülten ya da sınıflar arası varyansı en büyükleen çözümün bulunması ile en uygun eşik değerler belirlenir.

$$[t_1^*, t_2^*, \dots, t_{K-1}^*] = ArgMin \sigma^2_{smf_ici}(t) = ArgMax \sigma^2_{smf_ara}(t) \quad (2.23)$$

Çoklu seviye eşikleme ile gri-seviye görüntü ikiden fazla gri seviye grubuna ayrılmıştır. Tüm görüntülere çoklu-seviye eşikleme uygulanmasıyla, farklı seviyelerde elde edilen eşik değer sınırlarının ortalama değerleri aşağıdaki gibidir.

Tablo 2.1. Tohum seçimi için çoklu seviye eşikleme seviye grupları ve ortalama aralıkları

Seviye	Eşik değer aralıkları			
MLEVEL=2	T ₁			
	543			
MLEVEL=3	T ₁	T ₂		
	532	1485		
MLEVEL=4	T ₁	T ₂	T ₃	
	521	1219	1840	
MLEVEL=5	T ₁	T₂ = (T_{damar})	T₃ = (T_{kemik})	T ₄
	521	1164	1540	2072

Veri setindeki tüm görüntülere çoklu-seviye eşikleme uygulanmasıyla, farklı seviyelerden elde edilen eşik değer sınırlarının tüm BTA görüntülerine göre ortalama eşik değerleri Tablo 2.1.'deki gibidir. Bu tablodaki değerler her BTA verisi için çalışma uzayındaki görüntülere göre değişkenlik gösterebilir. Tohumlandırmada tüm veri setlerinde

sabit olarak bu eşik değerleri baz alınmamaktadır. Bu tablodaki değerler, 15 BTA verisine göre ortalama eşik değerlerini göstermektedir.

Çoklu seviye eşik değer sonucuna göre, damar ve yumuşak kemik (soft bone) bir sınıf, ve yoğun kemik (hard-bones) bir sınıf olarak düşünüldüğünde bu gri seviye ayırımı en optimum şekilde beş seviye grubuna karşılık gelen T_2, T_3 değerleri ile elde edilmiştir. Tablo 2.1'deki gibi her görüntü için ayrı ayrı global eşik değer belirlenmesi, beş seviye grubuna ayrıldığında elde edilen T_2, T_3 değerlerine göre belirlenmiştir. Bu aralıklar Şekil 2.9'daki grafik gibi tohumlandırma için optimum eşik değerlerini doğrular şekildedir. Tablo 2.1'den elde edilen T_3 eşik değeri üzerindeki noktalar $TohumNoktası_{kemik} > T_{kemik}$, kemik bölütleme için tohum noktaları olabilmektedir. Benzer şekilde damar bölütlemesinde $T_{damar} < TohumNoktası_{Damar} < T_{kemik}$ aralığındaki noktalar damar için tohum noktaları olabilmektedir. Otomatik bölütlemeye Otsu'nun çoklu seviye grubuna karşılık gelen eşik değerlerine göre tohumlandırılmalı bölütleme yöntemleri çalıştırılmaktadır.

2.3.3. Bölütleme Yöntemleri

Bu tez kapsamında, görüntülerdeki damar ve kemiğin dokusal yapısından ötürü etkileşimli görüntü bölütleme yöntemlerinden tohumlandırılmalı ve istatistiksel yaklaşımla bölge dahil etme yöntemleri tercih edilmiştir.

2.3.3.1. Bölge Büyütme Yöntemi

Adams ve Bischof'un [96] görüntü bölütlemesi için önerdiği tohumlu bölge büyütme algoritması, güçlü ve yürütmesi kolay bir yöntemdir. Aynı benzerlik kriterini sağlayan piksellerin oluşturduğu gruba bölge denir. Kavram olarak bölge büyütme, ön tanımlı benzerlik kriterine göre geniş bölgeleri alt bölgelere veya piksellere gruplandırma işlemidir.

Algoritma, her biri ayrı bir bölgeye karşılık gelen bir dizi tohum noktası ile başlar. Tohum noktaları daha sonra benzerlik kriterine dayanarak komşularıyla karşılaştırılır. Bölge büyütme yönteminin temel mantığı, bir ya da daha fazla tohum noktasının belirlenmesi ile bu tohumlarla benzer istatistiğe sahip komşu piksellerin bir araya gelip bir bölge oluşturmasıdır. Bölge büyütme tekniği görüntü bölütleme için ortalama yoğunluk (intensity)

ve standart sapma tekniğini kullanır. Bölge büyütme yönteminde tohum noktalarının değişmesinde en çok kullanılan yöntem, denklem (2.24)'e göre seçilen tohumun komşularıyla karşılaştırılarak düzgün dağılıma sahip olup olmadıkları belirli bir eşik değeri ile kontrol edilmektedir. Bu eşitliğe göre, eşik değeri kadar farklılık gösteren pikseller yeni bölgeye dahil edilir. Bu pikselin bölgeye dahil edilmesiyle bölge ortalaması yeniden hesaplanmaktadır. Bu yeni bulunan bölge ortalamasına göre, bundan sonraki karşılaştırma yapılır. Bu süreç bölgeye yeni piksel eklenmeyene kadar iteratif şekilde devam eder. Aradaki fark belirtilen bir eşikten azsa, piksel o bölgeye aittir ve etiketlenir. Aksi takdirde, piksel etiketlenmez ve atlanır. Bu eşitlikte, $Img(i, j)_{seg}$ bölütleme sonucunu, $Img_{org}(i, j)$ şu anki mevcut pikselin yoğunluk seviyesini, μ_R mevcut bölütlenmiş piksellerin ortalama yoğunluk değerini ve Δ referans eşik değerini temsil eder.

$$Img(i, j)_{seg} = \begin{cases} Kemik, & \text{Eğer } |Img_{org}(i, j) - \mu_R| \leq \Delta \\ Kemik değil & \text{Değilse} \end{cases} \quad (2.24)$$

Benzerlik kriteri seçimi görüntüden elde edilebilen veri çeşidine bağlı olarak değişebilmektedir. Benzerlik kriterleri; ortalama yoğunluk, varyans, renk, doku, hareket, şekil gibi özelliklerin homojenitesine bakılarak belirlenebilir. Bölge büyütme metodunda benzerlik kriterine göre bir eşik değeri seçilmesine ihtiyaç duyulmaktadır. Eşik değeri, görüntü bilgisinden çıkarılmaktadır. Bölge büyütme bir eşik kriterine ve bir ya da daha fazla tohum noktasına gereksinim duyar. Tohum pikselinin komşu pikselleriyle arasındaki farka bakılır. Fark değeri bu eşik değerinin altında bir değere sahip pikseller tohum pikseliyle aynı bölgeye dahil edilir. Bölge büyütme metodunda kritik nokta tohum noktalarını ve eşik değerinin uygun seçilmesidir.

Bir görüntünün varyansı, görüntü içerisindeki heterojenlik (değişirlik) ile alakalıdır. Pikseller homojen dağıldıklarında, varyansın değeri küçüktür. Buna karşılık piksel yoğunluğu çok farklılık gösteren bloklarda varyans büyük değerlere sahiptir. Dolayısıyla kemik dokunun bütün olduğu yerde içerisinde çok yüksek parlaklık seviye (intensity) değerine sahip pikseller olduğu gibi süngerimsi yapıdan ötürü kemik bölgesi içerisinde düşük parlaklık seviyesine sahip piksellerde bulunabilmektedir. İlk aşamada eşik değerleri deneysel olarak belirlenmiştir. Tersinir yöntemle öncelikle kemik dokunun bölütlemesini

yaparken bu eşik değeri yüksek (örnek: $\Delta \geq 50$) alınmıştır, ancak damar bölütlemesi yaparken damar bölgesi daha homojen yapıda olduğu için komşu pikseller arası değerler birbirine çok yakın olduğu için eşik değeri düşük değerde ($5 > \Delta < 10$) alındı. Bir sonraki aşamada doku tabanlı bölge büyütme aşamasında bu eşik değerinin otomatikleştirilmesi üzerine bu tez kapsamında çalışma yapılmıştır. Genel bir bölge büyütme yönteminin algoritmik adımları aşağıdaki gibidir

Adım 1: Tohum noktalarının ilklenmesi.

Adım 2: Verilen bir tohum noktası için,

- Tohum noktasını bölge etiketi olarak ata.
- Bölge ortalamasını, tohum noktasındaki piksel yoğunluğuna eşit olarak başlat.
- Tohum noktasının komşularını hesapla ve kontrol edilecek komşu piksel adreslerini saklayan komşu matrisinde tut.

Adım 3: Komşu matrisinde saklanan her piksel için.

- Eğer piksel etiketlenmemiş ve benzerlik kriteri karşılanmışsa,
 - Pikseli ilgili bölgeye etiketle.
 - Karşılık gelen yeni bölgenin ortalamasını hesapla.
 - Piksel komşularını hesapla ve etiketlenmemişse bunları komşu matrisinde sakla.
- Aksi takdirde,
 - Pikseli atla ve bir sonraki komşu pikselini seç.
- Komşu listesindeki tüm pikseller kontrol edilene kadar 3. adımı tekrarlayın.
- Bölge boyutu çok küçükse, bölge piksellerini etiketlenmemiş olarak bırak.


Adım 4: Bir sonraki tohum noktasını seç ve sonraki bölge için 2. adımı tekrarla.

Adım 5: Tüm pikseller etiketlenmemişse, yalnızca etiketlenmemiş pikselleri kullanarak tohum noktalarını tekrar hesapla.

Adım 6: Görüntünün tüm pikselleri karşılık gelen bölgelere etiketlenene kadar işlemi tekrarla. Bu şekilde, görüntü çeşitli bölümlere ayrılmıştır.

Bölge büyütme yönteminde, bölgenin bağlantısı dikkate alınmadığı takdirde, tek başına yoğunluk tabanlı eşikleme ile aynı bölgede benzer özellik gösteren bölgeleri birbirinden ayırmak mümkün değildir. İki bitişik özellik piksel bağlı olarak düşünülür ve bu nedenle aynı bölgeye ait olarak kabul edilir. Bağlantılılığın iki boyutta iki mümkün tanımı

mevcuttur; 4-bağlantılık ve 8-bağlantılık. Bu bağlamda pikselin daha fazla komşuları ile olan piksel benzerliğine bakmak için genellikle 8-bağlantılık tercih edilmiştir. Her tohum noktasının sekiz komşu pikseli incelenir ve eşik ölçütleri karşılayan her komşu piksel özellik kümesine ilave edilir ve sırayla bu yeni bir tohum noktası olur. Üç boyutta bu komşuluk 6-bağlantılık ve 26-bağlantılık şeklinde tercih edilmektedir. Bitişik bölgeler için, bölge büyütme uygun bir bölütleme yöntemidir.



Şekil 2.12. İki veya üç boyut için komşuluk gösterimi [97]

2.3.3.1.1. Tohumlandırılmalı Bölge Büyütme

Bölge büyütme bir ya da daha fazla tohum noktasına gereksinim duymaktadır. Burada bölütleme için gerekli tohum noktaları, her bir BTA görüntüsünün çalışma uzayında bölütlenecek dilimlerinin çoklu seviye eşik değer sonucuna göre otomatik olarak belirlenmektedir. Başka bir ifade ile bölge büyütme için gerekli tohum noktalarının manuel olarak işaretlenmesi ya da tohum noktalarının önceden uzaysal noktalarının belirtilmesi yapılmamaktadır. Her bir görüntünün dilimlerinden elde edilen eşik değerlerine göre ortalama bir global eşik değer aralığı belirlenmektedir. Her bir görüntü için otomatik belirlenen bu eşik değer aralıklarına göre bölge bölütleme için gerekli tohum noktaları belirlenebilmektedir. Damar ve yumuşak kemik (soft bone) bir sınıf, ve yoğun kemik (hard-bones) bir sınıf olarak düşünüldüğünde bu aralıklara göre bölge büyütme için tohum noktaları belirlenebilmektedir. Başka bir ifade ile, $TohumNoktası_{Kemik} > T_{kemik}$ şartını sağlayan görüntüdeki tüm noktalar kemik bölütlemesi için tohum noktaları olarak kabul edilmektedir. Bu noktalardan başlayarak görüntüden kemik çıkarımı için bölge büyütme yöntemi çalışmaktadır. Benzer şekilde, kemik çıkarımı sonrasında

$T_{damar} < TohumNoktası_{Damar} < T_{kemik}$ aralığında görüntüde kalan tüm noktalar damar bölütlemesi için tohum noktaları olarak kabul edilmektedir.

2.3.3.1.2. Doku Tabanlı Bölge Büyütme


Bu tez kapsamında dokusal tabanlı benzerlik kriteri göz önünde bulundurularak, eşik değerinin otomatik seçimi üzerine çalışılmıştır. Bir bölge büyütme algoritması, bir pikselin bölgeye eklenip eklenmeyeceğini belirlemek için bir homojenlik kriteri gerektirir. Her bir pikseli karakterize etmek için yerel doku tanımlayıcıları kullanılmıştır. Wu ve diğerleri [98], organ bölütlemesi için doku tabanlı bölütlemeyi kullanmışlardır. Benzer şekilde, Gambino ve diğerleri [99] de, otomatik karaciğer bölütleme çalışmalarında doku tabanlı bölge büyütme yöntemini kullanmışlardır. Bu tez kapsamında, Gambino ve diğerleri'nin [99] çalışması karotid arter bölütlemesine uyarlanmış ve bazı parametreler değiştirilmiştir. Örneğin, eş oluşum matris hesabında mevcut çalışma 13 yönü esas alırken bu çalışmada 26 yön esas alınmıştır. Mevcut çalışmada yerel doku tanımlamada Haralick'in 7 özneliği kullanılırken damar-kemik dokusunun daha fazla ayırt edici özelliğini çıkarmak için Haralick'in 14 özneliği kullanıldı. Dolayısıyla, vokselde ortalanmış hacmin yerel dokusunu tanımlayan daha büyük boyutlu bir vektör ile hesaplama yapılmıştır. Mevcut çalışmada, tohum vokselin komşuluğunda 6-bağlantılık kullanılırken, bu çalışmada 26-bağlantılık ile komşu vokseller bölütleme sürecinde işleme alınmaktadır. Bu aşamada, bir aday vokseli bir tohum nokta ile kıyaslaması yapılırken voksele ait yerel dokum tanımlayıcısından oluşan öznelik vektörü tohum nokta ile kıyaslanmaktadır. Burada kıyaslama işlemi iki öznelik vektörü arasındaki uzaklığa göre, önceden tanımlı bir eşik değeri ile yapılmaktadır. Bu önceden tanımlı eşik değeri ise, alınan doku örneklerine otomatik olarak belirlenmektedir. Daha fazla ayrıntı ilerleyen başlıkta otomatik eşik değer seçimi başlığı altında anlatılmaktadır.

İki dokusal örüntünün eşleştirilmesi, aralarındaki benzerliğinin / farklılığının önceden belirlenmiş bir eşik değerinden az ya da fazla olmasının kontrolü ile gerçekleştirilir. Bu amaçla kullanılan en yaygın yaklaşım ise iki örüntü (vektör) arasındaki uzaklığın hesaplanmasıdır. Bu aşamada, uygulaması basit ve hızlı çalışmasından ötürü Öklid uzaklığı tercih edildi. Vektörler arasındaki uzaklık ölçüm yöntemi olarak hangisinin daha yüksek

başarıma sahip olabileceğine ait bir ön bilgi bulunmamaktadır [100]. Öklid uzaklığı vektörler arasındaki uzaklık ölçümünün kullanıldığı çalışmalarda en çok tercih edilen uzaklıktır [101-103]. Görüntü sınıflandırma ve görüntü tanıma gibi problemler söz konusu olduğunda çalışmalar Mahalanobis mesafesinin genellikle daha başarılı sonuçlar verdiğini göstermektedir. Mahalanobis ölçüm yönteminin bu başarısına karşın ön işlem olarak kovaryans matrisinin hesaplanması nedeniyle diğer mesafe ölçüm yöntemlerine göre hesaplama süresi daha fazladır [100]. Doku tabanlı bölge büyütme çalışmalarından, Gambino ve diğerleri [99] Öklid uzaklığını Backman ve diğerleri [104] ise Mahalanobis uzaklığını kullanmıştır. Bu tez kapsamında, uygulanan yöntemin ara aşamalarındaki işlem sürelerinin uzunluğundan ötürü, bu aşamada doku tanımlayıcısını içeren vektörler arası uzaklık hesaplaması tercihi daha az hesaplama süresini sağlayan Öklid uzaklığı yönünde olmuştur. Burada, Öklid uzaklığını kullanarak bir aday pikselin tanımlayıcıları tohum nokta olanlarla kıyaslanmaktadır.

İki öznitelik vektörü $p = (p_1, p_2, \dots, p_n)$ ve $q = (q_1, q_2, \dots, q_n)$ arasındaki Öklid uzaklığı eşitlik (2.25) ile hesaplanmaktadır.


$$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (2.25)$$



Şekil 2.13. Aday piksel merkezli 5x5x5 alt hacim gösterimi

Doku tanımlamak için, aday piksel merkezli 5x5x5 bir alt hacim üzerinde hesaplanan Gri Seviye Birlikte Görülme Matrisine (GSBGM) dayanan istatistiksel yaklaşım kullanılmıştır. Bir görüntünün ikinci dereceden istatistiklerini tanımlayan bir eş oluşum matrisi, NxN matrisi olarak tanımlanır; burada N, görüntünün gri seviyelerinin sayısıdır. a_{ij} ögesi, ilk ögesi i gri seviyesi olan, ikincisi j gri seviyesine sahip olan piksel çiftlerinin oluşma sayısı olarak tanımlanır.

Bir eş-oluşum matrisi hesaplamada piksel çiftlerini tanımlamak için "yön uzaklık çiftleri" yaklaşımı kullanılır. Bu yaklaşımda, bir konum operatörü $P(d, \theta)$ tanımlanır. $P(d, \theta)$, uzaklığı d ve yönü θ olan hacimde iki piksel seçmek için bir θ yönünü ve d bir uzaklığı tanımlar. Konum operatörü tarafından tanımlanan çiftler, eş-oluşum matrisinin girişlerini oluşturmak için dikkate alınır. Bu aşamada, uzaklık $d = 1$ ve 26 üç boyutlu yönlerle 26 konum operatörünü tanımlanmıştır.

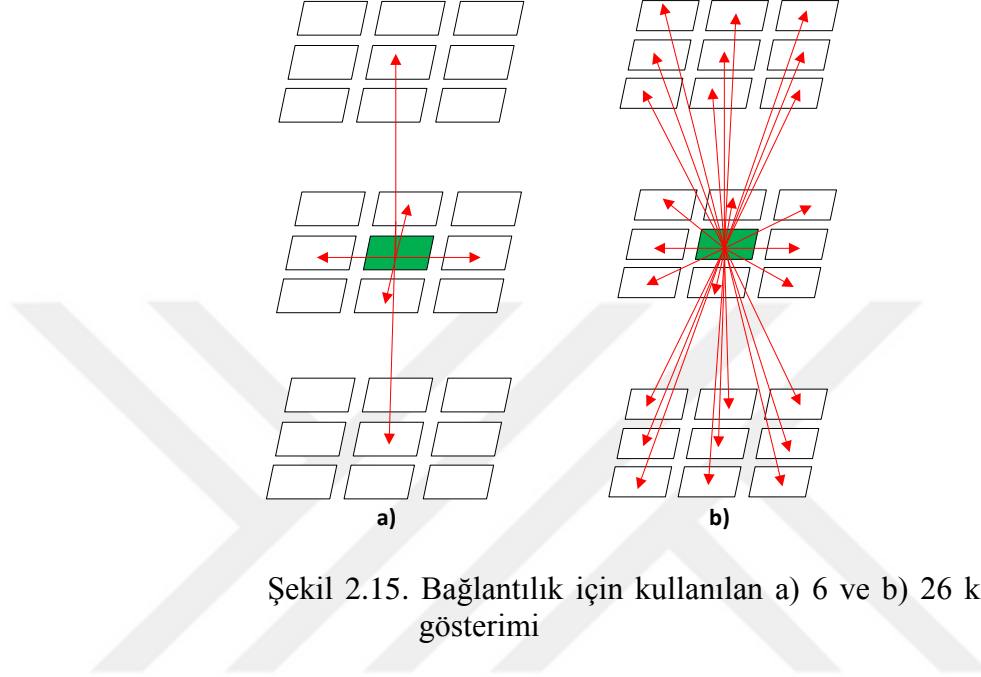


Şekil 2.14. Eş-oluşum matrislerinin hesaplanması için kullanılan 26 yönün gösterimi

Eş-oluşum matrislerinin hesaplamasından sonra, birkaç doku öznelikleri çıkarılmıştır. Kullanılan öznelıklar; enerji, entropi, karışıklık (contrast), homojenlik, korelasyon, çift-toplamların ortalaması (mean of pair-sums), çift-toplamların varyansı (variance of pair-sums)'dır. 7 öznelik ve 26 eş-oluşum matrisi kullandığımız için, işlenmiş vokselde ortalanmış hacmin yerel dokusunu tanımlayan 182 eleman vektörü elde edilmiştir.

Bir tohum noktasından başlayarak, tohumlu bölge büyütme algoritması tohum noktasına bağlı vokselleri ve homojenlik kriterini doğrularak bir bölgeyi bölütler. Daha

önce belirtildiği gibi öklid mesafesi homojenlik kriteri olarak kullanılırken, 6 veya 26 bağlanabilirlik ile iki vokselin komşu olup olmadığını belirlemek için kullanılır.



Şekil 2.15. Bağlantılık için kullanılan a) 6 ve b) 26 komşuluğun gösterimi

Bir tohum noktasından başlayarak, tohumlu bölge büyütme algoritması tohum noktasına bağlı vokselleri ve homojenlik kriterini doğrularak bir bölgeyi bölütler. Daha önce belirtildiği gibi Öklid mesafesi homojenlik kriteri olarak kullanılırken, 6 veya 26 bağlanabilirlik ile iki vokselin komşu olup olmadığını belirlemek için kullanılmaktadır.

Tohum vokselinden başlayarak, doku özellikleri arasındaki Euclidean Mesafesi önceden tanımlanmış bir eşik altındaysa, her 6 yada 26 komşu voksel iteratif şekilde hacime dahil edilir. Süreç, hacime yeni piksel eklenemediği veya maksimum iterasyon sayısına ulaşıncaya kadar tekrarlanmaktadır.

2.3.3.1.3. Otomatik Eşik Değer Seçimi

Yüksek eşik değeri aşırı seçiciliği (selective), düşük eşik değeri aşırı hassasiyetli (sensitive) artırdığı için, eşik değeri seçimi voksel büyütme prosedürü için kritik bir konudur. Eşik değeri, tohum komşularının doku özelliklerinin istatistiksel dağılımını analiz ederek seçilmiştir. Tohum noktasını merkez oluşturan 10000 elipsoidal numune alma bölgesi

düşünülmüştür. Doku özelliklerinin modellenmesinde gri seviye değerleri kullanılır. Yöntem iki adımdan oluşur: İlk aşamada, çok boyutlu Gaussian karışım parametreleri, dokuları farklı ve farklı boyutlarda bölgesel doku örnekleriyle modellemek suretiyle elde edilir. Böylece, doku çok boyutlu bir Gaussian karışım modeli ile modellenir ve belirli bir ortalama ve varyans bileşenleri ile ifade edilir. Her Gaussian karışım bileşeni, bir doku örneğinin ortalamasını ve varyansını temsil eder. Bu sayede, farklı dokuları çok boyutlu Gauss karışımları olarak modellenmektedir. Beklenen değeri en büyükleme yöntemi ile çok boyutlu Gauss karışım modeli parametreleri döngülü bir şekilde belirlenmektedir. İkinci aşamada, ilk aşamada öğrenilen karışım parametrelerine göre, en küçük ortalama değere sahip olan bileşen seçilir ve eşik değeri (T) değeri hesaplanır.

Literatürde sıklıkla kullanılan sürekli tek değişkenli Gauss olasılık yoğunluk fonksiyonu denklem (2.26)'daki gibidir. $p(x)$, σ ve μ sırasıyla, x değişkeninin olasılık yoğunluk fonksiyonu, x değişkeninin varyansı ve ortalamasıdır.

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right) \quad (2.26)$$

Denklem (2.26)'de verilen Gauss dağılım fonksiyonunun beklenen değeri ve varyans hesabı denklem (2.27) de verilmiştir. Böylelikle x değişkeni, ortalaması μ ve varyansı σ^2 olan normal bir dağılıma sahip olup $x \sim N(\mu, \sigma^2)$ şeklinde gösterilir.

$$\begin{aligned} \mu = E(x) &= \int_{-\infty}^{\infty} xp(x)dx \\ \sigma^2 = Var(x) &= \int_{-\infty}^{\infty} (x - \mu)^2 p(x)dx \end{aligned} \quad (2.27)$$

Çok değişkenli Gauss dağılım yoğunluk fonksiyonunun d boyutta genel gösterimi denklem (2.28)'de verilmiştir.

$$p(x) = \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} \exp \left[(x - \mu)^t \Sigma^{-1} (x - \mu) \right] \quad (2.28)$$

μ , d boyutlu ortalama vektörü; Σ , $d \times d$ boyutunda ortak varyans (kovaryans) matrisi, $|\Sigma|$ ve Σ^{-1} sırasıyla, Σ 'nin determinanı ve ters matrisidir.

$$\mu = [\mu_1 \mu_2 \mu_3 \dots \mu_d] \quad (2.29)$$

$$\Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1d} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2d} \\ \dots & \dots & \dots & \dots \\ \sigma_{d1} & \dots & \dots & \sigma_{dd} \end{bmatrix}_{d \times d} \quad (2.30)$$

Örneklenmiş voksellerin, damar vokselleri ve damar dışı vokseller olarak iki sınıfa ait olduğu varsayılmaktadır. Ayrıca, tohum noktasından bir sınıftaki voksellere olan uzaklıkların normal olarak dağıldığı varsayılmaktadır. Böylece, uzaklıklar bir Gaussian karışım dağılımı ile modellenir. Bölgesel örnekler, çok sayıda Gaussian olasılık dağılımının bir bileşeni olan çok değişkenli bir Gaussian karışım modeli ile modellenmiştir. Her bir gauss yoğunluğu, karışımın bir bileşenidir ve kendi ortalama μ_k ve kovaryans Σ_k 'na sahiptir. Çok değişkenli Gauss karışımının K bileşenli modeli denklem (2.31)'de verilmiştir. Burada α_k her bir bileşenin önsel olasılık değeridir.

$$p(x) = \sum_{k=1}^K \frac{1}{(2\pi)^{d/2} |\Sigma_k|^{1/2}} \exp \left[(x - \mu_k)^t \Sigma_k^{-1} (x - \mu_k) \right] \alpha_k \quad (2.31)$$

Çok değişkenli Gaussian karışım modelinin parametreleri Beklenen Değeri En Büyükleme (BDEB) algoritması ile elde edilir. BDEB algoritması genel ifadesi ile, tam olmayan bir veri kümesi için, bilinen bir dağılımdan en büyük olabilirlik (likelihood) kestirim parametrelerini bulmayı hedeflemektedir. BDEB algoritması iki aşamadan

oluşmaktadır; ilk aşamada beklenen değer hesaplanır ve ikinci aşamada logaritmik olabilirlik kestirimini en büyükleyen parametre kümesi bulunmaktadır. BDEB algoritmasının matematiksel ifadeleri aşağıdaki gibidir:

P adet bölge numunesi varlığında, bölgeler $Z = \{Z_i\}_{i=1}^P$ şeklinde gösterilmektedir. Bu bölgelerden parametreleri m_k ile temsil edilen k değerleri ($k = 1 \dots K$) için çok değişkenli Gauss bileşeni hesaplanır. Her bir m_k bileşeni, bir varyans matrisi w_k ve bir ortalama değer vektörü μ_k ile tanımlanmaktadır. Çok değişkenli Gauss karışım modeli, K adet çok değişkenli Gauss bileşeni ile $M = \{m_k\}_{k=1}^K$ şeklinde ifade edilir. Ortalama değer vektörü μ_k ve bir varyans matrisi w_k ile ifade edilen her bir Gauss karışım bileşeni m_k , Z içindeki bir bölge örneğini temsil eder. Bu sayede, verilen k . Gauss bileşeni m_k için Z_i bölgesinin olasılığı denklem (2.32)'den hesaplanır.

$$p(Z_i | \mu_k, \psi) = N(Z_i; \mu_k, w_k) \quad (2.32)$$

Burada $\psi = \{\alpha_k, \mu_k, w_k\}_{k=1}^K$ çok değişkenli Gauss karışımının parametre kümesidir. k . Gauss bileşeninin önsel olasılığı α_k ile ifade edilir. Önsel olasılıkların toplamı $\sum_{k=1}^K \alpha_k = 1$ olarak alınır. Hiçbir Gauss bileşeninin parametreleri bilinmemektedir bundan ötürü, verilen parametre kümesi için Z 'nin koşullu olasılığı her bir Z_i için tüm Gauss bileşenleri ile denklem (2.33) ile hesaplanır.

$$p(Z_i | K, \psi) = \sum_{k=1}^K p(Z_i | m_k, \psi) \alpha_k \quad (2.33)$$

Sonraki aşamada, bütün küme için gerçekleştirilen log-olasılık (log-likelihood) ifadesinin en iyilemesi denklem (2.34)'da verilmiştir.

$$\log p(Z | K, \psi) = \sum_{i=1}^P \log(p(Z_i | m_k, \psi)) \alpha_k \quad (2.34)$$

Bu aşamada ψ parametre kümesi için en büyük olabilirlik kestirimi BDEB algoritması ile eldeki bölgeleri kullanarak hesaplanmaktadır. Bu şekilde denklem, denklem (2.35)'deki hale gelir.

$$\psi = \arg \max \log(L(\psi | Z)) = \arg \max \log p(Z_i | K, \psi) \quad (2.35)$$

Bu aşamadan sonra, algoritma dögüsel olarak beklenen deęer hesabı ve en büyükleme adımlarını işlemektedir. İlk adımda ψ parametre kümesi için ilk deęerlerini tahmin ederek her bir Z_i bölgesinin Gauss karışım bileşenlerine atanması gerçekleştirilir. Sonrasında ise her bir t . ara adımda ψ^t parametre grubu hesaplanır. k .Gauss bileşeni verilen Z_i için olabilirliği Bayes kuralı kullanılarak denklem (2.36)'deki gibi hesaplanır.

$$p(m_k | Z_i, \psi^{(t)}) = \frac{p(Z_i | m_k, \psi^{(t)})\alpha_k}{\sum_{k=1}^K p(Z_i | m_k, \psi^{(t)})\alpha_k} \quad (2.36)$$

Log-olabilirliği en büyükleyerek ψ^t parametre grubu, en büyükleme aşamasında denklem (2.37) ile güncellenir.

$$\begin{aligned} \bar{\alpha}_k &= \frac{1}{P} p(m_k | Z_i, \psi^{(t)}) \\ \bar{\mu}_k &= \frac{\sum_i^P Z_i p(m_k | Z_i, \psi^{(t)})}{p(m_k | Z_i, \psi^{(t)})} \\ \bar{w}_k &= \frac{\sum_i^P (Z_i - \bar{\mu}_k)(Z_i - \bar{\mu}_k)^T p(m_k | Z_i, \psi^{(t)})}{\sum_i^P p(m_k | Z_i, \psi^{(t)})} \end{aligned} \quad (2.37)$$

Kestirimler kararlı hale gelene kadar, beklenen deęer ve en büyükleme adımları BDEB algoritması ile dögüsel bir şekilde tekrar tekrar işletilir. Bu işlem sonunda, çok boyutlu Gauss karışım parametreleri hesaplanmış olmaktadır.


Bu hesaplanan karışım parametrelerine göre, en küçük ortalama değere sahip olan bileşen seçilir ve eşik değeri (T) değeri denklem (2.38) ile hesaplanır [99].

$$T = \mu_1 + \alpha * \sigma_1 \quad (2.38)$$

burada μ_1 ve σ_1 en düşük ortalama değeri olan Gauss parametreleridir ve α (2.39)'daki gibi tanımlanan bir ayarlama parametresidir:

$$\alpha = \begin{cases} 2 & \text{if } \sigma_1^2 < 1 \\ 1 & \text{otherwise} \end{cases} \quad (2.39)$$

Bölge büyütme yöntemi ile Şekil 2.16'de örnek bir BTA'da tohum noktalarının ilklendirilmesi ile damar bölütlemelerinin gerçekleştirildiği görülmektedir. Damar bölgesinin kemik ve kemiğe benzer doku yoğunluğu ile karışmadığı bölgelerde, doğru tohumlandırma ile damarların bölütlendiği görülmüştür.



Şekil 2.16. Bölge büyütme yöntemi ile bir ya da daha fazla tohum noktası ile BTA'da damar bölütlemesi

2.3.3.2. Rassal Yürüyüş Yöntemi

Grady [105] tarafından önerilen rassal yürüyüş bölütlemesi, kısa bir süre önce bir dizi uygulamada kullanılmış popüler bir algoritmadır. Bu yöntemde, görüntü, grafik olarak modellenmiştir. Düğümler, görüntüdeki pikselleri temsil eder ve pikseller, komşu piksellere benzerliğe göre ağırlıklandırılmış kenarlar ile diğer düğümlere bağlanır. Etkileşimli görüntü bölütleme yöntemi olduğundan, kullanıcının başlangıç tohum noktalarını belirtmesine ihtiyaç duyar. Bu tohum noktaları genellikle ön ve arka plan olarak iki sınıfa bölünür, ayrıca daha fazla sınıfa ait tohum noktaları da belirtilebilir. Bu yöntem için tohum noktaları, bölge büyütme yönteminde olduğu gibi kemik ve damar için otomatik olarak belirlenen çoklu seviye eşik değer aralıklarından seçilmektedir.

Kullanıcı tanımlı tohum noktalarına etiketli pikseller denir. Görüntüdeki diğer pikseller etiketlenmemiş pikseller olarak adlandırılır ve hayali bir rastgele yürüyüşçü bu etiketlenmemiş piksellerden işlemeye devam eder. Kullanıcı orijinal görüntüyü tohumlandırdıktan sonra, etiketlenmemiş piksellerden rastgele bir yürüyüşçü çıkardığı varsayılır. Bu yürüyüşçü, kenar ağırlığına bağlı olarak diğer piksellere hareket eder. Bu piksellere ilk varış olasılığı, tüm etiketli pikseller için rastgele yürüyüş boyunca hesaplanır. Algoritma, rasgele yürüyücünün en yüksek olasılıkla tohuma (etiketlenmiş piksele) ulaşmasına göre pikselleri ön plan veya arka plan olarak etiketler. Etiketsiz bir pikselden bırakılan rasgele yürüyücünün en yüksek olasılıkla (hesaplanan olasılıklara göre) varacağı ilk etiketlenmiş piksel (tohum) hangisi ise bu piksel ile aynı etiket değerine sahip olmaktadır.

Belirli bir tohumdan gelen rastgele bir yürüyücünün olasılığı olan L , grafik Laplacian matrisi kullanılarak hesaplanabilir. Düğümler V_i olarak etiketlenir ve kenarları birleştiren i ve j düğümleri, E_{ij} olarak adlandırılır. Kenar ağırlıkları w_{ij} ile ifade edilir ve belirli bir düğümün (piksel) yoğunluğu g_i ile belirtilir. Bu nedenle, w_{ij} (2.40) ile hesaplanabilir [105]:

$$\omega_{ij} = \exp(-\beta(g_i - g_j)^2) \quad (2.40)$$

Denklem (2.40)'da, β bir sabittir. Amaç, verilen enerji fonksiyonunu optimize etmektir:

$$Q(x) = x^T Lx = \sum_{E_{ij}} w_{ij} (x_i - x_j)^2 \quad (2.41)$$

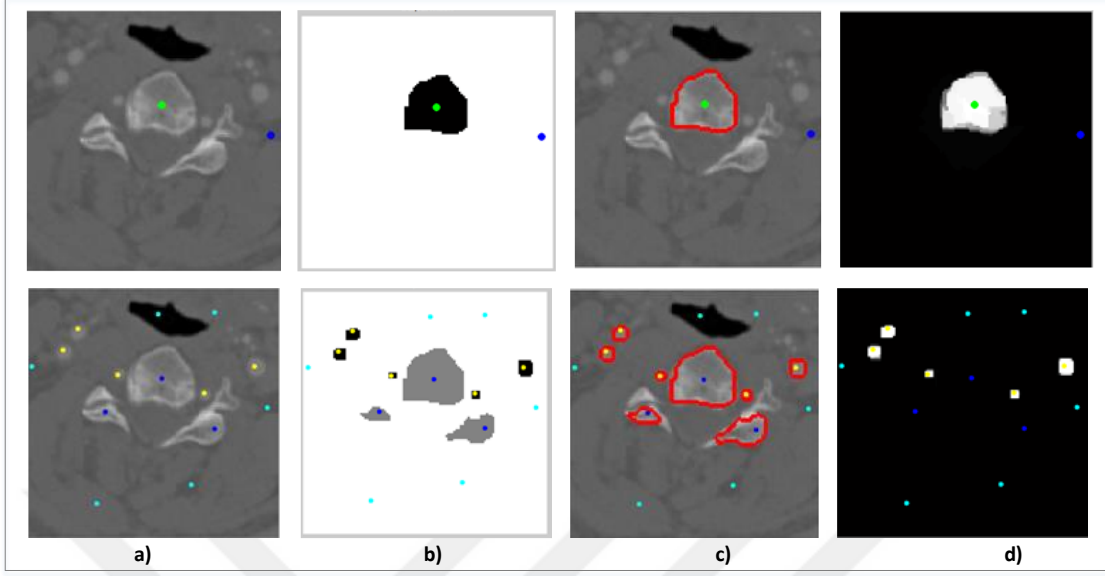
Denklem (2.41)'de,

$$x_i = \begin{cases} 1, & \text{Eğer } v_i \in \text{Ön plan} \\ 0, & \text{Değilse } v_i \in \text{Arka plan} \end{cases} \quad (2.42)$$

S , tohumlanan tüm düğümlerin kümesini temsil etsin ve \bar{S} tohumlanmamış düğüm kümesini temsil etsin, ve optimum enerji fonksiyonu Q 'nun (2.43)'deki gibi bir çözüm denklemini ile gösterilebilir:

$$L_{\bar{S}, \bar{S}}^{-x_s} = -L_{\bar{S}, S}^{-x_s} \quad (2.43)$$


Laplacian matrisi grafiği, karşılık gelen S ve \bar{S} kümelerinden oluşur. Diğer bir ifadeyle, Laplacian matrisinin altindisi matrisin hangi kısmının ilgili küme tarafından indekslendiğini gösterir. Rassal yürüyüşün daha ayrıntılı matematiksel ifadesi [105]'de mevcuttur.



Şekil 2.17. Rassal yürüyüş yöntemi ile bir ya da daha fazla tohum noktası ile BTA'da kemik-damar bölütlemesi

2.3.4. Kemik Bölütlemesi

Tersinir yöntem yaklaşımıyla öncelikle kemik bölgesi bölütlenmiş ve çıkarılmıştır, daha sonra damarlar bölütlenmiştir. Bu aşamada, ters bölütlemenin gerçekleştirebilmesi için öncelikle çoklu seviye eşik değer sonucundan yola çıkarak parlaklık seviyesi yüksek, kemik olma potansiyeli çok yüksek bölgelerin öncelikli olarak çalışma uzayımızdan çıkarılması hedeflenmiştir. Esasında damar ve yumuşak kemiği bir sınıf, ve yoğun kemiği bir sınıf olarak düşünerek çoklu seviye eşik değer sonucuna kemik bölütlemesi için tohumlandırılmalı bölütleme gerçekleştirilmiştir. Bu sonuca göre, $TohumNoktası_{Kemik} > T_{kemik}$ şartını sağlayan görüntüdeki tüm noktalar kemik bölütlemesi için tohum noktaları olarak kabul edilmektedir. Bu noktalardan başlayarak görüntüden kemik çıkarımı için bölge büyütme ve rassal yürüyüş yöntemleri gerçekleştirilmiştir. Her iki yöntemden de bölütlemenin başlaması için bir ya da bir den fazla tohum noktasına gereksinim duyduğundan, tohumlandırmanın manuel yapılması yerine bu şekilde otomatikleştirilmesi sağlanmıştır. Burada tersinir yöntem için, kemik bölütlemesi yaparken birbirinden bağımsız şekilde bölge büyütme ve rassal yürüyüş bölütleme yöntemleri uygulanmıştır.




Şekil 2.18. Bölge büyütme ve rassal yürüyüş yöntemi ile BTA'dan kemik bölütlemesi [86]

Ek Şekil 1, Ek Şekil 2, Ek Şekil 3 , Ek Şekil 4 , Ek Şekil 5, Ek Şekil 6 görüntülerde, farklı BTA görüntülerinin ait üst üste gelen farklı dilimlerinde (slices) kemik bölütlemelerine ait daha fazla örnek verilmiştir.

2.3.5. Damar Bölütlemesi

Damar bölütlemesi, kemik bölgesinin bölütlenip çıkarılmasından sonra gerçekleştirilir. Tersinir bölütleme ile hedef dışı bölge kemik bölütlemesi yapıldıktan sonra, damar bölütleme de tersinir bölütleme yaklaşımına benzer şekilde bölge büyütme ya da rassal yürüyüş bölütleme yöntemleri ile yapılmaktadır. Damar bölütlemesi yaparken tohum noktaları yine çoklu seviye eşik değeri sonucuna göre belirlenen aralıktan seçilmektedir. Kemik çıkarımı sonrasında $T_{damar} < TohumNoktası_{Damar} < T_{kemik}$ aralığında görüntüde kalan tüm noktalar damar bölütlemesi için tohum noktaları olarak kabul edilmektedir. Bu noktalar baz alınarak bölge büyütme ve rassal yürüyüş yöntemleri uygulanmıştır.




Şekil 2.19. Bölge büyütme ve rassal yürüyüş yöntemi ile BTA'dan damar bölütlemesi [86]

Ek Şekil 7, Ek Şekil 8 görüntülerde, farklı BTA görüntülerinin ait üst üste gelen farklı dilimlerinde (slices) damar bölütlemelerine ait daha fazla örnek verilmiştir.

2.4. Son İşleme Aşaması

Damar takibi yapmadan önce, ters bölütleme sonrası görüntülerdeki küçük kemik parçalar ve gürültülü bölgeler son işleme aşamasından geçirilir. Öncelikle kemik olarak bölütlediğimiz yerlerin dışlanması ile tersinir yöntemle Şekil 2.20 (c)'deki gibi damar bölgelerinin çıkarılabildiği görülmektedir. Ancak bu aşamada bir son işleme aşamasına daha ihtiyaç duyulduğu bazı damara benzer bölgelerin atılması gerektiğini görülmektedir.

Bu aşamada ters bölütleme sonrası bölütlü bölgeler üzerinde morfolojik işlem gerçekleştirme, şekilsel ve dokusal bilgi edinme amaçlanmaktadır. Burada yapılan işlemler; morfolojik açma işlemi, şekilsel olarak yaklaşık olarak yuvarlak nesnelere tespiti, damarın gürültülü yapılarından ve kemik kalıntılarında (fragments) ayırt edilmesi sırasında gerçekleştirilir.




Şekil 2.20. Bir BTA’da tersinir yöntem sonrasında son işleme aşaması: a) orijinal veri, b) tersinir yöntem ile kemik dokunun çıkarılması, c) damar bölütlemesi, d) son işleme aşaması ile bazı gürültülerin giderilmesi

2.4.1. Morfolojik İşlem

Açma görüntünün ön planından küçük nesnelere kaldırır, bunları arka plana yerleştirir. Bazı izole pikseller bölütlenmiş görüntüde kalabilir ve son bölütlenmiş görüntü için bunların yok edilmesine gereksinim olabilir. Morfolojik işlemler bölütlenmiş görüntüden izole olmuş pikselleri yok etmek için kullanılabilir. Bir I görüntüsündeki açma (opening) işlemi, H yapısal eleman olmak üzere $I \circ H$ ile ifade edilir. Denklem (2.44)’de olduğu gibi I görüntüsü önce aşındırmaya (\ominus : erosion) sonra genişletmeye (\oplus : dilation) tabi tutulur. Açma işlemi 3x3 boyutunda yapısal eleman kullanılarak gerçekleştirilmektedir.

$$I \circ H = (I \odot H) \oplus H \quad (2.44)$$

Bu aşamada morfolojik açma işleminden esinlenerek alan açma işlemi gerçekleştirildi. İkili bir görüntüden, P pikselinden daha az olan tüm bağlı bileşenlerin (nesnelerin) kaldırılması işlemi yapılmaktadır. Konturlardan nesne alanını bularak belirli değer altında kalan bölgelerin silinmesi işlemi yapılmaktadır.



Şekil 2.21. Bölütleme sonrası görüntüye uygulanan morfolojik işlemin sonucu

2.4.2. Şekilsel Bilginin Elde Edilmesi

Bir ikili görüntüdeki bir bağlı bileşen, bağlı grup formundaki bir piksel kümesidir. Bağlı bileşen etiketleme görüntüdeki bağlı bileşenlerin belirlenmesi ve her birine benzersiz bir etiket atama işlemidir. Burada, iki boyut için 8-bağlantılık kullanılmaktadır. Bu boyuttaki bütün halindeki tüm bileşenler birer nesne gibi kabul edilerek bu nesnelere etiketlenir. Bu aşamada, bölütleme aşaması ile ikili hale getirilmiş görüntüden nesne tespiti yapılmaktadır. Burada görüntüde etiketlenen ilgili nesnelerin etiket matrisi geri döndürülür. Nesne sınırları, aktif kontur model ile bulunmaktadır. Aktif konturlar veya snakes, dış ve iç kuvvetlerin etkisi altında hareket edebilen görüntü domaininde tanımlanan eğrilerin bölütlemesinde etkin bir yol sağlar [106]. Bu kuvvetler, snake'in nesne sınırlarına küçülerek gelecek şekilde tanımlanır. Bu yöntem kenar tespitinin yapılmasında çoğu uygulamada

kullanılmıştır. Diğer kenar bulma yöntemleri örneğin Canny kenar bulmaya göre daha düşük seviyeli görüntü işlem gerektirir. Genel enerji fonksiyonunda, E_{int} eğriden kaynaklanan iç kuvveti gösterir. Konturun gerginlik ve esneklik bozulmaları ile ifade edilir. E_{img} görüntü kuvvetini; E_{ext} ise dış kuvveti temsil etmektedir [107].

$$E_{snake} = \int_{s=0}^1 [E_{int}(v(s)) + E_{ext}(v(s)) + E_{img}(v(s))] ds \quad (2.45)$$


İç kuvvetler eğrinin biçim değiştirme boyunca düzgün şekilde kalmasını sağlamaktadır. Dış kuvvetler ise eğriyi yerel minimum düzeyde tutulmasını sağlamaktadır. Görüntü kuvvetleri ise nesnelere kenarlarına belirgin noktalara doğru yönlendirilmesini sağlamaktadır. Gradyan vektör akış model (Gradient Vector Flow Model-GVF), geleneksel aktif kontur modelin geliştirilmiş halidir. Geleneksel snake ile GVF snake arasındaki fark, ikincisinin sınır içbükey noktalarına yaklaşması ve sınırlara yakın bir şekilde başlatılmalarına gereksinim olmamasıdır [108]. Enerji fonksiyonunu en aza indirerek, dış kuvvet kullanımı kullanarak yeni bir vektör alanı elde edilir. Bu vektör alanına gradyan vektör akış alanları denir.

$$E_{int} = \int_0^1 \frac{1}{2} (\alpha |x'(s)|^2 + \beta |x''(s)|^2) ds \quad (2.46)$$

$$E_{ext} = \min(\iint \mu(u_x^2 + u_y^2 + v_x^2 + v_y^2) + |\nabla f|^2 |V - \nabla f|^2 dx dy) \quad (2.47)$$

Burada, α ve β snake'in gerginliğini ve katılığını kontrol eden ağırlık parametreleridir. $x'(s)$ ve $x''(s)$ ise s 'e göre eğri parametresi $x(s)$ 'in birinci ve ikinci türevlerini belirtir [109]. Dış kuvvet enerji fonksiyonu E_{ext} , görüntüden elde edilir. Bu dış kuvvet denklemi, Eşitlik (2.44)'de verildiği gibi algoritmayı nesnelere çizgi ve kenarlar gibi görüntü detaylarına yönlendirmektedir. Bu denklemler doğrultusunda eğri yüksek görüntü

gradyanının olduğu nesnelerin sınırlarına ulaştığında ilerleme durur ve böylece nesne sınırları tespit edilmiş olur.




Şekil 2.22. Bölütleme sonrası bölütlü bölgelerin şekilsel bilgisinin elde edilmesi

$$T(\text{thinness ratio}) = 4\pi \left(\frac{A}{P^2} \right) \quad (2.48)$$


Bu aşamadan sonra, etiket matrislerine bakarak bulunan nesnelerin alanlarına ve merkezlerine ulaşılabilir. Etiketli bileşenin sınırlarından yola çıkarak sınırlarındaki piksellerin satır ve sütun değerlerinden iki nokta arasındaki uzaklık formülü ile nesnelerin çevresi bulunmuştur. Bir nesnenin düzgünlüğünü (regularity) tanımlamak için incelik (thinness) genellikle kullanılır [110]. Nesnenin alan (A) ve çevre (P) bilgisini kullanarak T incelik oranı (thinness ratio) oranı Eşitlik (2.44) ile elde edilmiştir [110]. Bu ölçüm, bir çember (circle) için maksimum 1 değerini alır. Burada incelik oranı bir nesnenin yuvarlaklığını ölçmek için kullanılmıştır. Nesnelerin yaklaşık olarak yuvarlaklık tahminini

Eşitlik (2.44) ile elde edilmiştir. Bu eşitlikten elde edilen T değeri dikkate alınarak, Şekil 2.22 (c)'deki görüntüdeki gibi yaklaşık yuvarlak şekline sahip nesnelere işaretlenmektedir.



Şekil 2.23. Bir BTA'da tersinir yöntem sonrası uygulanan son işleme aşamasının gösterimi: a) orijinal veri, b) tersinir yöntem ile kemik dokunun çıkarılması, c) damar bölütlemesi, d) morfolojik işlemin uygulanması, e) damarların orijinal görüntüde gösterimi

Şekil 2.24'deki görüntüde görüldüğü gibi morfolojik işlem sonrası görüntüde bazı gürültü kalıntı varlıkları tespit edilmiştir. Başka bir ifade ile bu aşama sonrasında bazı görüntülerde, istenmeyen gürültü ve kemik kalıntılarının kaldığı gözlenmiştir. Bu istenmeyen gürültü ve kemik kalıntılarının damardan ayırt edilmesine ihtiyaç duyulmuştur.



Şekil 2.24 Tersinir yöntem sonrası bazı görüntülerde oluşan gürültü ve kemik kalıntılarının gösterimi

2.4.3. Damarın Gürültü ve Kemik Kalıntılarında Ayırt Edilmesi

Tersinir yaklaşımla, kemiklerin bölütlenmesi ve çıkartılmasından sonra damar bölütlenmesi yapıldıktan sonra görüntülerde damarla ilişkisi olmayan kalıntıların ve gürültülerin kaldığı gözlemlenmektedir. Bu kalan parçaların damardan ayırt edilmesi işlemi bu aşamada yapılmaktadır. Damar ve kemik dokularından alınan lokal örneklerden danışmanlı öğrenme ile eğitimi tamamlanmış karar verme mekanizması üzerinden makine öğrenmesi yöntemleri ile bölütlenmiş bölgelerin sınıflandırılması yapılarak, damarın gürültü ve kemik kalıntılarında ayırt edilmesi yapılmaktadır.

Bu tez kapsamında, son işleme aşamasında da bir sınıflandırıcı ile karar-verme mekanizmasına ihtiyaç duyulan ve öncesinde bir çalışma olarak sunulan “Bölge-tabanlı aktif-kontur ve sınıflandırma ile BTA görüntülerinden karotid arterlerin bölütlenmesi” çalışmasından bahsedilecektir.

2.5. Danışmanlı Öğrenme

Damar ve kemik gibi gri seviye değeri yüksek olan bölgelerin bölütlenmesi sonrasında, bu bölgelerin birbirinden ayırt edilmesi gerekmektedir. BTA görüntülerinden sadece karotid arterlerin bölütlenmesi için, görüntüde kemik parçalarının ve damara benzer gürültülerin çıkarılması gerekmektedir. Bunun için bu aşamada, danışmanlı bir öğrenme sistemi ile bölümlü bölgelerin birbirinden ayırt edilmesi yapılmaktadır.

Bu bağlamda danışmanlı bir sistemle özellikle problemlili olan kısım damar, kemik ve diğler bölgelerden alınan doku örnekleri, makine öğrenmesi yöntemleriyle eğitimi tamanlanmış karar verme mekanizması üzerinden sınıflandırma yapılmaktadır.

Sınıflandırma için eğitim aşamasında öznitelik çıkarımı ve uygulama performansı için öznitelik seçimi yapılmaktadır. Bu aşamanın ana amacı, her bölge için öznitelik vektörü formüle etmektir. Bu öznitelikler daha sonra sınıflandırma için eğitim aşamasında kullanılmaktadır.

2.5.1. Dokusal öznitelikler

Görüntünün dokusal öznitelikleri, tıbbi görüntü analizlerinde en çok kullanılan özniteliklerdir. Denetimli öğrenim algoritmalarıyla görüntü üzerindeki yapıların bölütlenmesi, kümelenmesi ya da sınıflandırılması için çoğunlukla dokusal öznitelikler kullanılmaktadır. Benzer şekilde damar bölütlemesi veya damar plaklarının tespitinde dokusal öznitelikler kullanılmıştır [111-113].

2.5.1.1. Gri-seviye Histogramın İstatistiksel Öznitelikleri

Görüntü üzerindeki objelerin parlaklıkları ile ilgili öznitelik çıkarımında sıklıkla gri seviye görüntülerin histogramından faydalanılır. Bir görüntüdeki nesnenin analiz edilmesinde, nesnenin ortalama parlaklık değeri, standart sapması, pürüzsüzlüğü, keskinliği ve tekdüzeliği gibi değerler ayırt edici öznitelikler olarak kullanılabilir.

Kullanılan gri seviye histogram momentleri (GSHM); ortalama, standart sapma, yumuşaklık (smoothness), üçüncü moment, tek düzelik (uniformity) ve entropidir. Görüntünün, parlaklık (intensity) histogramının istatistiksel özelliğine dayalı doku analizi sıklıkla kullanılan bir tekniktir. Tekniklerden biri istatistiksel momentleri temel alır. Örneğin, ortalama kullanılarak n'inci mertebeden moment (2.48) ifade kullanılarak hesaplanır.

$$u_n = \sum_{i=0}^{L-1} (z_i - m)^n \cdot p(z_i) \quad (2.48)$$

Denklem (2.48)'de, z parlaklığı belirtir ve $p(z_i)$ bölgedeki parlaklık seviyesinin histogramını temsil eder, L muhtemel parlaklık seviyelerinin sayısını, ve m is the ortalama parlaklığını belirtmektedir. Gri-seviye histogram momentleri, Tablo 2.2'deki gibi özetlenebilir.

Tablo 2.2. Gri-seviye histogramın istatistiksel öznitelikleri


Öznitelik	Formül -İfade	Ölçüm açıklama
Ortalama (Mean)	$m = \sum_{i=0}^{L-1} z_i p(z_i)$	Ortalama parlaklığın bir ölçüsüdür.
Standart Sapma (Standart Deviation)	$\sigma = \sqrt{\mu_2(z)} = \sqrt{\sigma^2}$	İlgilenilen bölgelerin parlaklık değerlerinin standart sapmasıdır. Kontrast ölçüsüdür.
Yumuşaklık (Smoothness)	$R = 1 - \frac{1}{1 + \sigma^2}$	Bir bölgedeki yoğunluğun göreceli yumuşaklığının ölçüsüdür.
Çarpıklık (Skewness)	$\mu_3 = \sum_{i=0}^{L-1} (Z_i - m)^3 p(z_i)$	Piksellerin parlaklık değerlerinin ortalama etrafındaki simetrikliğinin ölçüsüdür.
Tek düzelik (Uniformity)	$U = \sum_{i=0}^{L-1} p^2(z_i)$	Histogramdaki parlaklığın tek düzelik ölçüsüdür.
Entropi	$e = -\sum_{i=0}^{L-1} p(z_i) \log_2 p(z_i)$	Rasgeleliğin bir ölçüsüdür.

2.5.1.2. Haralick Doku Öznitelikleri

Haralick ve arkadaşları [114] tarafından önerilmiş Haralick doku öznitelikleri, doku alanında yapılan birçok çalışmada kullanılmıştır. Bu öznitelikler, dokuyu uzamsal parlaklık bağımlılıkları ile açıklamayı hedeflemiştir. Özgün çalışmada; doku, parlaklık değerlerinin d uzaklığında ve θ açısında birlikte görülmelerini temsil eden Gri Seviye Birlikte Görülme Matrisinin (GSBGM, Gray Level Co-occurrence Matrix, GLCM) bazı istatistiksel özelliklerinin hesaplanmasıyla tanımlanmıştır. GSBGM, tüm satır ve sütunların gri seviye parlaklık değerini gösteren kare bir matristir. Dolayısıyla, GSBGM'nin boyutları görüntüdeki gri seviye parlaklık değerlerinin sayısına bağlıdır.

Piksellerin uzaysal ilişkileri göz önüne alarak dokuyu inceleyen istatistiksel yöntem, ayrıca gri seviye mekânsal bağımlılık matrisi olarak da bilinir. GSBGM fonksiyonları, bir görüntü içinde bir piksel çiftinin ne sıklıkla belli değerlerle ve belirli bir uzaysal ilişkide oluştuğunu, bir GSBGM oluşturarak ve daha sonra bu matrizen istatistiksel ölçümler çıkararak bir görüntünün dokusunu karakterize eder. Başka bir ifade ile, farklı uzaysal yerlerdeki iki farklı piksel arasındaki gri seviyesi farklılıkları karşılaştırılır. Varsayılan olarak, uzaysal ilişki ilgilenilen piksel ve hemen sağındaki piksel (yatay bitişik) olarak tanımlanır, ancak istenirse iki piksel arasındaki diğer uzaysal ilişkiler; dikey diyagonal ve off-diyagonal gibi belirtilebilir. Her eleman (j,k) sonuç GSBGM içinde, basitçe j piksel değerinin, belirli uzaysal ilişki girdi görüntü içinde k piksel değerinde gerçekleşme sayısının toplamıdır [46].

GSBGM ikinci dereceden bileşik durum olasılık yoğunluk fonksiyonunun, $P(i, j|d, \theta)$, tahminine dayanır. Bu matris pikseller arası uzaklık d ve açı θ iken gri seviyesi i 'den gri seviyesi j 'ye geçme olasılığını gösterir. Desen özelliklerinin dönme ile değişmediğini ispatlamak adına genellikle $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° olacak şekilde dört yönde inceleme yapılır ve kare matris kullanılmaktadır. Genellikle uzaklık olarak $d = 1, 2$ değerleri tercih edilir. Haralick bu dört yön için bulunan GSBGM'den elde edilen özelliklerin ortalamasının alınmasını önermiştir.



Şekil 2.25. GSBGM'nin oluşturulmasında $d = 1$ ve $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° için kullanılan pikseller


Tablo 2.3. GSBGM'den hesaplanan Haraçlık öznelikleri

Öznitelik	Formül - İfade	Ölçüm açıklama
Karşıtlık (Contrast)	$\sum_{i,j} i - j ^2 p(i, j)$	Gri-seviye eş oluşum matrislerindeki lokal varyasyonların ölçüsüdür.
Korelasyon (Correlation)	$\sum_{i,j} \frac{(i - \mu_x)(j - \mu_y) p(i, j)}{\sigma_x \sigma_y}$	Belirtilen piksel çiftlerinin ortak olasılık oluşumunun ölçüsüdür. Burada, μ_x ve σ_x GSBGM'nin satır bazlı ortalama ve standart sapması; μ_y ve σ_y GSBGM'nin sütun bazlı ortalama ve standart sapmasıdır.
Enerji (Energy)	$\sum_{i,j} p(i, j)^2$	GSBGM içindeki karesel elemanların toplamını sağlar. Ayrıca, tek düzelik (uniformity) ya da açısız ikinci moment olarak da bilinir.
Homojenlik (Homogeneity)	$\sum_{i,j} \frac{p(i, j)}{1 + i - j }$	GSBGM içindeki elemanların dağılımının GSBGM diyagonala olan yakınlılığın ölçüsüdür.

GSBGM öznitelik çıkarımında dışardan sabit bir pencere boyutu tercih edilir. Burada, pencere boyutu çok küçük olursa, istatistiksel açıdan çıkarılan uzaysal bilgi güvenilir olmayabilir. Alternatif olarak, pencere boyutu çok büyük olursa bu hatalı dokusal bilgilere yol açabilir. Bu aşamada, GSBGM öznitelik çıkarımında 5x5 lik pencere boyutu kullanılmıştır. 5x5 boyutundaki pencere farklı dokular üzerinde gezdirilerek $d = 1$ ve $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° değerleri ile GSBGM'ler oluşturulmuştur. İlgili bölgelerden aşağıdaki dört öznitelik çıkarımı yapılmaktadır. Bu matrislerden görüntünün dokusal karakteristiğini tanımlayan karşıtlık, korelasyon, enerji ve homojenlik olmak üzere 4 adet öznitelik bulunmuştur.

2.5.2. Boyut İndirgeme

Bir nitelik kümesinin indirgeme sürecinde ilk m nitelikten oluşan nitelik kümesi bir k nitelikten oluşan bir öznitelik kümesine indirgenirse ($k < m$) buna boyut indirgeme denilir. İdeal olarak, k azalmış öznitelik, orijinal m niteliğin önemli özelliklerini taşır. Başka bir ifade ile, boyut indirgeme işlemi ile yapılan, yüksek boyutlu verinin daha düşük boyutlu bir uzayda anlamlı bir şekilde ifade edilmesidir.



Şekil 2.26. n örnek ve d öznitelikten oluşan bir verinin temsili gösterimi

Bu aşamada bu tez kapsamında, sınıflandırma için örnek eğitim verisi $n=1000$ lokal doku örneği ve $m=10$ tane öznitelikten oluşmaktadır. Boyut veri $n \times m$ ile hesaplanırsa boyut= 1000×10 şeklindedir. Örnek sayısının artırılmasıyla 10000 lokal doku örneğine ulaşıldığında boyut= 10000×10 'a ulaşmaktadır. Veri boyutunun yüksek oranda artması, sınıflandırıcının hem başarısını sorgulamak ve hep de tepki süresini ölçme ihtiyacını beraberinde getirmektedir. Dolayısıyla bu aşamada, sınıflandırıcının hem başarısını hem de tepki süresini düşürmek için boyut indirgeme işlemine ihtiyaç duyulmuştur.

Yüksek boyutlu bir verinin daha düşük boyutlu bir uzaya lineer olarak iz düşüm yapılması, lineer boyut indirgeme yöntemidir. Bu yöntemlerde amaç, n tane örneğe sahip d boyutlu veriyi x_1, x_2, \dots, x_n , örnek sayısı n 'i sabit tutarak k boyutlu y_1, y_2, \dots, y_n veriye dönüştüren bir $d \times k$ boyutlu dönüşüm matrisi P bulmaktır. Yüksek boyutlu veri nesnelere, P dönüşüm matrisi kullanılarak (2.49)'daki gibi dönüştürülür.

$$y_i = P^T x_i \quad (2.49)$$

Eğer yüksek boyutlu veriyi, $d \times n$ veri matrisi $X = [x_1, x_2, \dots, x_n]$ şeklinde tanımlarsak, boyutu indirgenmiş veri $k \times n$ matrisi $Y = [y_1, y_2, \dots, y_n]$ olmak üzere, boyut indirgeme işlemi (2.50)'deki gibi tanımlanabilir:

$$Y = P^T X \quad (2.50)$$

Farklı P dönüşüm matrislerinin oluşma nedeni, farklı lineer boyut azaltma yöntemlerinin kullanılmasından kaynaklanmaktadır. Verinin sahip olduğu özelliklerden hangisinin yansıtılmak ve korunmak istediğine bağlı olarak, kullanılan yöntemler farklılık gösterebilir.

Boyut indirgeme tekniği iki önemli kategoriye ayrılır: Öznitelik çıkarma (Feature extraction) ve Öznitelik seçimi (Feature selection).

2.5.2.1. Öznitelik Çıkarma Yöntemleri

Öznitelik çıkarma, n orijinal boyutlu bir kombinasyonda bir yeni k boyutlu nitelik bulma işlemi olarak tanımlanabilir. Bundan ötürü öznitelik dönüşümü olarak da tanımlanır. Projeksiyon ve sıkıştırma yöntemlerine dayanan teknikler en iyi bilinen öznitelik çıkarma teknikleridir. Doğrusal ayırteden analizi (DAA) ve Temel Bileşenler Analizi (TBA) sırasıyla denetimli ve denetimsiz öğrenme için projeksiyon yöntemleri örnekleridir.

Özellik çıkarım yöntemleri kurulan sistemin başarısını ve hızının artırılması için yapılan ön çalışmalar olarak tanımlanabilir. Bağımsız bileşen analizi, temel bileşen analizi, ve doğrusal ayırteden analizi yaygın bilinen öznitelik çıkarım yöntemleridir. Bu aşamada boyut düşürme için bu tez kapsamında TBA öznitelik çıkarma yöntemi ile orijinal veri kümesinin daha düşük boyutta bir veri kümesi ile temsil edilebilirliği, bir başka ifade ile veriyi temsil eden daha düşük boyutta veri ile sınıflandırma uygulamasının çalışabileceği gösterilmektedir. Bu aşamada kısaca, TBA öznitelik çıkarım yöntemi ve yöntemin matematiksel yapısından bahsedilmektedir.

2.5.2.1.1. Temel Bileşenler Analizi

Temel Bileşenler Analizi (Principle Components Analysis- PCA) birbiriyle bağlantılı ve çok sayıda değişkeni bulunan bir veri kümesinin boyutunu düşürmek amacıyla geliştirilmiş bir yöntemdir [115]. Boyut düşürme işlemi yapılırken hedeflenen, veri kümesinde olabildiğince çok değişiminin (varyasyonun) kalmasını sağlamaktır. Bu sayede orijinal kümenin, orijinal veri kümesine göre daha düşük boyutlu bir veri kümesi ile temsil edilmesi sağlanır. TBA'nın uzun zamanlardır örüntü tanıma alanında sıklıkla tercih edilmesinin nedeni de budur.

TBA ile veri kümesinin temel karakteristiğini bularak veri kümesinin boyutunun düşürülmesi hedeflenmektedir. Bu işlem veri kümesine ait varyasyonların hesaplanması ile yapılmaktadır. Öncelikle örneklere ait değerlerle oluşturulan matrisin kovaryans matrisinin hesaplanması yapılır. Veri kümesinin varyansı işte bu kovaryans matrise ait özdeğer ve özvektörden elde edilir. Yüksek sayısal değere sahip olan özdeğer elemanları, veriyi daha nitelendirici şekilde temsil eden özvektörlerdir. Verinin karakteristiğini daha az belirleyen özvektörler, düşük sayısal değere sahip özdeğer elemanları ile elde edilir. Bir özvektörün

lineer bağımlı olduğu durum, özdeğerin değerinin sıfır olması ile o özdeğere karşılık gelen özvektörün diğer özvektörlerin bileşenleri olarak ifade edilmesindedir [116].

Özdeğerler ve özvektörler elde edildikten sonra sıralama yapılır. Bu sıralamada en yüksek değere sahip olan özvektörlerin baz alınması yapılır. Bu sayede bu özvektörlerden kaç tanesinin kullanımıyla yeni verilerin elde edilmesi gerektiğinin testi, başarı oranına göre bulunabilmektedir. Bileşenler hesaplandıktan sonra başarıyı en büyük yapan Temel Bileşen (TB) sayısının bulunması için örnek veriler değişik bileşen sayıları ile test edilerek en uygun Temel Bileşen sayısı bulunmaktadır. Bunun uygulaması Şekil 2.27'deki gibidir.

TBA'nın matematiksel yapısı aşağıdaki gibidir. TBA'nın ilk adımında kullanılan örneklerin her bir sınıfının ortalamaları hesaplanır. x_i , $i = 1, 2, \dots, N$ örnek veriler ve her bir x_i örneği için $x_i = [x_i^1 x_i^2 \dots x_i^M]^T$ olmak üzere ortalama, denklem (2.51) ile hesaplanır.

$$m = \frac{1}{N} \sum_{i=1}^N x_i = \frac{1}{N} \begin{bmatrix} x_1^1 + x_2^1 + \dots + x_N^1 \\ \cdot \\ \cdot \\ x_1^M + x_2^M + \dots + x_N^M \end{bmatrix} \quad (2.51)$$

Bundan sonra, hesaplanan ortalama $x = [x_1 x_2 \dots x_N]$ matrisinden çıkarılarak ortalaması sıfır olan bir veri kümesi elde edilir.

$$\bar{x}_i = x_i - m_i \quad (2.52)$$

$$\bar{x} = [\bar{x}_1 \bar{x}_2 \dots \bar{x}_N]_{M \times N} \quad (2.53)$$

Ardından (2.53)'de ifade edilen \bar{x} matrisi transpozesi ile çarpılarak kovaryans matrisi hesaplanır.

$$Cov(\bar{x} \bar{x}^T) \quad (2.54)$$

Hesaplanan kovaryans matrisine ait özdeğerler ve bu özdeğerlere karşılık gelen özvektörler hesaplanmaktadır. Bulunan bu özvektörler aranan Temel Bileşen (TB)'lerdir. Herhangi bir özvektörün hesaplanması için kullanılan özdeğerinin sayısal değeri ise özvektörün elimizdeki örnek verileri ne kadar iyi temsil ettiğini göstermektedir. Bundan dolayı hesaplanan özvektörler kendilerine karşılık gelen özdeğerlere göre büyükten küçüğe doğru sıralanır. Hesaplanan ve büyükten küçüğe doğru sıralanan özdeğer dizisi $E = [E_1 E_2 \dots E_M]$ ve özdeğerlerin değerine göre sıralanmış özvektör matrisi $V = [V_1 V_2 \dots V_M]$, $\forall V_i = [V_i^1 V_i^2 \dots V_i^M]^T$ olmak üzere, yeni örnek kümesi (2.55) ile bulunur.

$$\tilde{x} = \bar{x} \tilde{V} \quad (2.55)$$

Burada \tilde{V} seçilmiş olan ilk t , $t \leq M$ özdeğere karşılık gelen özvektör matrisini göstermektedir [116].

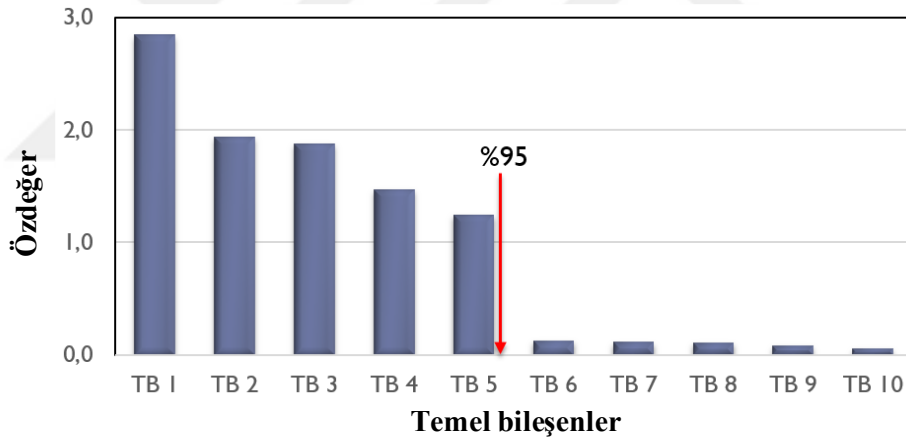
Seçilecek özdeğerlerin sayısı, TB'lerin bulunması sürecinde önemli bir adımdır. Bu aşamada özvektörlerin seçimi, özdeğerlerin büyükten küçüğe sıralanmasıyla olmaktadır. Sıralama sonrası her bir özdeğere karşılık gelen seçilen özvektörler dikkate alınır. Özdeğerlerin büyük olması, karşılık gelen ilgili özvektörün veri kümesi hakkında daha çok bilgi verdiğinin göstergesidir. Literatürde, genellikle özvektörlerin seçimi özdeğerlerin toplamının %95'ini sağlamasına karşılık gelen nokta olarak değerlendirilmektedir. Bu seçim değerinden, verinin %95 oranında korunduğunu söylenebilmektedir. (2.56)'deki orantıda λ_i , i 'inci özdeğere karşılık gelmektedir.

$$\frac{\sum_{i=1}^K \lambda_i}{\sum_{i=1}^N \lambda_i} \cong 0,95 \quad (2.56)$$

10 dokusal öznitelik kullanıldığında Tablo 2.4'e göre özdeğer toplamının oranı ilk beş bileşen için %95 değerine ulaşmaktadır. Bu veri kümesi için, veri boyutunun yarı yarıya düşürülmesi anlamına gelmektedir.

Tablo 2.4. 10 tane öznelik için en önemli temel bileşenleri sıralanması

10 Bileşenin Önemi	Özdeğer
Bileşen 1	2,8445
Bileşen 2	1,9354
Bileşen 3	1,8752
Bileşen 4	1,4685
Bileşen 5	1,2454
Bileşen 6	0,1241
Bileşen 7	0,1114
Bileşen 8	0,1053
Bileşen 9	0,0817
Bileşen 10	0,0549



Şekil 2.27. TBA ile 10 öznelik için optimum temel bileşen noktasının gösterimi

2.5.2.2. Öznelik Seçme Yöntemleri

Öznelik seçimi (feature selection), mümkün olan en büyük genellemeyi sağlayan belli bir büyüklükteki niteliklerin en uygun alt kümesini bulma sürecidir. Nitelik veya değişken seçimi olarak da ifade edilen öznelik seçimi, bazı kriterlere göre orijinal giriş niteliklerinden en optimum niteliklerin alt kümesini seçmek için geliştirilmiş bir tekniktir. Niteliklerden daha küçük bir alt kümenin bulunma nedeni, bir sorunun çözümünün daha

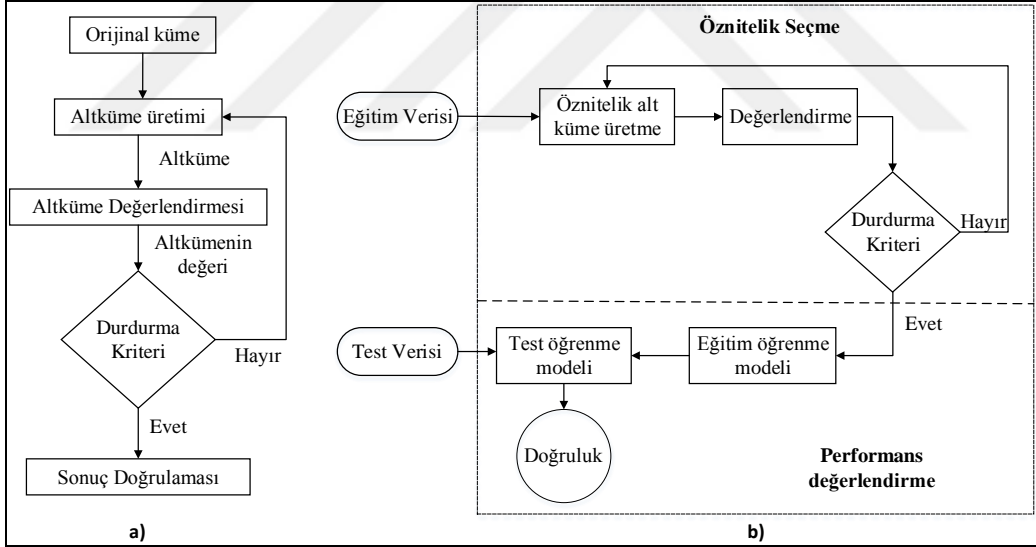
düşük boyutta yapılması daha kolaydır. Bu işlem, giriş ve çıkış değişkenleri arasında bir doğrusal olmayan eşleştirmenin anlaşılabilirliğini sağlamaktadır [117].

Öznitelik seçme yöntemleri, veri boyutunu azaltma (boyut indirgeme) yöntemlerinin bir alt grubudur. Temel bileşen analizi, bağımsız bileşen analizi gibi öznitelik projeksiyon yöntemleri, bütün ölçülen özniteliklerin doğrusal bileşimi olan ama daha az sayıda boyut kullanırken, ileri (forward) ya da geri (backward) öznitelik seçimi, sadece belirli öznitelikleri seçip kullanmaktadır. İleri öznitelik seçme, nitelik alt kümesi ile başlar ve nitelikleri belirlenen sayıya ulaşana kadar veya daha iyi yaklaşım sonucu elde edilene kadar her adımda bir nitelik ekler. Geri öznitelik seçme, tüm modeli tahmin ederek başlar ve sonra kalan tüm giriş değişkenleri istatistiksel olarak önemli olana kadar, en kötü ortak değişkenleri birer birer kaldırır [118].

Büyük veri setlerinde, sadece en önemli ve tanımlayıcı özniteliklerin seçilmesi ve geri kalanının göz ardı edilmesi önemlidir [119, 120]. Zaman ya da maliyet açısından özellikle ölçümlerin alınması ya da saklanması külfetli olduğu şartlarda, öznitelik seçme yöntemleri, öznitelik projeksiyon yöntemleri yerine tercih edilmektedir. Birçok özellikleri bünyesinde barındıran yüksek boyutlu bir verinin, özelliklerinden sadece bazıları ilgili verinin sınıfını belirlemede önemli rol alabilmektedir. Bu durumda yapılması gereken, özellik kümesinden bir alt küme seçmek veya bu bazı özelliklerin birleşiminden yeni özellikler elde etmektir.

Veri boyutunun artması ile birlikte, performans açısından öznitelik seçme yöntemlerinin kullanılmasına gereksinim duyulmuştur. Aşırı çok boyutlu veri, daha fazla hesaplama zamanı ve kaynağa gereksinim duyar. Bazı durumlarda öznitelik uzayının boyutunun artması, sınıflandırma aşamasında sınıflandırıcının başarısını azaltıcı etki yapabilmektedir. Aşırı çok boyutlu veri, daha fazla hesaplama zamanı ve kaynağa gereksinim duyar. Bazı öznitelikler, doğruluk ve hesaplama zamanı cinsinden sistemden daha iyi performans elde edebilmek için çıkarılabilir. Bu durumda sınıflandırma gücü olmayan ve gereksiz işlem yükü getiren özelliklerin ayıklanması gerekliliği ortaya çıkar. Ayrıca, ayırt edici nitelikte olmayan özelliklerin kullanıldığı özellik vektörleri sınıflandırma başarısını düşürebilir. Bu nedenlerden dolayı bu aşamada öznitelik seçimi yapılmıştır. Öznitelik seçiminde, öznitelik uzayının boyutunu azaltarak, gürültü öznitelikleri ortadan kaldırarak sınıflandırma doğruluğunu ve hassasiyeti artırılmış dolayısıyla sınıflandırıcı uygulama daha verimli hale getirilmiştir.

Öznitelikler genellikle arama yöntemleri ile seçilir. Literatürde çok farklı arama yöntemleri bulunmaktadır. Öznitelik seçme yöntemlerinde, genetik algoritma (GA) oldukça önemli bir yer tutar. Bu tez kapsamında, öznitelik seçiminde Genetik arama yöntemi kullanılmıştır. Genetik algoritma, doğal genetik ve biyolojik evrimin temellerine dayalı fonksiyon optimizasyonu için rassal bir yöntemdir. Doğada, organizmaların genleri, çevreye daha iyi uyum sağlamak için birbirini takip eden nesiller boyunca gelişmeye eğilimlidir. Genetik Algoritma, bu doğal evrim prosedürlerinden esinlenen bir sezgisel optimizasyon yöntemidir. Öznitelik seçiminde, optimize etme işlevi, bir tahmin modelinin geliştirme performansınıdır. Daha açık ifade ile, modelin yaratılmasında kullanılmayan bağımsız bir veri setindeki modelin hatasını en aza indirmek hedeflenmektedir. Bu fonksiyon seçim hatası olarak adlandırılır. Tasarım değişkenleri, modeldeki her olası özelliğin varlığını (1) veya yokluğu (0) ile ifade eder [121, 122].



Şekil 2.28. a) Öznitelik seçimi süreci, b) Öznitelik seçme ve performans değerlendirme akış diyagramı

Tablo 2.5. Genetik arama yöntemi ile sınıflandırma için seçilen öznitelikler

Öznitelik çıkarma teknikleri	Seçilen öznitelik sayısı
GSHM	3
GSBGM	2

Bu aşamada, lokal doku örneklerinden çıkarılan 10 farklı tipte öznelik genetik arama yaklaşımı ile optimize edilmiştir. Bu seçilen ya da optimize edilen öznelikler bölütleme için sınıflandırma algoritmasına eğitim aşamasında girdi olarak verilmiştir. Genetik arama ile seçilen 5 farklı öznelik sayısı Tablo 2.5'deki gibidir. Bu aşamada, 10 öznelikten seçilen 5 özneliğin performansı koruduğu gibi hesaplama zamanını da azaltmıştır. Genetik arama ile 5 farklı öznelik seçilmiştir. Bunlar, GSHM'den 3 tane; standart sapma, yumuşaklık (smoothness), ton düzgünlüğü (uniformity), GSBGM'den 2 tane; kontrast ve homojenliktir.

2.5.3. Makine Öğrenmesi ve Kullanılan Sınıflandırıcılar

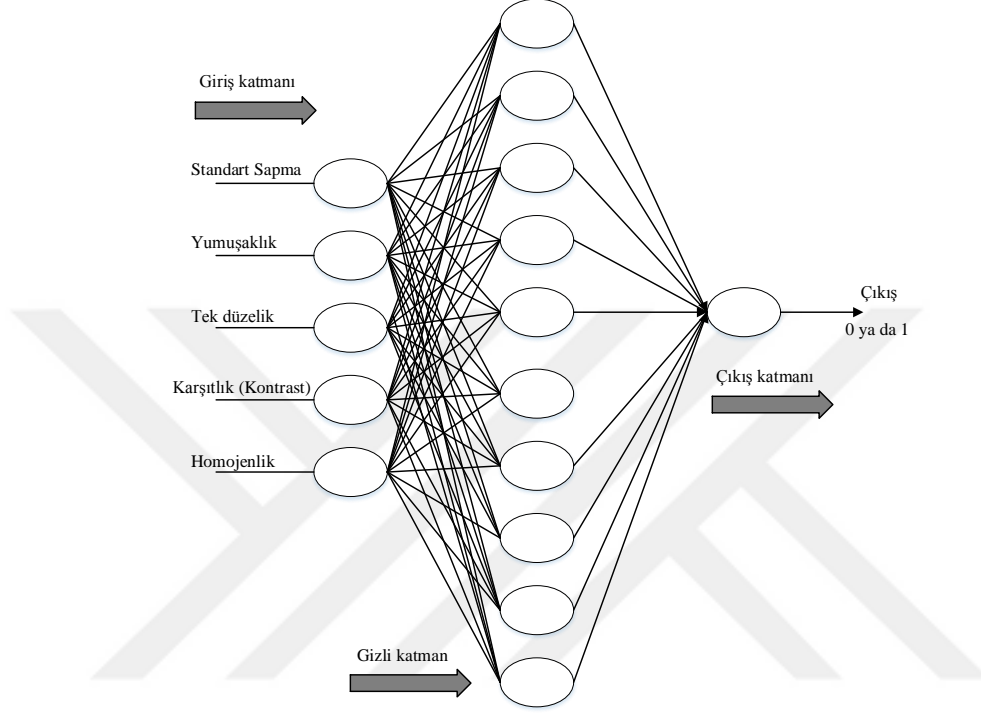
Bu aşamada, damar ve kemik dokularından alınan lokal örneklerden danışmanlı öğrenme ile eğitimi tamamlanmış karar verme mekanizması üzerinden makine öğrenmesi yöntemleri ile bölütlenmiş bölgelerin sınıflandırılması işleminde kullanılan sınıflandırıcılardan kısaca bahsedilmektedir. Bu tez çalışmasında, literatürde en çok bilinen gözetimli sistemlerden, Destek Vektör Makineleri (DVM), k-En Yakın Komşu (k-EYK) Yöntemi, Yapay Sinir Ağları (YSA) sınıflandırıcıları kullanılmıştır.

Literatürdeki çalışmalarda bu amaçla en çok gözetimsiz ve gözetimli öğrenme metodunu kullanan algoritmalar kullanılmaktadır [123]. Gözetimsiz öğrenme (unsupervised learning) sistemleri, çıktı verilerini kullanmadan sadece girdi verileri üzerinden öğrenme işlemini gerçekleştirirken, gözetimli öğrenme (supervised learning) sistemleri ise eğitim verileri (etiketlenmemiş veri) ile çıktı verileri (etiketlenmiş veri) arasında eşleme yaparak öğrenme yapar.

2.5.3.1. Yapay Sinir Ağları

Yapay sinir ağları (YSA), daha önce hiç görülmemiş olayları elde bulunan mevcut örneklerden öğrenerek ilgili olaylara önceki örneklerden çağrışım yaparak çözümler üretmesi adına önemli bir tekniktir. Yapay sinir hücreleri sıklıkla birkaç katman halinde dizilerek çeşitli yapılardaki YSA modellerini oluştururlar. Temel bir YSA'da bu katmanlar işlevlerine göre girdi, ara (gizli) ve çıktı katmanları olmak üzere üç gruba ayrılmaktadır [124]. Genel olarak yapay sinir ağları modelleri; ağıın yapısına, geri beslemeli (feed back), ileri beslemeli (feed forward), ağırlık matrislerinin asimetrik ve simetrik oluşuna, ağırlık

matrislerinin deęişken veya sabit oluşuna, ağda yer alan düğümlerin özellikleri, kullanılan eşik fonksiyonuna ve eğitim-öğrenme kurallarına göre farklılık göstermektedir.



Şekil 2.29. Sınıflandırmada kullanılan YSA'nın yapısı

Bu aşamada, çok katmanlı ileri beslemeli yapay sinir ağı kuruldu. YSA uygulamalarında önemli bir yeri olan perseptron yapısı özellikle çok katmanlı ve geri yayımlı modeli ile örüntü sınıflandırma problemlerinde sıkça kullanılmaktadır. Çok katmanlı ağlarda nöronlar katmanlar şeklinde organize edilmiştir. Çok katmanlı yapay sinir ağlarının eğitiminde geri yayılım (backpropagation) algoritması kullanılmıştır. Burada tek gizli katmana sahip bir ağ yapısı yeterli olmuştur. Şekil 2.29'da olduğu gibi, ağımız 5 girdi, 10 tane gizli nöron ve bir çıkıştan oluşmaktadır. Çıkış değeri (y_t) ile geçmiş N gözlem değerinden oluşan girişler ($y_{t-1}, y_{t-2}, \dots, y_{t-N}$) arasındaki ilişki denklem (2.57)' de verilmiştir [125].

$$y_t = w_o + \sum_{j=1}^p w_j f \left(v_{0j} + \sum_{i=1}^N v_{ij} y_{t-i} \right) + e_t \quad (2.57)$$

Eşitlik (2.57)'de, p gizli nöron sayısını, w_j , v_{ij} nöronlar arasındaki ağırlık değerlerini, f ise gizli katmanda kullanılan doğrusal olmayan aktivasyon fonksiyonunu göstermektedir [125]. Bu aşamada, çalışmalarda en çok tercih edilen aktivasyon fonksiyonlarından biri olan sigmoid fonksiyon (2.58) kullanılmıştır.


$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.58)$$

2.5.3.2. Destek Vektör Makineleri


Verileri en uygun olarak iki kategoriye ayıran n -boyutlu bir hiperdüzlem oluşturmak için Destek Vektör Makinesi (DVM) kullanılmaktadır. Esasında, DVM'de sigmoid bir kernel fonksiyonu kullanan iki katmanlı ileri beslemeli bir yapay sinir ağına sahiptir [126].

Bu yöntemde temel olarak doğrusal ayrıştırılabilen veri yapıları için en iyi ayırıcı hiperdüzlem belirlenerek sınıflandırma gerçekleştirilir. Ancak, çoğu sınıflandırma probleminde veriler uzaya doğrusal olarak dağılmamakta ve ayrıştırılamamaktadır. Özellikle, bu çalışmada olduğu gibi yüksek boyutlu veri ve özelliklerinin sınıflandırılması problemlerinde bu durumla sıklıkla karşılaşmaktadır. Bu yöntemde öznitelik uzayında doğrusal ayrıştırılamayan veriler çeşitli dönüşümlerle farklı boyutta ve doğrusal ayrıştırmanın gerçekleştirilebileceği öznitelik uzaylarına taşınarak sınıflandırılmaya çalışılır [127-129].

Destek Vektör Makinelerinde karşılaşılabilecek iki durum, verilerin lineer olarak ayrılacak yapıda olması veya lineer olarak ayrılacak bir yapıda olmasıdır. Lineer olarak ayrılabilme durumu olduğunda, iki değerli veriler direkt olarak aşırı düzleme ayırıcı (aşırı düzlem) ile ayrılabilir. DVM'nin amacı, bu aşırı düzlem ayırıcının iki ayrı sınıfta bulunan örnek grubuna eş uzaklıkta olmasını sağlamaktır [116].



Şekil 2.30. Lineer ayrılabilir durumda en uygun ayırıcı aşırı düzlem [128]



Şekil 2.31. Birbirinden doğrusal olarak ayrılamayan veriler [128, 130]

Lineer ayrılabilir durumda veriler iki sınıfa doğrusal bir düzlem ile ayrılabilirdi. Uygulamada bu durum her zaman geçerli olmayabilir. Yani doğrusal bir düzlem ile veriler birbirinden ayrılmayabilir. Verilerin doğrusal olarak ayrılamadığı durumlarda doğrusal olmayan sınıflandırıcılar kullanılır. Bu durumda giriş uzayı X 'den daha yüksek boyutlu uzaya dönüşüm yapılır ve sınıflandırma işlemi bu uzayda gerçekleştirilir. H uzayı olarak ifade edilen bu uzaya olan dönüşüm (2.59) ile ifade edilen ϕ dönüşümü ve K çekirdek fonksiyonları ile gerçekleştirilir [131].

$$K(x, z) = \phi(x) \cdot \phi(z), \quad \forall x, z \in X \quad (2.59)$$

Birçok uygulama alanında olduğu gibi verilerinin sınıflandırılmasında da veri setinin tam veya belirli bir hatayla doğrusal olarak ayrılması mümkün olmamaktadır. Bu durumda veriler üzerinde sınıflandırma işlemi çekirdek fonksiyonları kullanılarak verinin yüksek boyutlu başka bir uzaya taşınması ve bu uzayda doğrusal ayırıcı hiperdüzlemin aranması ile gerçekleştirilir. Literatürde yaygın olarak kullanılan diğer çekirdek fonksiyonları: Doğrusal (2.60), Polinomiyal (2.61), Radyal Tabanlı (2.62), Sigmoid (2.63) ve RBF (2.65) çekirdek fonksiyonlarıdır [131]. Bu aşamada, doğrusal ayrılamayan veri kümesi, radyal tabanlı çekirdek fonksiyonları kullanılarak doğrusal ayrıştırmanın gerçekleştirilebileceği daha yüksek boyutta bir uzaya taşınmıştır.

$$K(x, z) = (x \cdot z) \quad (2.60)$$

$$K(x, z) = (x \cdot z + 1)^d \quad (2.61)$$

$d > 0$ çekirdek fonksiyonunun derecesini belirleyen bir sabittir.

$$K(x, z) = \exp\left(-\frac{\|x - z\|^2}{2\sigma^2}\right) \quad (2.62)$$

$\sigma > 0$ çekirdek fonksiyonunun genişliğini belirleyen bir sabittir.

$$K(x, z) = \tanh(\gamma xz + \Phi) \quad (2.63)$$


$$K(x, z) = \exp(-\gamma \|x - z\|^2) \quad (2.64)$$

2.5.3.3. k-En Yakın Komşu Sınıflandırıcı

KEYK sınıflandırıcı, eğitim kümesinin sınıf etiketlerine dayanarak bilinmeyen sınıf etiketini bulmayı hedefler. Bu veri kümesi büyük bir matristen oluşabilir. Satırlar eğitim vektörleri (N) ve sütunlar eğitim örnekleri (M) olarak adlandırılır. Sınıf etiketini temsil eden ek bir sütun daha vardır. Belirli bir mesafe ölçüsü (örneğin, Öklid ya da Manhattan) kullanarak sorgu vektörü ve tüm eğitim vektörlerin arasındaki mesafeleri hesaplayarak sınıflandırıcı çalışmaktadır. Eğer bir sorgu M boyutlar ile $X = \{X_1, X_2, \dots, X_M\}$ olarak tanımlanır ve N eğitim vektörlerin her biri $Y_{NM} = \{Y_{N1}, Y_{N2}, \dots, Y_{NM}\}$, ve $L = \{L_1, L_2, \dots, L_N\}$, eğitim vektörlerin sınıf etiketi olursa, Öklid ölçüsü kullanarak bir eğitim vektörü Y ve bir sorgu X arasındaki mesafe (2.65) ile hesaplanır. Burada $D(X, Y)$, iki vektör X ve Y arasındaki mesafedir [132, 133].

$$D(X, Y) = \sqrt{\sum_{i=1}^M (X_i - Y_{Ni})^2} \quad (2.65)$$

Mesafe hesaplama fazının sonunda, bir sorgu ve N eğitim vektörlerin her birinin bütün örneklerinin arasındaki toplanmış mesafelere karşılık gelen N mesafeler karşılaştırılır. Sonra sınıflandırıcı, K-minimum mesafeler elde eder ve K en yakın komşular veya KEYK olarak bilinen K en yakın eğitim vektörleri ile ilişkili sınıf etiketleri ile birlikte azalan bir şekilde sıralar. Son olarak, sınıflandırıcı en çok karşılaşılan KEYK ye sorguyu atamak için KEYK üzerinde bir oylama gerçekleştirir. K-en yakın komşu yönteminde sınıflandırma yapabilmek için kaç adet en yakın komşu sayısının katılacağı, k gibi bir pozitif tam sayı ile belirtilir [134]. Eğer k=1 ise sınıflandırmaya çalıştığımız nesne en yakın komşusunun bulunduğu sınıfa dahil olacaktır. Örneğin, Şekil 2.32’de w_1 , w_2 ve w_3 olmak üzere üç adet sınıf olduğu varsayalım ve bilinmeyen bir x_u örneği sınıflandırılmaya çalışalım. k=5 değeri için 5 en yakın komşu incelendiğinde 4 adet komşunun w_1 sınıfında olduğu, 1 adet komşunun ise w_3 sınıfında olduğu görülmektedir. Baskın olan taraf w_1 olduğu için x_u örneği w_1 sınıfına dahil olur.

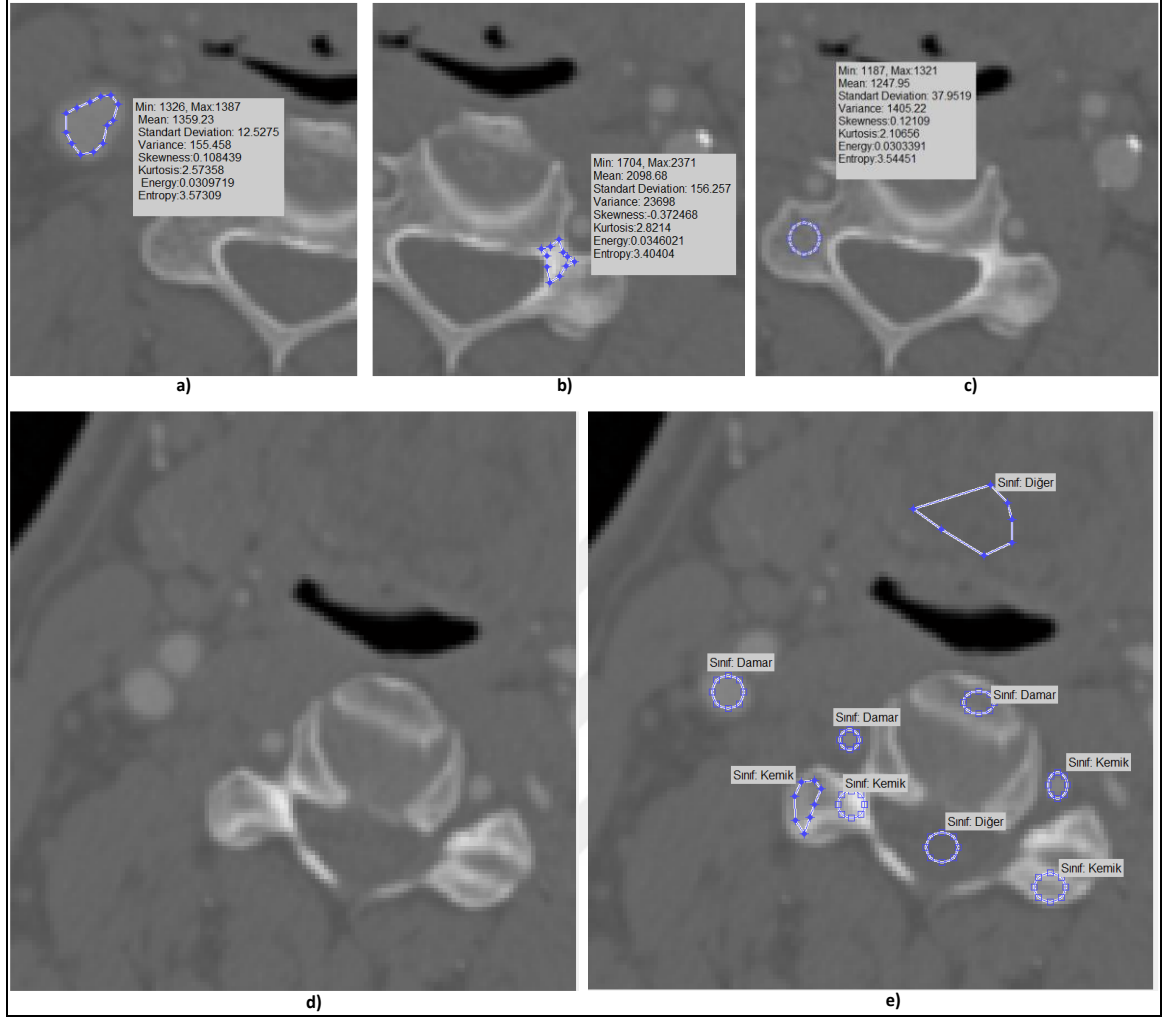


Şekil 2.32. k-en yakın sınıflandırma örneği [135]

Çalışmada, k- NN sınıflandırıcısının k parametresi 1'den 10'ye kadar sırayla denenmiş ve doğruluk oranları elde edilmiştir. Sınıflandırma sonuçları 10-kat çaprazlama yöntemi ile elde edilmiştir. 10 katlı çapraz onaylamaya göre sınıflandırma hatası en düşük k=5 için oluşmuştur.

Çapraz geçerylemede eğitim kümesi eşit büyüklükteki birbiriyile kesişmeyen altkümelere ayrılır. Her bir altküme için eğitim geri kalan alt kümelerin birleşim kümesinde yapılır. Test performansı ise ilgili altküme üzerinde hesaplanır. Bir sınıflandırıcının yeni örnekler üzerindeki beklenen hata oranı bu altkümeleredeki hata oranlarının ortalaması alınarak bulunur.

İlerleyen bölümde sınıflandırıcıların performans değerlendirmesi yapılırken de benzer şekilde sınıflandırıcıların test sonuçlarının daha güvenilir olması için k-katlı çapraz onaylama kullanılmıştır. K-katlı çapraz onaylamada, orijinal veri kümesi, rasgele k tane alt kümeyle bölünmüştür [136]. Modeli test etmek için onay verisi olarak k tane alt kümeden tek bir alt küme alınmış ve geriye kalan k-1 alt küme eğitim verisi olarak kullanılmıştır. Daha sonra bu çapraz onaylama işlemi yani onay verisi olarak her bir k alt kümesi kullanılarak k kez tekrar edilmiştir. Sınıflandırıcıların test doğruluğunu, bu katlardan elde edilen k sonuçlarının ortalaması vermektedir [137, 138].

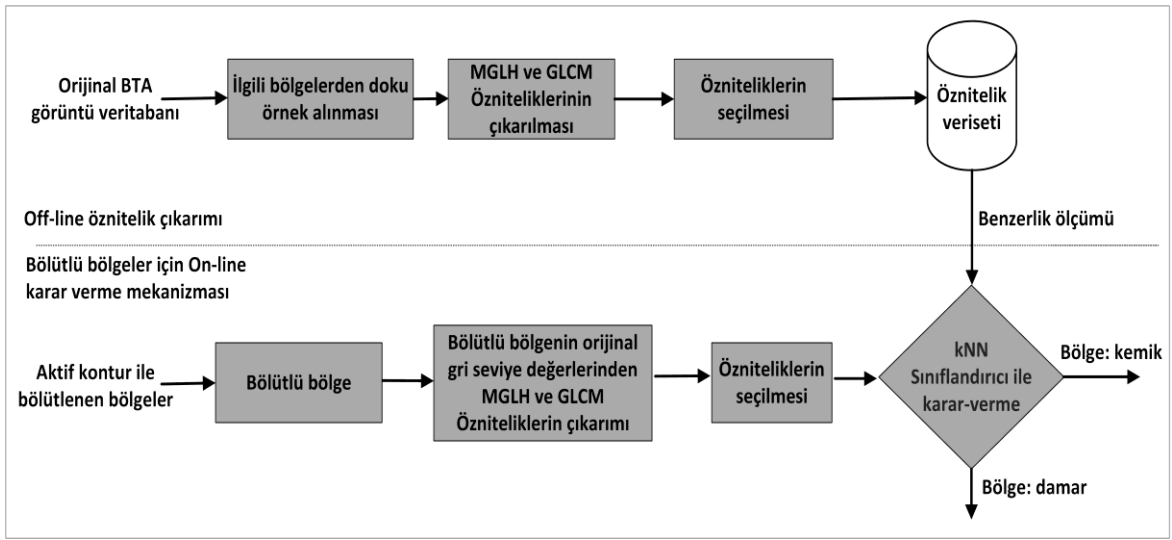


Şekil 2.33. Bölgesel doku öznitelikleri ile eğitimi tamamlanmış sınıflandırıcının test edilmesi: (a), (b), (c), bölgesel doku örnekleri ile özniteliklerin çıkarılması, eğitim için etiketlenmesi (d), (e) girdi bir BTA'da sorgulanan bölgelerin sınıflandırıcı ile tanınması

Şekil 2.33'de uygulamasının basit, sınıflandırma başarısının istenilen seviyede yüksek ve tepki süresinin kısa olmasından ötürü kullanılan k- NN sınıflandırıcısının test edilmesi görülmektedir. Şekil 2.33'de görüldüğü üzere daha önce damar-kemik bölgelerinden alınan örneklere ve tanımlı etiketlere göre oluşturulan öğrenme kümesi üzerinden öğrenme işleminin yapılması ve daha sonra sınıfı belli olmayan bölgelerin bu danışmanlı öğrenmeye sorularak sınıflandırılması yapılmaktadır.

2.5.4. Bölütlü Bölgelerin Sınıflandırılması

Bu çalışmanın son işleme (post-processing) aşamasında faydalandığımız sınıflandırma temelli karar verme mekanizması bir diğer çalışmamızda da kullanılmıştır [139]. Bozkurt ve diğerleri [139], bu tez kapsamında bölge-tabanlı aktif kontur ve sınıflandırma ile BTA görüntülerinden karotid arter bölütlemesi çalışmasını yaptılar.



Şekil 2.34. Bölge-tabanlı aktif kontur ve sınıflandırma ile karotid arter bölütlemesinde uygulanan yöntemin genel blok diyagramı

Şekil 2.34'de BTA'dan bölge-tabanlı aktif kontur ve sınıflandırma ile karotid arter bölütlemesinde uygulanan yöntemin genel blok diyagramı görülmektedir. Bu çalışmada, daha önce ilgili doku bölgelerinden alınan örneklere göre eğitim tamamlanmış bir sınıflandırıcıya aktif kontur ile bölütlü bir bölgenin sorularak damar-kemik ayırımını yapan karar verici yapı kurulmuştur. Bozkurt ve diğerleri [139] bu çalışmada, daha önce damar-kemik bölgelerinden alınan örneklere ve tanımlı etiketlere göre oluşturulan öğrenme kümesi üzerinden öğrenme işleminin yapılması ve daha sonra sınıfı belli olmayan (aktif kontur tabanlı bölütleme ile bölütlü) bölgelerin bu danışmanlı öğrenmeye sorularak sınıflandırılmasını yaptılar. Daha önce damar ve kemik bölgelerinden örnek alınarak oluşturulan eğitim verisi setindeki öznitelik uzayındaki her eksen bir tane örnek bölgenin özneliğini temsil eder. Öğrenme kümesi, öznitelik değerlerine göre öznitelik uzayına

eklemiş olan sınıflandırma öncesi örneklerden ibarettir. En uygun sınıflandırıcı seçimi için öncelikle arama uzayındaki eğitim verisinin dağılımı analiz edilmiştir. Bu analizin sonucunda sınıfın doğrusal ayrılabilirlik derecesi BTA görüntüdeki karotid arter damar bölütlemesinde gerekli doğruluk seviyesi için yeterli olmadığı görülmüştür. Bu yüzden doğrusal olmayan sınıflandırıcı kullanarak, k - NN sınıflandırıcısı tercih edilmiştir. Bu aşamada, damar ve kemik gibi gri-seviye değeri yüksek olan bölgelerin aktif kontur tabanlı bölütlenmesi ve daha sonra bölütlü bölgelerin sınıflandırılması işlemi yapılmaktadır.

Bu sayede bu tezin son işleme aşamasında da faydalandığımız bölütlü bölgelerin sınıflandırılması ile bölütlü bölgelerin damar ya da damar dışı yapılar olduğuna dair bir karar verme mekanizması sağlanmıştır.

2.5.4.1. Bölge-Tabanlı Aktif Kontur Bölütleme

Kontrast madde verilmiş damar bölgeleri ve kemik bölgeleri, BTA taraması ile yüksek gri seviye parlaklık seviyesine sahip bölgelerdir. Bu bölgelerin sınırları bölge tabanlı aktif kontur bölütleme ile bulunmaktadır. Aktif kontur yöntemi, sınırları gelişen eğriler ile tespit edilen nesnelere bölütlemeye etkin bir yol sağlar [140]. Bölge tabanlı aktif kontur modeli aktif kontur hareketini yönlendirmek için ilgili her bölgeyi belirli bir bölge tanımlayıcısı kullanarak tanımlamayı hedefler ve görüntü gradyantını kullanmaz. Bu nedenle zayıf nesne sınırları olan görüntülerde daha iyi performans verebilir. Bölge bazlı aktif kontur modeli, değişken düzeyde küme yapısında (framework) görüntü bölütlemesi için global yoğunluklu enerji ayarlaması temeline dayanır. Bu yöntem, global görüntü bilgisinden etkili bir şekilde faydalanır ve istenilen sınırdaki gelişen eğriyi durdurmak için herhangi bir kenar fonksiyonuna bağlı değildir.

Chan-Vese'nin "active contours without edges" yönteminde [141], fonksiyonel olarak 'minimal ayırma problemi' ve verilen eğri (curve) $C = \partial\omega$, $\omega \subset \Omega$ bir açık küme ile, ve iki tane bilinmeyen sabit c_1 ve c_2 ile temsil edilmektedir. Chan-Vese, c_1 , c_2 ve C ile enerjiyi minimize eden (2.66) ifadesini önermektedir.

$$F(c_1, c_2, C) = \int_{\Omega_1=\omega} (\mu_0(x, y) - c_1)^2 dx dy + \int_{\Omega_2=\omega} (\mu_0(x, y) - c_2)^2 dx dy + \nu |C| \quad (2.66)$$


Bu yöntemde, ilk iki terim iki kuvvete yorumlanır. İlk terim kontürü küçültmek için olan kuvettir. İkinci terim ise kontürü genişletmek için olan kuvettir. Bu iki kuvvet kontur, ilgilendiğimiz nesnenin sınırlarına ulaştığı zaman dengeli hale gelmektedir. Burada sadece $F_1 = 0$ ve $F_2 = 0$ olması durumunda enerji uydurması (energy fitting=0) tamamlanmakta, aksi durumlarda ise devam etmektedir.

$$F_1(C) + F_2(C) = \int_{\text{inside}(C)} |\mu_0 - c_1|^2 dx + \int_{\text{outside}(C)} |\mu_0 - c_2|^2 dx \quad (2.67)$$

F_1 ve F_2 nin sıfır ve sıfırdan büyük olma gibi bütün olası ihtimalleri göz önüne alındığında, eğri C kontur nesnenin sınırlarında olduğu zaman yani $F_1 = 0$ ve $F_2 = 0$ olması durumunda sadece uydurma enerji (fitting energy) minimize edilmiştir. Bunun sonucunda artık C bir dengeye ulaşmıştır. Dolayısıyla nesnenin konturu bulunabilmekte ve bölütlemesi yapılabilmektedir. Bu sayede, gri seviye değeri yüksek olan damar ve kemik bölgelerinin sınırları belirlenerek damar ve kemik bölgeleri bölütlenmektedir.

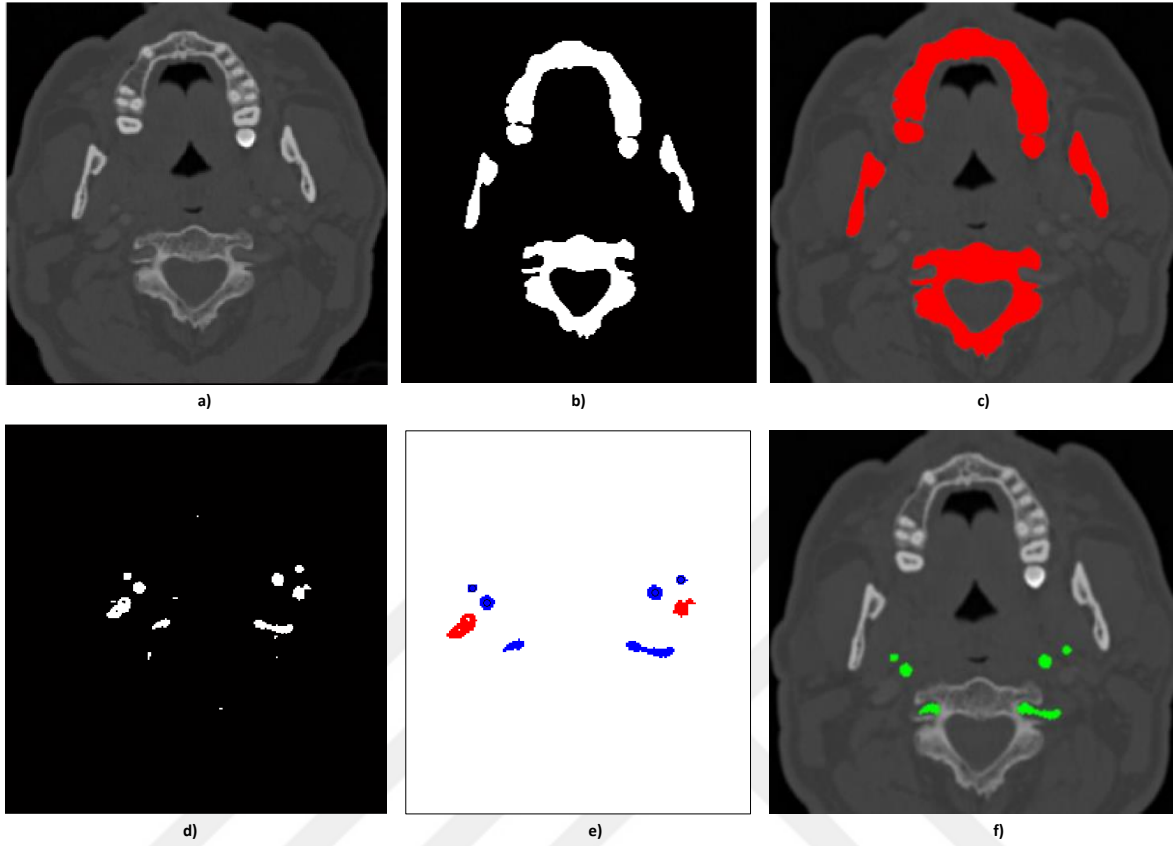
2.5.4.2. Sınıflandırıcı ile Karar-Verme Mekanizması

Damar ve kemik gibi gri seviye değeri yüksek olan bölgelerin bölütlenmesi sonrasında, damar ile birlikte kalan gürültü yapılarının damardan ayırt edilmesi gerekmektedir. BTA görüntülerinden sadece karotid arterlerin bölütlenmesi için, görüntüde kemik parçalarının ve damara benzer gürültülerin çıkarılması gerekmektedir. Son işleme aşamasında kullanılan sınıflandırıcı ile karar-verme mekanizması tam olarak bu ayırt etme işlemini gerçekleştirmektedir. Şekil 2.35'de tersinir bölütleme ile damar bölütlemesi yapılmış görüntü üzerinde uygulanan son işleme aşaması sonuçları bulunmaktadır. Bu aşamada, tersinir bölütleme sonrası damar bölütlemesi yapılan Şekil 2.35 (c)'deki görüntü üzerinden, Şekil 2.35 (d)'deki gibi morfolojik işlem uygulanmış, Şekil 2.35 (e)'deki gibi görüntüde damar dışı kalıntıların varlığı gözlenmiş olup bu kalıntıların sınıflandırıcı ile ayırt edildiği görülmektedir. Burada ikili görüntünün renklendirilmesiyle damarlar mavi, damar dışı kalıntılar kırmızı olarak gösterilmiştir. Şekil 2.35 (f)'de ise nihai sonuç damarların orijinal görüntüde gösterimi yine renklendirilerek gösterilmiştir.




Şekil 2.35. Tersinir bölütleme ile damar bölütlemesi yapılmış bir görüntü üzerinde son işleme aşamasının uygulanması: (a) orijinal verinin ön-işlemeden geçirilmesi, b) tersinir yöntem ile kemik dokunun çıkarılması, c) damar bölütlemesi, d) morfolojik işlemin uygulanması, e) sınıflandırıcı ile karotid damar ve karotid damar dışı gürültülerin birbirinden ayırt edilmesi f) sonuç damarların orijinal görüntüde gösterimi

Şekil 2.36’da benzer şekilde tersinir bölütleme ile damar bölütlemesi yapılmış görüntü üzerinde uygulanan son işleme aşaması sonuçları bulunmaktadır. Bu aşamada, tersinir bölütleme sonrası damar bölütlemesi yapılan Şekil 2.36 (b-c)’deki görüntü üzerinden, Şekil 2.36 (d)’deki gibi morfolojik işlem uygulanmış, Şekil 2.36 (e)’deki gibi görüntüde damar dışı kalıntıların varlığı gözlenmiş olup bu kalıntıların sınıflandırıcı ile ayırt edildiği görülmektedir. Burada ikili görüntünün renklendirilmesiyle damarlar mavi, damar dışı kalıntılar kırmızı olarak gösterilmiştir. Şekil 2.36 (f)’de ise nihai sonuç damarların orijinal görüntüde gösterimi yine renklendirilerek gösterilmiştir.



Şekil 2.36. Tersinir bölütleme ile damar bölütlemesi yapılmış bir görüntü üzerinde son işleme aşamasının uygulanması: (a) orijinal verinin ön-ışlemden geçirilmesi, b-c) tersinir yöntem ile kemik dokunun çıkarılması, d) damar bölütlemesi, e-f) morfolojik işlemin uygulanması ve sonrasında sınıflandırıcı ile karotid damar ve karotid damar dışı gürültülerin birbirinden ayırt edilmesi f) sonuç damarların orijinal görüntüde gösterimi

Şekil-2.37’de bölge-tabanlı aktif kontur bölütleme ile gri seviye değeri yüksek olan damar ve kemik bölgelerinin sınırlarının belirlendiği görülmektedir. Aktif kontur tabanlı bölütleme ile bölütlenmiş sınıflı belli olmayan bölgelerin danışmanlı öğrenmeye sorularak sınıflandırılması yapılmıştır. Buna göre; kırmızı bölgeler kemik bölgelerini, mavi bölgeler ise damar bölgelerini göstermektedir.

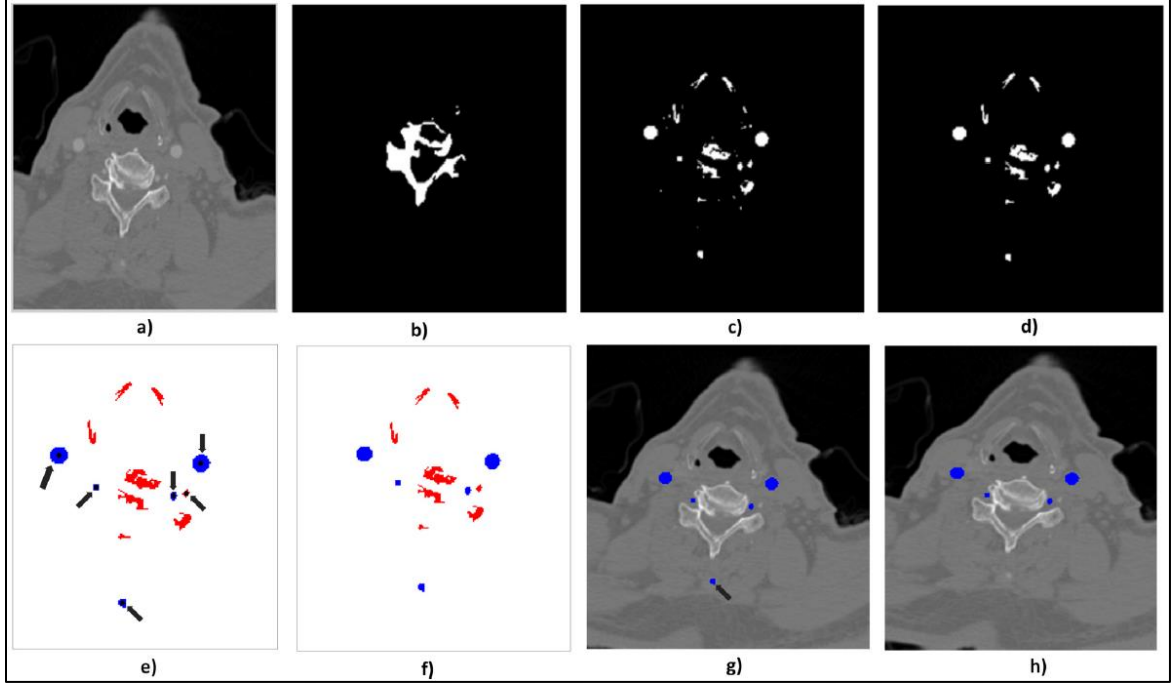


Şekil 2.37. Bölge-tabanlı aktif kontur ve sınıflandırma ile BTA görüntülerinden karotid arter bölütlemesi [139]

2.6. Damar Takibi

Şekil 2.38'da yöntemin tüm aşamalarında yapılan işlemler örnek bir BTA katmanı için gösterilmektedir. Şekil 2.38 (a)'da görüntü ön-işlemeden geçirildikten sonra, Şekil 2.38 (b-c)'de tersinir yaklaşımla ilk olarak kemiklerin bölütlenmesi ve çıkartılmasından sonra damar bölütlemesi yapılmaktadır. Şekil 2.38 (d)'den sonra sora-işlemeaşamasına geçerek görüntüde morfolojik açma işlemi yapılmaktadır. Şekil 2.38 (e)'de katmandaki tüm bölütlü nesnelere şekilsel özelliğine bakılarak yaklaşık olarak yuvarlak nesnelere tespiti yapılmaktadır, ok ile işaretli yerler bu kontrole uymaktadır. Şekil 2.38 (f)'de damarların gürültü ve kemik fragmentlerinden elimine edildiği görülmektedir. Bu ayırım sonucunda damarın (mavi bölgeler), kemiğin (kırmızı bölgeler) olarak ayrışabildiği görülmektedir. Şekil 2.38 (g)'de ok ile işaretli yerler gibi bölütlü nesnelere varsa damarla ilişkili olmayan kalıntıların çıkarılması özellikle damar sürekliliği dikkate alınarak damar takibi ile elenmektedir. Şekil 2.38 (h)'de tüm işlemler ve damar takibi sonrasında nihai damar bölütleme işleminin bu


katman için gerçekleştirildiği görülmektedir. Bu işlemler çalışma uzayında damar bölütlemesi yapılacak tüm katmanlarda yapılmaktadır.




Şekil 2.38. Bir BTA diliminde damar bölütlemesinde gerçekleştirilen tüm işlemler: (a) orijinal verinin ön-ışlemden geçirilmesi, b) tersinir yöntem ile kemik dokunun çıkarılması, c) damar bölütlemesi, d) morfolojik işlemin uygulanması, e) şekilsel bilginin elde edilmesi, f) sınıflandırıcı ile karotid damar ve karotid damar dışı gürültülerin birbirinden ayırt edilmesi g) damar merkezlerinden damar takibinin yapılması, h) sonuç damarların orijinal görüntüde gösterimi

Damar takibi aşamasında daha önce iki boyutlu olarak her katmanda çıkarılan damarların takibi, süreklilik esas alınarak yapılmaktadır. Şekil 2.39'deki gibi her katmanda iki boyutlu kesit olarak damarlar bölütlenmiştir. Bu aşamada damarla ilişkili olmayan kalıntıların elimine edilmesi ya da tam tersi durumda bir katmanda bir damarın tamamen kemiğe karışması durumunda alt ve üst katmanlarda damarın varlığı kontrol edilerek o bölgede lokal bölge büyütme ile damarın bölütlemesi yapılmaktadır. Damar bölütlemesinin yapıldığı çalışma uzayımızda en alttaki ortak karotid arterlerden başlayarak yukarı doğru damar merkezini referans alarak süreklilik esaslı damar takibi yapılmaktadır. Genelde en alttaki Aort şah damarların olduğu katmandaki damarların etrafında kemik olmadığı için ve damarlar hatasız olarak bölütlenbildiği için bu damarları başlangıç noktası olarak

alınmaktadır. Bu damarlar iki ana karotid ve iki tane vertebral damarlardır. Örneğin Şekil 2.40 (a)'da işaret edilen damar 1 nolu vertebral damarın başlangıç noktasıdır. Şekil 2.40 (a)'daki eksenel görüntüde iki ana karotid iki tane de vertebral damar başlangıç noktası mevcuttur. Bu damarları başlangıç noktaları olarak yukarı doğru çalışma uzayımızda diğer katmanlarda bulduğumuz bütün OKA, İKA, EKA ve VA damarları takip ederek bulunduğumuz katmanın alt tabaka üst tabakasına bakarak damar takibi yapılmaktadır. Bu işlem, arada damar kopukluklarının olduğu yerleri tespit etmekte büyük kolaylık sağlamaktadır. Bu şekilde damar bölgeleri, üç boyutlu ortama geçmeden önce damarlarda alt üst katmanlarda süreklilik olacak şekilde çalışma uzayımızda takip ederek birleştirilmektedir.



Şekil 2.39. Bölümlü damar en kesitlerinden damar merkezleri ile süreklilik esaslı damar takibinin gösterimi




Şekil 2.40. Aort bölgesinden damar takibi başlangıç noktasının bir BTA tabakasındaki: a) eksenel, b) koronal ve c) sagittal görünümü

2.7. Görselleştirme

Tıbbi görüntüleme ve bilgisayar teknolojisindeki gelişmelerle birlikte, tıbbi klinikte büyük değişim vardır. Tıbbi görüntülerin görselleştirilmesi, quantitative ve qualitative analiz yapabilmemiz için iki boyutlu bir dizi görüntü kullanarak üç boyutlu görüntü modeli oluşturma sürecidir. İki boyutlu kesit görüntülerden üç boyutlu sezgisel model kurulumu, tıbbi görüntüleme verisi için hastalık tespitinde teşhis amaçlı temel işler. Bölütlenmiş karotid arter kesit görüntülerinin, yeniden yapılandırma (reconstruction) ve görselleştirme süreci; 3B yüzey işleme (surface-rendering) yeniden yapılandırma ve 3B dijital görselleştirme uygulamasını içerir. Bu aşamanın amacı daha önce bölütlenmiş iki boyutlu görüntülerden 3B yeniden yapılandırma işleminin ve görselleştirmesinin yapılmasıdır.

2.7.1. 3B Yeniden Yapılandırma

3B yeniden yapılandırma işlemi Şekil 2.41'deki gibi, bölütlenmiş 2B görüntü kümesi kullanılarak 3B voksel tabanlı hacimsel veri oluşturma işlemidir. İki boyutlu (2B) her BTA görüntüsü hacimsel veri içinde kendi doğru konumuna yerleştirilir [142, 143]. Bunun sonucunda, diğer iki boyutlu görüntülemeler ile bakıldığında bütün 2B görüntü bilgisi korunur. Bu çalışmada yüksek kontrast ile BT tarayıcısından paralel çekilerek alınan 2B görüntü yığını verisine uygulanan bölütleme işlemi tamamlandıktan sonra, bu aşamada 3B yeniden yapılandırma ile 3B hacimsel veri oluşturulmuştur.



Şekil 2.41. 2B görüntü kümesini kullanarak 3B voksel tabanlı hacimsel veri oluşturma

Yüzey işleme (surface rendering) ve hacim işleme (volume rendering) DICOM görüntüler için üç boyutlu yeniden yapılandırma ve görselleştirme uygulaması elde etmede alışık yöntemlerdir [144]. 3B veri alanından kontur (contour) çıkarma ihtiyacı ile iso-surface görüntülemek için bilgisayar görüntü teknolojilerinden yararlanma işlemi surface rendering algoritması olarak tanımlanır. Marching Cubes, Dividing Cubes, ve Cuberille sık kullanılan surface rendering yöntemleridir [145]. Surface Rendering (SR) tekniği, iso-surfaces olarak anılan yüzeyler (surfaces) kümesi gibi 3B nesneyi görselleştirir. Her yüzey bütün katmanlar üzerinde iso-value diye adlandırılan benzer intensity değerine sahip noktalar içerir [146]. Her ne zaman bir yapının yüzeylerini yakın yapılardan (baş katmanından kafatası, vücut katmanından kan damar sistemi v.b.) ayrı görmek istediğimizde bu teknik kullanılır. SR tekniği yüksek kontrastlı veriler için daha çok kullanılır. Dolayısıyla mevcut orijinal DICOM veriler yüksek kontrastlı verilerden oluştuğu için çalışmanın bu aşamasında SR tekniği tercih edilmiştir. Iso-surfaces lerin yeniden yapılandırmasında iki ana yöntem aşağıdaki gibi düşünülebilir. (1) Kontur tabanlı yeniden yapılandırma (Contour based reconstruction): her katmandan çıkarılan Iso-contours, iso-surfaces yaratmak için birleştirilebilir. (2) Voxel tabanlı yeniden yapılandırma (voxel based reconstruction): Iso-surfaces ler, aynı iso-value ya sahip voksellerden direk kurulur. Bu aşamada iso-surfaces yeniden yapılandırmasında kontur tabanlı yaklaşımı tercih edilmiştir.

Üç boyutlu yeniden yapılandırmada marching cubes algoritması kullanıldı. Marching cubes üç boyutlu hacimsel veriden isosurfaces polygonal mesh elde etmek için kullanılan bilgisayar grafik algoritmasıdır. Burada isosurface volume uzayı içinde sabit bir değeri işaret eder. Marching cubes, yalnızca vokseller (yani kübik hücreler) ile birlikte çalışır. Yürüyen küpler algoritmasıyla tüm kübik hücreler kesiştirilir. Vokselleri bireysel olarak analiz ederek, şayet sekiz köşe noktası arzu edilen isovalue nin (isovalue, isosurface için contour değeridir) “yukarısı” ya da “aşağısı” nda ise hızlı ve kolayca belirlenebilir. Bu sekiz değer her biri kolaylıkla 8 bitlik tek bit sayıyla ifade edilebilir. Öyleki, vokselin i -th verteksi mevcut kartezyan koordinat sisteminde P noktasının koordinatlarıdır. q_i , P (aslında isosurface deki iso-pointler bu noktalarda aynı özellik değerine sahiptir) noktasındaki değer fiziksel özelliğidir, i -th verteksteki S durum değeri isosurfaceden çıkarılan verilen nitelikteki C_0 ifadesi (2.68) ile ifade edilir [147].

$$S = \begin{cases} 1 & q_i \geq C_0 \\ 0 & q_i < C_0 \end{cases} \quad (2.68)$$

Problemin $2^8-1=255$ mümkün kombinasyon vardır. Bu bütün 255 kombinasyon geometrik simetri kullanılarak 15 den aşağı benzersiz çözüme azaltılabilir. Bu noktada kenarlar boyunca noktalar yaratmak için çoğu uygulamalar, basit bir lookup tablosu ve doğrusal enterpolasyon kullanır. Öyle ki, iki nokta $P_i(x_i, y_i, z_i, q_i)$ ve $P_j(x_j, y_j, z_j, q_j)$ olsun doğrusal enterpolasyon teorsine göre iso-point $P(x, y, z)$, (2.69) ile elde edilir [148].


$$\begin{cases} x = x_i + Q(x_j - x_i) \\ y = y_i + Q(y_j - y_i) \\ z = z_i + Q(z_j - z_i) \\ Q = (q_i - C_0)(q_j - C_0) \end{cases} \quad (2.69)$$

Voksel kenarları üzerinde bu iso-pointler hesaplandıktan sonra, bu iso-pointler bir üçgen ya da çokgen şeklinde isosurface in parçası formunda bileştirilir. Bu işlemden sonra vokseller bağlanabilirlik ile birbirlerine bağlanır ve otomatik bir şekilde istenilen bölgenin üçgen tabanlı tel çerçeve görüntüsü çıkarılır. Böyle isosurface görüntüsünü göstermek için; verteks normalleri verilmeli, vertices ve üç koordinat boyunca merkezi farklar alınarak voksel kenarları boyunca enterpolasyon, gradyan kullanılarak hesaplanabilir. Bu koordinat eksenleri [147];

$$\begin{cases} g_x(i, j, k) = \frac{D(x_{i+1}, y_j, z_k) - D(x_{i-1}, y_j, z_k)}{\Delta x} \\ g_y(i, j, k) = \frac{D(x_i, y_{j+1}, z_k) - D(x_i, y_{j-1}, z_k)}{\Delta y} \\ g_z(i, j, k) = \frac{D(x_i, y_j, z_{k+1}) - D(x_i, y_j, z_{k-1})}{\Delta z} \end{cases} \quad (2.70)$$

Eşitlik (2.70)'de $D(x_i, y_j, z_k)$, katman k da piksel (i, j) deki yoğunluğu (density) gösterir. $\Delta x, \Delta y, \Delta z$ küp kenar uzunluklarıdır.

Ayrık 3B yumuşatma (smoothing) algoritması sayesinde, orjinal olanlar arasındaki enterpolasyonlu katmanlar hesaplanmaktadır. Bu yöntem, her bir dilim içinde piksel çözünürlük ve kesit arası mesafesi arasındaki farka rağmen her boyutta homojen olan bir geometrik modelin bilgisayarlı hesabını sağlamaktadır [149]. Şekil 2.42’de ITK ile yumuşatma, 3B yeniden yapılandırma işlemi öncesi ve sonrası 3B görüntü ve bir katmandaki değişiklik görülmektedir.



Şekil 2.42. 3B yeniden yapılandırmanın a-) yumuşatma öncesi, b-)yumuşatma sonrası

2.7.2. 3B Görselleştirme

Bu çalışmada, DICOM verisinin yüzey çıkarımı için ITK [150] ve sonucu görüntülemek için ise VTK [151] kullanıldı. VTK, açık kaynak kodlu 3B bilgisayar grafikleri, modelleme, görüntü işleme, volume rendering, bilimsel ve bilgi görselleştirme için serbestçe kullanılabilir yazılım sistemidir. VTK görselleştirme için, çok geniş ve çeşitli gelişmiş görselleştirme ve volume işleme algoritmalarını destekleyen bir açık kaynak kodlu yazılım paketidir. VTK, bizim tıbbi görselleştirmemize kolaylık ve imkan sağlayacak, çok çeşitli geniş görselleştirme algoritmaları ve ileri modelleme teknikleri ile entegre edilmiş C++ sınıf kütüphanesini içermektedir. VTK ile rahatlıkla rekonstrüksiyon sonucunu

görüntüleyebiliriz. Tecrübeler tıbbi görüntüyü rekonstrüksiyon etmek için ITK ve VTK'nın entegre edilmesinin uygun bir yol olduğunu göstermektedir. ITK-SNAP [152] bu amaçla C++ ile geliştirilmiş açık kaynak kodlu bir yazılımdır. ITK-SNAP, medikal görüntülerin üç boyutlu anatomik yapıların bölütlemesine yönelik ITK üzerine kurulu bir açık kaynak kodlu yazılım paketidir. ITK-SNAP, bölütleme işlemini yarı otomatik şekilde kullanıcı rehberli ve kullanıcı dostu arayüz sağlar. Kaynak kodu aktif geliştirilmektedir, serbestçe kullanılabilir ve kullanıcıları giderek artan bir topluluğa sahiptir. Bu aşamada, VTK kullanarak bir önceki aşamadan bölütlemesi yapılmış katman görüntüler kullanarak 3B dijital yeniden yapılandırma işlemi gerçekleştirildi, daha sonra ITK-SNAP kullanarak, karotid arter damar yapılarının tamamen görselleştirilmesi yapıldı. Şekil 2.43'deki gibi görselleştirilmiş araç ile kullanıcılar, OKA, EKA, İKA, ve VA'leri yakınlaştırma (zoomed), kaydırma (paned), ve döndürme (rotated) yapabilirler. Orthogonal axial, coronal, and sagittal düzlemler (planes) görüntülenebilir. Bu sayede damar değerlendirilmesi daha rahat yapılabilmektedir.



Şekil 2.43. VTK ile görselleştirme ve ITK-SNAP ile bölütlü arterlerin eksenel, koronal ve sagittal düzlemlerinin gösterilmesi

3. BULGULAR

3.1. Karşılaştırma Yapılan Veri Setleri

MICCAI'2009 veri seti de çalışmada referans olarak kullanılmıştır. Bu BTA veri seti üç farklı tıp merkezinden alınarak oluşturulmuştur. Çatallaşma ve internal karotid arterlerin önemine dikkat çeken Hameeteman ve ark. (2011), çatallaşma diliminden itibaren Eksternal karotid arter (EKA)'ya 20 mm'lik mesafede ve İnternal karotid arter (İKA)'ya çatallaşma referans diliminden 40 mm'lik uzaklığa kadar olan kısımdan veri setini kullanmayı önermişlerdir [153].

MICCAI'2009 veri seti içerisinde 15 BTA görüntüsü mevcuttur. Her BTA görüntüsü 466-786 arasında dilimden oluşmaktadır. Her BTA'da bu çalışma uzayında çatallaşma noktasını referans olarak çatallaşma diliminden itibaren yukarı 40 mm ve aşağı 20 mm olacak şekilde yaklaşık 95-134 dilimde damarlar işaretli olarak bulunmaktadır.

Tablo 3.1. MICCAI'2009 veri seti içeriği

BTA	Dilim Sayısı	Çalışma uzayındaki dilim sayısı	İşaretli damar sayısı
1	516	95	133
2	501	96	135
3	466	97	133
4	497	100	138
5	504	95	135
6	524	97	137
7	491	98	140
8	564	97	132
9	539	96	134
10	786	121	158
11	711	121	167
12	570	121	177
13	673	134	182
14	666	134	201
15	748	134	104

MICCAI'2009 veri seti içerisinde 15 BTA görüntüsü mevcuttur. Her BTA görüntüsü 466-786 arasında dilimden oluşmaktadır. Her BTA'da bu çalışma uzayında çatallaşma noktasını referans alarak çatallaşma diliminden itibaren yukarı 40 mm ve aşağı 20 mm olacak şekilde yaklaşık 95-134 dilimde damarlar işaretli olarak bulunmaktadır.

Tablo 3.2. Farabi veri seti içeriği

BTA	Dilim Sayısı	Çalışma uzayındaki dilim sayısı	Uzman tarafından işaretlenen damar sayısı	Uzman doğrulaması ile işaretlenen damar sayısı
1	361	175	65	790
2	379	166	66	784
3	372	155	59	786
4	363	169	63	777
5	352	177	61	728
6	347	165	54	811
7	390	158	59	829
8	375	167	62	835
9	365	173	64	794
10	378	181	67	827
11	383	176	58	732
12	358	161	66	719
13	344	168	65	748
14	389	172	68	757
15	396	180	60	772

Çalışmada kullanılan bir diğer karşılaştırma veri seti, Farabi veri setidir. Karadeniz Teknik Üniversitesi Farabi Hastanesi Radyoloji bölümünden 15 farklı hastaya ait BTA verisi alınarak oluşturulmuştur. Her BTA verisi 347-390 arası değişen çok sayıda dilim görüntüden ibarettir. DICOM görüntüleme yazılımıyla el ile damar işaretlemesi yaptırılmıştır. Öncelikle, farklı BTA görüntülerindeki rasgele seçilen katmanlara radyoloji uzmanına el-ile işaretlemesi yoluyla damar işaretlemesi yaptırılmıştır. Daha sonra bu bilgi ışığında, karşılaştırma yapabilecek veri setini artırabilmek için, çalışma uzayında bulunan tüm internal ve vertebral karotid arter yapılarının işaretlemesi yapılmış olup, işaretli bölgelerin uzman tarafından doğrulaması yapılmıştır.

3.2. Performans Değerlendirme Ölçütleri

Yöntemin performansını değerlendirmek için, üç tip ölçüt kullanılmıştır. (1) İstatistiksel-tabanlı ölçütler, (2) Alan-tabanlı ölçütler ve (3) Uzaklık-tabanlı ölçütlerdir [153-157]. Yöntemin performansı, doğruluk (accuracy) ve üretkenlik (reproducibility) açısından bir radyoloji uzmanı tarafından manuel olarak işaretlenen bölütlemeler ile kıyaslama yaparak değerlendirilmiştir. Benzer şekilde, MICCAI'2009 veri setindeki eğitim sonuçlarına göre testler yapılmıştır.

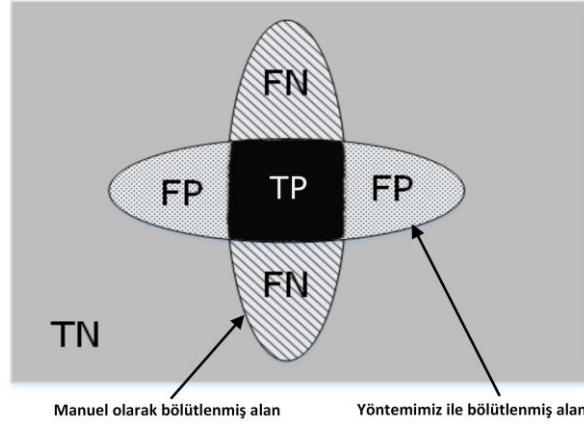
3.2.1. İstatistiksel-tabanlı Ölçütler

Bölütlemenin performansını ölçmek için Tablo 3.3'deki damar için hata matrisi tablosu kullanılır.

Tablo 3.3. Damar için hata matrisi tanımı

	Damar mevcut	Damar yok
Damar tespit edildi	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
Damar tespit edilmedi	Yanlış Negatif (FN)	Doğru Negatif (TN)

İstatistiksel ölçüm yapabilmek için öncelikle, Şekil 3.1'de gösterildiği gibi, yöntemimiz ile bölütlemiş görüntünün doğruluğunu karşılaştırmada kullanılan alanlar tanımlandı. TP; gerçek pozitif piksellerin sayısıdır, yani otomatik ve manuel bölütlemenin birebir eşlendiği piksel sayısıdır. FP; hatalı pozitif piksellerin sayısıdır, yani otomatik bölütlemenin bölütlediği, ancak manuel bölütlemenin yapmadığı piksel sayısıdır. TN; gerçek hatalı piksel sayısıdır, yani otomatik ve manuel bölütlemenin bölütlü olarak eşleşmediği piksel sayısını belirtir. FN; hatalı negatif piksellerin sayısıdır, yani manuel bölütlenenin bölütlü olarak gösterdiği, ancak otomatik bölütlemenin yapmadığı piksel sayısıdır. Bu tanımları kullanarak aşağıdaki istatistiksel ve alan-tabanlı bazı performans metrikler çıkarılmıştır [156].



Şekil 3.1. Yöntemimiz ile bölütlemiş görüntünün doğruluğunu karşılaştırmak için kullanılan alanlar [157]

Duyarlılık, sistemin pozitif örnekleri hangi doğruluk yüzdesi ile sınıflandırıldığını göstermektedir. (3.1) şeklinde hesaplanır.

$$\text{Duyarlılık (Sensitivity-SE)} = \frac{TP}{(TP+FN)} \quad (3.1)$$

Özgüllük (3.2)'de görüldüğü üzere sistemin negatif örnekleri hangi doğruluk yüzdesi ile sınıflandırdığını gösterir.

$$\text{Özgüllük (Specificity -SP)} = \frac{TN}{(TN+FP)} \quad (3.2)$$

Hassasiyet ölçütü sınıflandırma sonuçları arasındaki doğru tahmin edilen örneklerin oranını vermektedir. (3.3) ile hesaplanır.

$$\text{Hassasiyet (Precision -PR)} = \frac{TP}{(TP+FP)} \quad (3.3)$$

Hata matrisi üzerinden sistemin hangi yüzde ile doğru tahmin yaptığının ölçütü olan doğruluk (accuracy) oranı (3.4)'deki gibi hesaplanır.

$$\text{Doğruluk (Accuracy-ACC)} = \frac{(TP + TN)}{(TP + FP + TN + FN)} \quad (3.4)$$

3.2.2. Alan- tabanlı Ölçütler

Bölütleme tekniğinin geçerliliği, yöntem sayesinde otomatik olarak lumen sınırları çıkarılan damarların, manuel olarak uzman klinikçi tarafından sınırları belirtilen alanlara karşılık gelen yerlerin karşılaştırması ile yapılmaktadır.

Alan örtüşmesi (Area Overlap-AO) alanların üst üste gelme oranıdır, yöntem tarafından doğru olarak tanımlanan orantılı alanı ölçer [156, 157].

$$\text{Alan örtüşme (AO)} = \frac{TP}{TP+FN+FP} \times 100\% \quad (3.5)$$

Alan farkı (Area Difference- AD) alan farkı, yöntem tarafından hatalı olarak saptanan oransal alanı ölçer.

$$\text{Alan farkı (AD)} = \frac{FP+FN}{TP+FN+FP} \times 100\% \quad (3.6)$$

Zar benzerliği (Dice Smilarity- DS), iki bölütlemenin benzerlik ölçütüdür [155]. Bu metrik iki veri (manuel ve otomatik bölütleme) arasındaki uyuşma seviyesini ölçmek için kullanılmıştır. Alan için benzerlik katsayısı (3.7) ile hacimsel olarak yüzey için benzerlik (3.8) ile ifade edilmektedir. R_M ve R_A manuel ve algoritma tarafından oluşturulan yüzeylerin çevrelediği bölgeleri gösterir.

$$DS_A = 2x(TP) / ((TP+FN)+(FP+TP)) \quad (3.7)$$

$$DS_Y = \frac{2(R_M \cap R_A)}{R_M + R_A} \quad (3.8)$$

3.2.3. Uzaklık- tabanlı Ölçütler

Uzaklık-tabanlı ölçütler 2B (iki-boyut) için kontur (contour) bazlı ve 3B (üç-boyut) için yüzey (surface) bazlı ele alınmıştır.

Bu ölçüt, manuel ve yöntem ile bölütlenmiş iki tane 2B nesnesi arasında uyumsuzluk derecesi ölçümü için kullanılabilir. Algoritmanın bölütlediği kontur (A)'nın köşelerini $\{a_i : i = 1 \dots K\}$ ve manuel bölütlenmiş kontur (M)'nin köşelerini $\{m_n : n = 1 \dots N\}$ olarak alınır. Daha sonra bir köşe a_i (kontur A) ve kontur M arasındaki uzaklık (3.8) gibi ifade edilir [157].

$$d(a_i, M) = \min_n \|a_i - m_n\| \quad (3.8)$$

Ortalama mutlak fark (Mean Absolute Difference-MAD), her görüntü için bölütlemeye ortalama uzaksal hatayı temsil eder. Bu metrik, yüzey pikseller arasındaki mesafeleri kullanarak iki yüzey arasındaki ortalama farkın tahmininin ölçütüdür.

$$MAD = \frac{1}{K} \sum_{i=1}^K d(a_i, M) \quad (3.9)$$

Ortalama yüzey uzaklığı (Mean surface distance- MSD) metriği, 3B'de yüzey vokselleri arasındaki mesafeleri kullanarak iki yüzey arasındaki ortalama farkı ölçer. (3.10) ile hesaplanır. Bu formüldeki s_{dm_r} ve s_{dm_p} referans (manuel) ve önerilen yöntem bölütlemesinin işaretlenmiş uzaklık haritalarıdır. S_r ve S_p lümen sınır yüzeyleri ve $|S_i|$ ise yüzey S_i 'nin yüzey alanıdır (örnek: $|S_i| = \int_{S_i} ds$).


$$MSD = \frac{1}{2} x \left(\frac{\int_{S_r} |s_{dm_p}| ds}{|S_r|} + \frac{\int_{S_p} |s_{dm_r}|}{|S_p|} \right) \quad (3.10)$$

RMSE, uzaklığın ortalama karesel hatanın kareköküdür (root-mean-squared-error (RMSE) of distance). RMSSD ise 3B'de yüzey (surface) uzaklığı için aynı ifadenin karşılığıdır.

$$RMSE = \sqrt{\frac{1}{K} \sum_{i=1}^K d(a_i, M)^2} \quad (3.11)$$

$$RMSSD = \frac{1}{2} x \left(\frac{\int_{S_r} sdm_p^2 ds}{|S_r|} + \frac{\int_{S_p} sdm_r^2 ds}{|S_p|} \right) \quad (3.12)$$

Maksimum uzaklık farkı (Hausdorff uzaklığı- MAXD), her görüntü için bölütlemeye maksimum hatayı temsil etmektedir. Hausdorff uzaklığı, 3B’de yüzey için MAXSD ile ifade edilir.



Şekil 3.2. Maksimum uzaklık farkı (Hausdorff uzaklığı) [158]


$$MAXD = \max_{i \in [1, K]} \{d(a_i, M)\} \quad (3.13)$$

$$MAXSD = \frac{1}{2} x \left(\max_{x \in S_r} (|sdm_p(x)|) + \max_{x \in S_p} (|sdm_r(x)|) \right) \quad (3.14)$$

3.3. Sınıflandırıcıların Performans Değerlendirmesi

Bölüm 2’de bahsi geçen damar, kemik ve diğer dokulardan alınan lokal örneklerden danışmanlı öğrenme ile eğitimi tamamlanmış karar verme mekanizması üzerinden makine öğrenmesi yöntemleri ile oluşturulan farklı sınıflandırıcıların doğrulukları tablosu Tablo 3.4 ve grafiği Şekil-3.3’deki gibidir. Bu tabloya göre en iyi sınıflandırıcı doğruluğu % 98,8 ile DVM ile elde edilmiştir.

Sınıflandırıcı performansı karmaşıklık (confusion) matrisinden; doğruluk (accuracy), duyarlılık (sensitivity), hassasiyet (specificity), Matthews korelasyon katsayısı (MKK), F-Ölçüsü (F-score), negatif öngör değeri (negative predictive value-NPV) hesaplanarak değerlendirilmiştir.



Şekil 3.3. Farklı sınıflandırıcıların geçerlilik ölçüleri grafiği

Tablo 3.4. Farklı sınıflandırıcıların geçerlilik ölçü sonuçları

	Doğruluk (%)	F-Ölçüsü	MKK	Duyarlılık	Özgüllük	NÖD (%)
DVM	98,8	0,9879	0,9763	0,9999	0,9766	99,4
YSA	98,7	0,9799	0,9645	0,9885	0,9748	98,4
KEYK	98,4	0,9765	0,961	0,9874	0,9712	98,2

Bölüm 2’de veri boyutunun artması ile boyut indirgemeye duyulan gereksinimden bahsedilmiştir. Zaman ve sınıflandırıcıların doğruluğu açısından boyut indirgemenin kazanç sağlayıp sağlamadığı üzerine değerlendirme yapılmıştır.

Tablo 3.5. Boyut indirgeme işlemi yapılmadan önce sınıflandırıcıların doğruluğu ve süreleri

	KEYK	DVM	YSA
Doğruluk (%)	94,8	95,6	95,8
Süre (saniye)	60,6	64,78	528


Tablo 3.6. Boyut indirgeme işlemi sonrası sınıflandırıcıların doğruluğu ve süreleri

	KEYK	DVM	YSA
Doğruluk (%)	98,4	98,7	98,8
Süre (saniye)	15,54	16,22	112

3.4. Bölütleme Sonuçlarının Değerlendirilmesi

Bölüm 2’de damar bölütlemesinde kullanılan bölge büyütme ve rassal yürüyüş yöntemlerinin bölütleme başarısı sonuçları istatistiksel, alan ve uzaklık tabanlı ölçütlere göre incelenmiştir.

Tersinir yöntemin uygulamadaki başarısı, Farabi veri seti üzerinden eğitim verisindeki manuel işaretlemeye göre alan ve uzaklık tabanlı ölçütlere göre kıyaslama ile değerlendirilmiştir. Aynı şekilde MICCAI’2009 veri seti üzerinde yöntemin uygulanması sonrası elde edilen sonuçlar literatürdeki değerlendirme kriterleri baz alınarak, literatürdeki mevcut sonuçlar ile karşılaştırılmıştır.



Şekil 3.4. Damar bölütlemesinde BB ve RY yöntemlerinin bölütleme sonuçlarının kıyaslanması: a) orijinal BTA, b) yakınlaştırılmış görüntü, c-d) BB ve RY bölütleme sonucunun (mavi) ve manuel işaretleme (yeşil) gösterimi, e-f) BB ve RY bölütlemenin manuel olanla kıyaslanması yeşil: örtüşen (overlap), mavi:fazla (over), kırmızı: altında (under) bölütlemeyi gösterir

Tablo 3.7. Damar bölütlemesinde BB ve RY yöntemlerinin başarı kıyaslaması

	SE	SP	ACC	PR	AO (%)	AD (%)	DS _A	MAD (mm)	RMSE (mm)	MAXD (mm)
BB	0.9927	0.9997	0.9996	0.9310	90.46	9.54	92.08	0.10	0.39	2.24
RY	0.9903	0.9997	0.9996	0.9344	90.59	9.41	92.25	0.11	0.41	2.45

Bu tez kapsamında yapılan bir çalışmada [86]; Bölge büyütme (BB) ve Rassal yürüyüş (RY) yöntemlerinin damar bölütlemesi sonuçlarının karşılaştırması yapılmıştır. Bu çalışmada, 10 farklı BTA görüntülerinden, rasgele dilimlerden alınan 56 farklı görüntü üzerinden damar bölütleme karşılaştırması yapılmıştır. Şekil 3.4'deki gibi bölütleme yöntemi ile bulunan damarların manuel ile kıyaslaması ile 2B'de istatistiksel, alan ve uzaklık tabanlı sonuçları Tablo 3.8 ve Tablo 3.9'da çıkarılmıştır [86]. Bu sonuçlara göre; bölge büyütme yöntemi ile %99 doğruluk, %89 Dice benzerliği, 0,12 mm uzaklığın ortalama mutlak farkı (MAD) elde edilmiştir. Rassal yürüyüş yöntemi ile, %99 doğruluk, %90 Dice benzerliği, 0,11 mm MAD elde edilmiştir.

Tablo 3.8. Damar bölütlemede, BB yönteminin 56 görüntü üzerinde başarı değerlendirilmesi

BTA	Görüntü sayısı	İstatistiksel sonuçlar				Alan-tabanlı sonuçlar			Uzaklık-tabanlı sonuçlar		
		SE	SP	ACC	PR	AO (%)	AD (%)	DSA(%)	MAD(mm)	RMSE(mm)	MAXD(mm)
1	5	0.7875	0.9998	0.9994	0.9999	85.76	14.24	88.56	0.11	0.35	2.18
2	7	0.8512	0.9998	0.9994	0.9492	80.66	19.34	88.13	0.13	0.43	2.26
3	6	0.9518	0.9996	0.9996	0.9397	88.92	11.08	87.15	0.15	0.38	2.32
4	4	0.9811	0.9998	0.9997	0.9382	92.75	7.25	92.32	0.07	0.29	1.96
5	5	0.7891	0.9997	0.9995	0.9413	90.25	9.75	89.32	0.09	0.31	2.18
6	6	0.8347	0.9999	0.9994	0.9582	78.48	21.52	88.24	0.13	0.42	2.26
7	8	0.7917	0.9999	0.9996	0.9512	83.78	16.22	89.49	0.10	0.33	2.20
8	6	0.9815	0.9998	0.9997	0.9346	91.88	8.12	90.17	0.15	0.40	2.27
9	5	0.9515	0.9997	0.9995	0.9428	78.87	21.13	87.47	0.14	0.39	2.29
10	4	0.9785	0.9995	0.9994	0.9512	89.85	10.15	89.58	0.12	0.41	2.23

Tablo 3.9. Damar bölütlemede, RY yönteminin 56 görüntü üzerinde başarı değerlendirilmesi

BTA	Görüntü sayısı	İstatistiksel sonuçlar				Alan-tabanlı sonuçlar			Uzaklık-tabanlı sonuçlar		
		SE	SP	ACC	PR	AO (%)	AD (%)	DSA(%)	MAD(mm)	RMSE(mm)	MAXD(mm)
1	5	0.7928	0.9998	0.9995	0.9998	86.39	13.61	89.26	0.10	0.30	2.10
2	7	0.8672	0.9998	0.9994	0.9491	81.99	1.01	88.96	0.12	0.41	2.21
3	6	0.9676	0.9996	0.9996	0.9488	89.25	10.75	88.26	0.14	0.35	2.26
4	4	0.9862	0.9998	0.9997	0.9391	93.59	6.41	93.10	0.06	0.27	1.90
5	5	0.7982	0.9997	0.9995	0.9495	91.17	8.83	90.11	0.08	0.29	2.11
6	6	0.8472	0.9999	0.9994	0.9591	79.17	20.83	88.98	0.12	0.41	2.24
7	8	0.8169	0.9999	0.9996	0.9591	84.89	15.11	90.22	0.09	0.29	2.13
8	6	0.9854	0.9998	0.9997	0.9425	92.25	7.75	90.34	0.14	0.37	2.21
9	5	0.9779	0.9997	0.9995	0.9568	80.33	19.67	88.69	0.13	0.34	2.22
10	4	0.9892	0.9995	0.9994	0.9611	90.59	9.41	90.11	0.10	0.38	2.15

Tersinir bölütleme yaklaşımında, kemik dokunun bölütlenmesi ve çıkarılması ve sonrasında damar bölütlemesi yapılmasında farklı yaklaşımlar bu aşamalarda uygulanmıştır. Kemik bölütlemesi ayrı ayrı bölge büyütme (BB) ve rassal yürüyüş (RY) yöntemleri ile gerçekleştirilmiştir. Benzer şekilde damar bölütlemesinde de farklı yöntemler ile çalışılmıştır. Bu karşılaştırma sonucuna göre, tohum noktalarının ilklendirilmesi her iki yöntemde de aynı eşik aralıklarından verilse de, bölütleme performanslarında farklı sonuçlar elde edilmiştir. Tablo 3.10 sonucuna göre, kemik bölütlemesinde BB yaklaşımını, damar bölütlemesinde RY yaklaşımı ile tersinir yöntem uygulandığında en iyi Dice benzerliği, %92,75 elde edilmiştir. En düşük ortalama yüzey uzaklığı (MSD), 0.16 mm ile elde edilmiştir.

Tablo 3.10. Tersinir bölütleme ile kemik/damar bölütlemesine farklı yöntemlerin uygulanmasından elde edilen uzaklık-tabanlı başarı karşılaştırması


	Tersinir bölütleme		DSY(%)	MSD(mm)	RMSSD(mm)	MAXSD(mm)
	Kemik bölütleme ve çıkarma	Damar bölütleme				
Yaklaşım 1	RY	RY	88.43	0.32	0.40	2.71
Yaklaşım 2	RY	BB	89.26	0.30	0.38	2.27
Yaklaşım 3	BB	BB	92.20	0.18	0.26	1.78
Yaklaşım 4	BB	RY	92.75	0.16	0.24	1.72

Tablo 3.11. Tersinir bölütlemenin uygulanması ile farklı damar noktalarındaki uzaklık ve alan tabanlı ortalama başarı sonuçları

	MAD(mm)		RMSE(mm)		MAXD(mm)		AO (%)		AD (%)		DSA(%)	
	Ortalama	Std	Ortalama	Std	Ortalama	Std	Ortalama	Std	Ortalama	Std	Ortalama	Std
OKA	0.10	0.04	0.36	0.22	1,73	0.9	92.25	4,25	7,75	4,32	93.14	3,21
İKA	0.11	0.03	0.35	0.20	1,89	0.8	91.78	3,20	8,22	5,29	92.91	2,05
EKA	0.13	0.05	0.38	0.25	2,45	1.2	91.58	3,16	8,42	2,25	91.83	2,88
VA	0.12	0.03	0.33	0.18	1,96	0.9	90.46	5,44	9,54	6,41	89.16	3,69
Karotid çatallaşma	0.15	0.06	0.40	0.21	2,64	1.1	89.87	4,10	10,13	4,52	88.91	3,24
Tüm arterler	0.12	0.05	0.37	0.19	1,85	0.7	91.33	6,85	8,67	3,48	92.75	2,75

Tersinir yöntemle, kemik bölütlemesinde BB yaklaşımını, damar bölütlemesinde RY yaklaşımını Farabi veri setine uygulanmıştır. Daha sonra radyoloji uzmanı kontrolünde farklı BTA görüntülerindeki farklı damar noktalarındaki uygulanan yöntemin performans değerlendirilmesi yapılmıştır. Bu farklı damar noktaları; ortak karotid arter (OKA), internal karotid arter (İKA), eksternal karotid arter (EKA), vertebral arter (VA) ve alınan tüm

örnekleri ortalaması tüm arterler olacak şekilde kategorize edilmiştir. Bu kategoriye göre farklı damar noktalarında performans değerlendirilmesi yapılmıştır. Buna göre, Tablo 3.11’de OKA noktalarında en iyi Dice benzerliği, %93,14 olarak, en düşük ise Dice benzerliği %88,91 ile karorid çatallaşma ve %89,16 ile VA noktalarından elde edilmiştir.



Şekil 3.5. Görüntülerdeki örnek farklı damar noktaları ve bölütleme sonuçları

Tersinir yöntemin Farabi veri setine uygulanması ile ortalama Dice benzerliği, %92.75, ortalama yüzey uzaklığı (MSD) ise 0.16 olarak elde edilmiştir.

Tablo 3.12. Farabi 15 BTA verisine uygulanan tersinir yöntemin performans değerlendirilmesi

BTA	DSY(%)	MSD(mm)	RMSSD(mm)	MAXSD(mm)	İşlem süresi
1	93.80	0.18	0.26	1,54	489
2	93.40	0.17	0.24	1,72	360
3	93.70	0.16	0.23	1,45	602
4	89.90	0.18	0.25	2,34	482
5	92.80	0.17	0.23	1,65	389
6	92.60	0.15	0.22	1,68	645
7	92.50	0.16	0.24	1,88	597
8	92.80	0.15	0.23	1,69	496
9	91.30	0.17	0.24	2,21	680
10	93.10	0.19	0.25	1,48	620
11	91.70	0.17	0.26	1,87	535
12	92.40	0.15	0.23	1,63	566
13	93.60	0.16	0.24	1,82	372
14	93.80	0.18	0.26	1,49	402
15	93.90	0.20	0.25	1,41	475
Ort:	92.75	0.16	0.24	1,72	514(std = 103)

MICCAI'2009 veri seti bölütlemesinde, öncelikle kemik bölütlemesinde BB yaklaşımını, damar bölütlemesinde RY yaklaşımı ile sonuçlar alınmıştır. Burada bölge büyütme işleminde bir vokselin komşuları ile olan benzerliği genelleksel ve hızlı yöntem olan ortalama ve standart sapmaya bakılarak işletilmiştir. Daha sonra bu tersinir yöntem voksellerin dokusal tabanlı benzerliğini dikkate alarak tekrar düzenlemiştir. Dokusal tabanlı bölge bölütleme öncesinde tersinir yöntemle, Tablo 3.13'de görüldüğü gibi, Dice benzerliği %90,18 olarak elde edilmiştir. Bu yöntemle tersinir yöntemin çalışma süresi 2 dakika olarak ölçülmüştür.

Benzerlik kriteri, bölgenin dokusal özelliklere bakılarak oluşturulmuştur. Doku tabanlı bölge bölütlemesinde, dokusal tabanlı benzerlik kriteri göz önünde bulundurularak eşik değerinin seçimi otomatikleştirilmiştir. Bölge büyütme işleminde, her vokselin yerel doku tanımlayıcıları kullanılmıştır. Bir vokselin dokusal özelliği bir vektör haline getirilerek tohum olanlar ile Öklid uzaklığı kıyaslaması yapılmıştır.

Tablo 3.13. MICCAI'2009 veri seti için önerilen yöntemin mevcut çalışmalarla kıyaslanması

Çalışmayı yapan	Etkileşim	DS _Y (%)	MSD (mm)	MAXSD (mm)	İşlem süresi
Referans	-	100.0	0.01	0.06	-
Gözlemci A	Manuel	95.1	0.10	0.65	-
Gözlemci B	Manuel	94.6	0.11	0.83	-
Gözlemci C	Manuel	94.4	0.12	0.97	-
Valencia ve diğerleri [159]	Yarı-otomatik	53.6	3.4	12	2 dk
Wong ve diğerleri [160]	Yarı-otomatik	77.5	1.1	11	90 sn
Zuluga ve diğerleri [161]	Yarı-otomatik	80.9	0.82	10	4 dk
Freiman ve diğerleri [162]	Yarı-otomatik	82.9	0.75	9.2	2 dk
Mille ve diğerleri [163]	Yarı-otomatik	83.5	0.74	10	90 sn
Krissian ve Garcia [164]	Yarı-otomatik	87.3	0.54	4.4	15 dk
Tang ve diğerleri [165]	Yarı-otomatik	90.2	0.34	3.45	25 dk
Gülsün ve diğerleri [166]	Yarı-otomatik	91.8	0.18	1.5	50 sn
Cuisenaire [167]	Otomatik	89.6	0.17	1.7	1-2 dk
Tez çalışması	Otomatik	90.18	0.16	1.66	2dk


Literatürdeki mevcut bir çalışmada esas alınarak, 7 öznitelik ve Eş oluşum matrisi için 13 yön kullanılarak tersinir yönleme uyarlanmıştır. Daha sonra bu öznitelikler artırılarak Haralick'in 14 özniteliği ve eş oluşum matrisi için 26 yön olarak tersinir yönleme tekrar uyarlanmıştır. İki vokselin komşuluğuna mevcut çalışmada 6 bağlanabilirlik ile bakılırken, bu çalışmada 26-bağlanabilirlik kullanılmıştır. Bu değişiklikler ile birlikte hem yön sayısının artması hem de artırılan öznitelik sayısı ile büyüyen doku tanımlayıcısı vektörü, tersinir yöntemde işlemlerin daha uzun sürmesine sebep olsa da, benzerlik ölçütü başarısını artırmıştır. Dokusal tabanlı bölge bölütleme eklenerek tersinir yöntemle, Tablo 3.14'de görüldüğü gibi Dice benzerliği %91,8'e ulaşmıştır. Uyarlanmış tersinir yöntemin çalışma süresi ise 20 dakika olarak ölçülmüştür.

Tablo 3.14. Doku tabanlı bölge büyütme yönteminin tersinir yöntemle uyarlanması ile MICCAI'2009 veri seti için performans değerlendirilmesi

	GLCM- Yönü (θ)	Öznitelik Sayısı	Voksel bağlantılığı	Başarı (DiceBenzerliği)	İşlem Süresi
Literatüdeki mevcut çalışma	13	7	6	%88.4	8dk
Teze uyarlanmış çalışma	26	7	6	%89.6	14dk
Teze uyarlanmış çalışma	26	14	26	%91.8	20dk


Tablo 3.15. Literatürde konu ile ilgili farklı BTA veritabanları ile yapılmış diğer çalışmalar

Çalışmayı yapan	Yıl	Etkileşim	Veritabanı	Boyut	Başarı (Dice benzerliği)
van Velsen ve diğerleri [168]	2006	Yarı- otomatik	Rotterdam Tıp Merkezi- BTA verisi	3B	88%
Manniesing ve Niessen [169]	2007	Otomatik	Utrecht Tıp Merkezi-BTA verisi	2B	90%
Manniesing ve diğerleri [170]	2010	Yarı- otomatik	Erasmus Tıp merkezi- BTA verisi	3B	92%
Freiman ve diğerleri [171]	2012	Otomatik	Üç farklı tıp merkezi- BTA verisi	3B	90,64%
Behrens [172]	2013	Otomatik	Özel Klinik- BTA verisi	2B	70%
Hemmati ve diğerleri [173]	2015	Yarı- otomatik	Tehran Kalp Merkezi- BTA verisi	3B	85%
Tez çalışması		Otomatik	Farabi - BTA verisi	3B	92,75%



Şekil 3.6. MICCAI'2009 ve Farabi verilerine ait damar bölütlemelerinin ekran görüntüleri

Kafatası tabanından (skull base) başlayarak Willis çemberi (circle of willis) ne kadar olan kısımda damar ile kemik çok daha yakın komşuluk halindedir. Bu bölgede tersinir yöntemin doku tabanlı bölütleme ile uyarlanması ile daha fazla başarı elde edilmiştir. Daha fazla doku bilgisi ile bölütleme yapıldığında tersinir yöntemin bu bölgede başarısını oranı artmıştır. Öncesinde bu bölgede yapılan bölütlemelerde kemik bölgesine doğru aşırı bölütleme (over segmentation) olmaktadır. Doku tabanlı bölge büyütmenin tersinir yöntemle uyarlanması ile bu aşırı bölütlemeler azalmıştır.




Şekil 3.7. Kafatası bölgesindeki bir BTA görüntüsüne doku tabanlı bölge büyütme yönteminin tersinir yöntemle uyarlanması ile aşırı bölütlemenin azalma durumu: a) öncesi b) sonrası

Tablo 3.16 Kafatası bölgesindeki bir BTA'daki aşırı bölütlemenin tersinir yöntemle azalmasının performans değerlendirilmesi

	SE	SP	ACC	PR	AO (%)	AD (%)	DS _A (%)	MAD (mm)	RMSE (mm)	MAXD (mm)
Öncesi	0,9049	0,9998	0,9997	0,7933	73,24	26,76	84,54	0,06	0,33	2,64
Sonrası	0,8707	0,9999	0,9998	0,9502	83,28	16,72	90,87	0,05	0,28	2,00

Tablo 3.16'daki hassasiyet (precision) değerinin öncesinde düşük olması aşırı bölütlemenin olduğunu göstermektedir. Doku tabanlı bölge büyütmenin tersinir yöntemle uyarlanması ile sonrasında bu değer yükselmiştir. Aynı zamanda Şekil 3.7 görüntüsü için Dice benzerliğinin, %84,54'den %90.87 değerine yükseldiği görülmektedir. Benzer durum Şekil 3.8 ve Tablo 3.17'de de görülmektedir.



Şekil 3.8. Kafatası bölgesindeki bir BTA görüntüsüne doku tabanlı bölge büyütme yönteminin tersinir yöntemle uyarlanması ile aşırı bölütlemenin azalma durumu: a) öncesi b) sonrası

Tablo 3.17 Kafatası bölgesindeki bir BTA'daki aşırı bölütlemenin tersinir yöntemle azalmasının performans değerlendirilmesi

	SE	SP	ACC	PR	AO (%)	AD (%)	DS _A (%)	MAD (mm)	RMSE (mm)	MAXD (mm)
Öncesi	0,8764	0,9996	0,9995	0,6985	63,59	36,41	77,74	0,06	0,36	3,31
Sonrası	0,9730	0,9997	0,9996	0,7456	73,04	26,96	84,42	0,05	0,29	2,64


Tablo 3.18. Damar bölütlemeye, tersinir yöntemin uygulanması ile 80 görüntü (kafatası tabanı ile Willis çemberi arasında) üzerindeki başarı değerlendirilmesi

BTA	Görüntü sayısı	İstatistiksel sonuçlar				Alan-tabanlı sonuçlar			Uzaklık-tabanlı sonuçlar		
		SE	SP	ACC	PR	AO (%)	AD (%)	DSA(%)	MAD(mm)	RMSE(mm)	MAXD(mm)
1	4	0,8205	0,9997	0,9994	0,8333	70,49	29,51	82,68	0,11	0,5	3,87
2	5	0,8324	0,9998	0,9995	0,8422	71,12	28,88	83,15	0,1	0,44	3,76
3	6	0,8405	0,9994	0,9993	0,8568	72,56	27,44	84,42	0,09	0,41	3,69
4	5	0,8159	0,9997	0,9994	0,8246	69,89	30,11	81,86	0,12	0,52	3,9
5	4	0,8109	0,9997	0,9993	0,8116	69,11	30,89	81,21	0,12	0,53	3,96
6	5	0,8342	0,9995	0,9992	0,8448	71,18	28,82	83,24	0,1	0,43	3,74
7	6	0,8484	0,9996	0,9996	0,8589	72,92	27,08	84,89	0,09	0,39	3,65
8	7	0,8281	0,9997	0,9995	0,8359	70,78	29,22	82,87	0,11	0,48	3,83
9	5	0,8179	0,9998	0,9994	0,8312	70,12	29,88	82,18	0,11	0,5	3,89
10	5	0,8112	0,9994	0,9993	0,8202	69,12	30,88	81,24	0,12	0,53	3,92
11	6	0,8305	0,9993	0,9993	0,8408	71,04	28,96	83,04	0,1	0,45	3,79
12	7	0,8424	0,9998	0,9994	0,8578	72,68	27,32	84,58	0,09	0,4	3,67
13	6	0,8248	0,9996	0,9995	0,8352	70,64	29,36	82,79	0,11	0,49	3,86
14	5	0,8345	0,9997	0,9994	0,8449	71,21	28,79	83,29	0,1	0,42	3,72
15	4	0,8298	0,9995	0,9994	0,8373	70,89	29,11	82,96	0,11	0,47	3,81
	Ort:	0,8282	0,9997	0,9994	0,8384	70,92	29,06	82,96	0,11	0,47	3,8

Tablo 3.19. Damar bölütlemeye, doku tabanlı bölge büyütme yönteminin tersinir yöntemle uyarlanması ile 80 görüntü (kafatası tabanı ile Willis çemberi arasında) üzerindeki başarı değerlendirilmesi

BTA	Görüntü sayısı	İstatistiksel sonuçlar				Alan-tabanlı sonuçlar			Uzaklık-tabanlı sonuçlar		
		SE	SP	ACC	PR	AO (%)	AD (%)	DSA(%)	MAD(mm)	RMSE(mm)	MAXD(mm)
1	4	0,8711	0,9999	0,9997	0,9361	77,2	22,8	87,12	0,09	0,41	2,64
2	5	0,8856	0,9998	0,9996	0,9439	78,55	21,45	88,44	0,09	0,4	2,58
3	6	0,8889	0,9999	0,9996	0,9485	78,89	21,11	88,92	0,09	0,4	2,58
4	5	0,8746	0,9997	0,9995	0,9348	77,44	22,56	87,56	0,1	0,41	2,61
5	4	0,8943	0,9999	0,9998	0,9549	79,34	20,66	89,42	0,08	0,39	2,56
6	5	0,8824	0,9998	0,9998	0,9411	78,21	21,79	88,14	0,09	0,4	2,59
7	6	0,8734	0,9999	0,9997	0,9334	77,56	22,44	87,48	0,1	0,41	2,63
8	7	0,8848	0,9999	0,9998	0,9431	78,48	21,52	88,36	0,09	0,4	2,58
9	5	0,8921	0,9998	0,9999	0,9528	79,12	20,88	89,22	0,08	0,39	2,56
10	5	0,8826	0,9996	0,9998	0,9412	78,24	21,76	88,15	0,09	0,4	2,59
11	6	0,8778	0,9999	0,9997	0,9376	77,81	22,19	87,84	0,1	0,41	2,6
12	7	0,8837	0,9999	0,9997	0,9421	78,34	21,66	88,24	0,09	0,4	2,59
13	6	0,8908	0,9998	0,9998	0,9515	79,04	20,96	89,12	0,08	0,39	2,57
14	5	0,8867	0,9999	0,9998	0,944	78,58	21,42	88,46	0,09	0,4	2,58
15	4	0,8956	0,9998	0,9999	0,9557	79,46	20,54	89,58	0,08	0,39	2,56
	Ort:	0,8843	0,9999	0,9998	0,9441	78,42	21,59	88,41	0,09	0,4	2,59

Farabi veri setindeki 15 BTA görüntüsünden rasgele alınan kafatası tabanı ile Willis çemberi arasındaki 80 görüntüye doku tabanlı bölge büyütme yönteminin tersinir yöntemle uyarlanmasının öncesi ve sonrasının değerlendirilmesi yapılmıştır. Bu değerlendirmeye göre, hassasiyet (precision) değerinin %83,84'den %94,41'e yükseldiği ve Dice benzerliğinin de %82,96 'dan %88,41'ye yükseldiği gözlemlenmiştir.



Şekil 3.9. Kafatası tabanı ile Willis çemberi arasındaki Farabi verilerine ait damar bölütlemelerinin ekran görüntüleri

Farabi veri setindeki 15 BTA görüntüsüne Aort bölgesinden Willis çemberine kadar olan tüm damarlara (OKA, İKA, EKA, VA) doku tabanlı bölge büyütme yöntemi ile tersinir yöntemin tekrar uygulanması ile kafatası bölgesindeki aşırı bölütlemelerin azalması ile genel bölütleme başarısı, Dice benzerliğinin %92,75'den %93,54'e yükseldiği gözlemlenmiştir.

4. SONUÇLAR VE TARTIŞMA

Tez çalışması kapsamında, tersinir yöntem yaklaşımıyla öncelikle kemik bölgesi bölütlenmiş ve çıkarılmıştır, daha sonra damarlar bölütlenmiştir. Yöntemi içeren uygulama ile girdi verisi olarak BTA verisini alınıp, çeşitli görüntü işleme teknikleri ile daha fazla bir tarama verisine (kemik tarama görüntüsü gibi) ihtiyaç duymadan karotid arter yapılarının çıkarılması ve üç boyutlu görselleştirilmesi yapılmıştır. Ayrıca yöntemin performans doğrulaması için, temin edilen BTA verisinden eğitim verisi de oluşturulmuştur. Eğitim verisi, damar bölgelerinin bir kısmının radyoloji uzmanı tarafından ve daha sonrasında uzman kontrolünde DICOM görüntüleme aracıyla işaretlenmesi ile oluşturulmuştur. Buna ilaveten, yöntemin performans doğrulaması literatürde kabul görmüş bir ortak veri seti olan MICCAI'2009 ile de yapılmıştır. Bu bölümde, çalışmalarımızda elde ettiğimiz sonuçlar özet biçimde sıralanacaktır.

- Tohumlandırılmalı yöntemler, kullanıcı etkileşimli yöntemlerdir. Bu yöntemlerin çalışması için, uygulamada bir tohum ilklendirmesine ihtiyaç duyulmaktadır. Literatürde tohum ilklendirmede otomatik ve yarı otomatik yöntemler mevcuttur. Burada yarı-otomatik işlemde kasıt kullanıcının başlangıç tohum noktalarını belirtmesi-işaretlemesi istenmektedir. Bu çalışmada, kullanıcıdan bir parametre girişi ya da ilklendirme beklenilmemektedir.

- Tohumlandırmada eşik değer belirleme işlemi her BTA verisine uygulanan önceden belirli sabit aralıklar ile değil, farklı BTA'lara göre değeri güncellenen global eşikleme ile belirlenmiştir.

- Tohumlandırma işlemi otomatikleştirmede tohum noktaları için eşik değer belirlenmesine gereksinim duyulmuştur. Burada global eşikleme yönteminin kullanılması az işlem yüküyle performans sağladığı için tercih edilmiştir. Eşikleme işlemi çoklu seviye eşikleme yöntemiyle kemik bölgesi için bir BTA'daki çalışma uzayındaki tüm katmanlara göre ortalama eşik değerinin belirlenmesi ile gerçekleştirilmiştir. Çoklu seviye eşikleme seviye grupları ve ortalama aralıkları ile seviye grubu deneysel sonuçlar ile en uygun MLEVEL=5 olarak alınmıştır. Bu sayede damar-kemik bölütlemesi için gerekli olacak tohum eşik aralıkları global olarak belirlenmiştir. BTA görüntülerindeki her dilim için ayrı ayrı eşik değer belirlemesi ile de uygulama denenmiştir. Bu hem daha fazla işlem hem de son işleme aşamasına daha fazla istenmeyen damar dışı bölgelerini de beraberinde

getirmiştir. Dolayısıyla son işleme aşamasında bu istenmeyen aykırı bölgelerin elimine edilmesi bölütleme sürecini daha da uzatmış ve genel başarıyı düşürmüştür.

- Bu global eşik değerlerine göre tersinir yöntem öncelikle kemik seviyesi için belirlenen eşik değerden itibaren görüntüdeki tüm vokselleri tohum noktası olarak alıp, kemik bölütlemesi ve çıkarılmasını gerçekleştirmiştir. Bu işlemde sonra damar için belirli eşik değerindeki aralıktaki vokseller damar bölütlemesi için çalıştırılmıştır.

- Kemik bölütlemesi ayrı ayrı bölge büyütme ve rassal yürüyüş yöntemleri ile gerçekleştirilmiştir. Benzer şekilde damar bölütlemesi de farklı yöntemler ile çalışılmıştır. Bu karşılaştırma sonucuna göre, tohum noktalarının ilkendirilmesi her iki yöntemde de aynı eşik aralıklarından verilse de, bölütleme performanslarında farklı sonuçlar elde edilmiştir. Performans doğrulama sonuçlarına göre ortalama başarıya bakıldığında, kemik bölütlemesinde BB yaklaşımını, damar bölütlemesinde RY yaklaşımı ile tersinir yöntem uygulandığında en iyi sonuç elde edilmiştir.

- Bölge büyütme algoritması, bir pikselin bölgeye eklenip eklenmeyeceğini belirlemek için bir homojenlik kriteri gerektirir. Bölgeye komşu noktanın dahil edilmesi noktasında bir benzerlik kriterinin belirlenmesine ihtiyaç duyar. Eşik değerinin görüntü bilgisinden çıkarılması gerekmektedir. Burada ortalama yoğunluk ve dokusal özellik olmak üzere iki farklı benzerlik kriteri uygulanmıştır. Hızlı ve uygulaması basit olduğu için öncelikle daha önce alınan damar kemik örneklerine göre ortalama ve standart sapmalarının incelenmesi ile damar bölgesi için küçük, kemik bölütlemesinde büyük olacak şekilde bir eşik değer deneysel olarak belirlenmiştir. Bunun sebebi, damar pikseller homojen dağılım gösterdiğinden varyansın değeri küçük iken, buna karşılık kemik iskelet yapıda piksel yoğunluğu çok farklılık gösterdiği için varyans büyük değerlere sahiptir. Bölge büyütme için dokusal tabanlı benzerlik kriteri göz önünde bulundurularak, eşik değerinin otomatik seçimi üzerine de çalışılmıştır. Eşik değeri, tohum komşularının doku özneliklerinin istatistiksel dağılımını analiz ederek otomatik seçilmiştir.

- Her bir pikseli karakterize etmek için yerel doku tanımlayıcıları kullanılmıştır. Doku tabanlı bölge büyütme ile, 7 öznelik ve 26 eş-oluşum matrisi kullandığımız için, işlenmiş vokselde ortalanmış hacmin yerel dokusunu tanımlayan 182 eleman vektörü elde edilmiştir. Burada, Öklid uzaklığını kullanarak bir aday pikselin tanımlayıcıları tohum nokta olanlarla kıyaslanmaktadır. Bir tohum noktasından başlayarak, tohumlu bölge büyütme algoritması tohum noktasına bağlı vokselleri ve homojenlik kriterini doğrularak bir bölgeyi bölütler.

Daha önce belirtildiği gibi öklid mesafesi homojenlik kriteri olarak kullanılırken, 6 veya 26 bağlanabilirlik ile iki vokselin komşu olup olmadığını belirlemek için kullanılmıştır. Daha sonra, öznitelik sayısı artırılarak ve eş oluşum matrisinden yön sayısını artırarak doku tanımlayıcısını daha başarılı hale getirilmiştir. Bu işlem, çalışma süresini daha fazla işlem gereksiniminden ötürü artırsa da bölütleme başarısını artırmıştır.

- Son işleme aşamasında dokusal özniteliklere göre oluşturulmuş eğitim kümesi üzerinden sınıflandırma için öncelikle tüm öznitelikler kullanılmış, daha sonra öznitelik seçimi yaklaşımlarından genetik algoritma yöntemi kullanarak öznitelik sayısı azaltılmıştır. Burada en iyi performansı veren 5 öznitelik seçilerek, sınıflandırıcının performansı artırılmıştır.

- Bölütleme yöntemlerinin başarısı ölçmek için alan ve uzaklık bazlı ölçütler kullanılmıştır. Literatürde kullanılmış bir ortak veri setinden aynı değerlendirme ölçütleri ile elde edilen sonuçlar yöntemin başarısını ortaya koymuştur.

Sonuç olarak, bu tez ile kan damarları bölütlemesi literatürüne yaptığımız katkılar aşağıdaki gibi verilmiştir.

- Özgün eğitim verisetinin oluşturulması: Bu tez kapsamında, DICOM görüntüleme yazılımıyla BTA görüntülerindeki çalışma uzayındaki katmanlarındaki damar bölgelerini radyoloji uzmanlarına manuel işaretleyerek damar manuel bölütlemesi yapılmıştır. Veri seti boyutunu artırmak adına, daha fazla damar bölgesi tarafımızca işaretlenerek işaretli bölgelerin uzman tarafından kontrol edilmesi ile kıyaslama yapabilecek 15 BTA veri seti oluşturulmuştur. İlerleyen zamanda, bu veri setinin ve manuel bölütlemelerin bilim insanları ile paylaşılması planlanmaktadır.

- Kemik çıkarma bilgisayarlı tomografi anjiyografisi ile hastayı daha fazla radyasyona maruz bırakmak yerine görüntü işleme teknikleriyle kontrastlı bir BTA'dan damar bölütlemesi yapılmıştır.

- Tek bir BT taramasından daha fazlasının olmaması için elimizdeki kontrastlı BTA görüntülerinden tersinir yöntemle öncelikle problem olan kısım, kemiğin tersinir yöntemle çıkarılması üzerine çalışmalar yapılmıştır.

- Tersinir yaklaşım ile yeni bir otomatik bölütleme yöntemi geliştirilmiştir.

- Tersinir yaklaşımla ilk olarak kemiklerin bölütlenmesi ve çıkartılmasından sonra damar bölütlemesi yapmak tezin bir özgünlüğüdür.

- Aynı zamanda, bu tez kapsamında geliştirilen yöntemin kendi içinde de aşamaları bulunmaktadır. Bölütleme tekniğimiz, öncesi ön işleme ve sonrasında son işleme adımlarıyla daha kararlı hale getirilmiştir. Bu aşamaların hepsi ile birlikte ortaya çıkan yöntem bu tezin özgünlüğünü göstermektedir.

- Literatürde daha önce karaciğer ya da organ bölütleme için kullanılmış olan doku tabanlı bölge büyütme yaklaşımı tersinir yöneme uyarlanmıştır. Bu sayede boyun ve baş bölgesindeki kan damarlarının bölütlenmesinde doku tabanlı bölge büyütme yönteminin çalışma uzayımızdaki yere uyarlanarak ilk kez kullanılması ile başarılı sonuçlar aldığımızı söylemek mümkündür.

- Literatürde kabul görmüş bir ortak veri seti üzerinde de yöntem uygulanmıştır. Yöntemin ortak veri seti üzerinde uygulanması ile elde edilen sonuçların, literatüre göre kıyaslandığında kabul edilebilir seviyede başarılı olduğunu görmek mümkündür.

5. ÖNERİLER

Uygulama, özellikle dokusal tabanlı bölge büyütmenin tersinir yönleme uyarlanması ile yavaş çalışmaktadır. Doku tanımlayıcısındaki öznitelik sayısının artırılması, eş oluşum matrisinden yön sayısının artırılması ve voksel bağlantılığında daha fazla komşuna odaklanma doku tanımlayıcısını daha başarılı hale getirirse de hesaplama ve işlem süresini artırmaktadır. Bu yavaşlık kodların paralelleştirilmesiyle giderilebilir.

Doku tanımlayıcısında kullanılan öznitelik sayısına başka öznitelikler de eklenebilir. Ayrıca yararlı özniteliklerin belirlenmesi adına tekrar bir öznitelik seçimi yapılabilir. Özniteliklerin optimize edilmesi ile genel bölütleme başarısı artabilir ve işlem süresi kısaldır.

6. KAYNAKLAR

1. Gratama van Andel, H., Venema, H.W., Streekstra, G.J., van Straten, M., Majoie, C.B., den Heeten, G.J. ve Grimbergen, C.A., Removal of bone in CT angiography by multiscale matched mask bone elimination, Medical physics, 34,10 (2007) 3711-3723.
2. Morhard, D., Fink, C., Becker, C., Reiser, M.F. ve Nikolaou, K., Value of automatic bone subtraction in cranial CT angiography: comparison of bone-subtracted vs. standard CT angiography in 100 patients, European radiology, 18,5 (2008) 974-982.
3. van Straten, M., Schaap, M., Dijkshoorn, M.L., Greuter, M.J., van der Lugt, A., Krestin, G.P. ve Niessen, W.J., Automated bone removal in CT angiography: comparison of methods based on single energy and dual energy scans, Medical physics, 38,11 (2011) 6128-6137.
4. Tuncel, E., Radyolojik tanıda temel kavramlar ders notları. http://www.anadoluissagligi.com/img/file_2151.pdf.
5. Goldman, L.W., Principles of CT: multislice CT, Journal of nuclear medicine technology, 36,2 (2008) 57-68.
6. Sen, Y., Medical image segmentation system for cerebral aneurysms, Doktora Tezi, Macquarie University, Medicine and Health Sciences, 2015.
7. <http://www.startradiology.com/internships/neurology/brain/ct-brain-hemorrhage/#top>. 21 Mart 2018.
8. Hedblom, A., Blood vessel segmentation for neck and head computed tomography angiography, Yüksek Lisans Tezi, Linköpings universitet, Computer Technology, 2013.
9. Hebb, A.O. ve Poliakov, A.V., Imaging of deep brain stimulation leads using extended Hounsfield unit CT, Stereotactic and functional neurosurgery, 87,3 (2009) 155-160.

10. Netter, F.H., Atlas of Human Anatomy, Professional Edition E-Book: including NetterReference. com Access with Full Downloadable Image Bank2014: Elsevier Health Sciences, 2014.
11. Marieb, E. ve Hoehn, K., The cardiovascular system: blood vessels, Human anatomy & physiology, (2004) 703-720.
12. Kirbas, C. ve Quek, F., A review of vessel extraction techniques and algorithms, ACM Computing Surveys (CSUR), 36,2 (2004) 81-121.
13. Lesage, D., Angelini, E.D., Bloch, I. ve Funka-Lea, G., A review of 3D vessel lumen segmentation techniques: Models, features and extraction schemes, Medical image analysis, 13,6 (2009) 819-845.
14. Suri, J.S., Liu, K., Reden, L. ve Laxminarayan, S., A review on MR vascular image processing algorithms: acquisition and prefiltering: part I, IEEE transactions on information technology in biomedicine: a publication of the IEEE Engineering in Medicine and Biology Society, 6,4 (2002) 324-337.
15. Felkel, P., Wegenkittl, R. ve Kanitsar, A., Vessel tracking in peripheral CTA datasets-an overview, Computer Graphics in Spring Conference, Nisan 2001, Budmerice, IEEE, 232-239.
16. Dehkordi, M.T., Sadri, S. ve Doosthoseini, A., A review of coronary vessel segmentation algorithms, Journal of medical signals and sensors, 1,1 (2011) 49.
17. Fraz, M.M., Remagnino, P., Hoppe, A., Uyyanonvara, B., Rudnicka, A.R., Owen, C.G. ve Barman, S.A., Blood vessel segmentation methodologies in retinal images– a survey, Computer methods and programs in biomedicine, 108,1 (2012) 407-433.
18. Gonzales-Barron, U. ve Butler, F., A comparison of seven thresholding techniques with the k-means clustering algorithm for measurement of bread-crumbs features by digital image analysis, Journal of food engineering, 74,2 (2006) 268-278.

19. Zhao, K., Kang, B., Kang, Y. ve Zhao, H., Auto-threshold bone segmentation based on CT image and its application on CTA bone-subtraction, Photonics and Optoelectronic (SOPO) Symposium, Haziran 2010, Chengdu, IEEE,1-5.
20. Gan, R., Wong, W.C. ve Chung, A., Statistical cerebrovascular segmentation in three-dimensional rotational angiography based on maximum intensity projections, Medical physics, 32,9 (2005) 3017-3028.
21. Zhang, B., Xing, Z., He, J., Yi, S. ve Ma, L., Local optimal threshold segmentation and reconstruction of cerebrovascular mra images, 5th International Conference of Biomedical Engineering and Informatics (BMEI), Ekim 2012, Chongqing, IEEE,300-303.
22. Park, J.W., Connectivity-based local adaptive thresholding for carotid artery segmentation using MRA images, Image and vision computing, 23,14 (2005) 1277-1287.
23. Wang, R., Li, C., Wang, J., Wei, X., Li, Y., Zhu, Y. ve Zhang, S., Threshold segmentation algorithm for automatic extraction of cerebral vessels from brain magnetic resonance angiography images, Journal of neuroscience methods, 241, (2015) 30-36.
24. Wilkinson, M.H., Gaussian-weighted moving-window robust automatic threshold selection, International Conference on Computer Analysis of Images and Patterns, Ağustos 2003, Groningen, Springer, 369-376.
25. Kittler, J., Illingworth, J. ve Föglein, J., Threshold selection based on a simple image statistic, Computer vision, graphics, and image processing, 30,2 (1985) 125-147.
26. Boegel, M., Hoelter, P., Redel, T., Maier, A., Hornegger, J. ve Doerfler, A., A fully-automatic locally adaptive thresholding algorithm for blood vessel segmentation in 3D digital subtraction angiography, 37th annual international conference of Medicine and Biology Society (EMBC), Ağustos 2015, Milan, IEEE, 2006-2009.

27. Chung, A.C., Noble, J.A. ve Summers, P., Vascular segmentation of phase contrast magnetic resonance angiograms based on statistical mixture modeling and local phase coherence, IEEE Transactions on Medical Imaging, 23,12 (2004) 1490-1507.
28. Gao, X., Uchiyama, Y., Zhou, X., Hara, T., Asano, T. ve Fujita, H., A fast and fully automatic method for cerebrovascular segmentation on time-of-flight (TOF) MRA image, Journal of digital imaging, 24,4 (2011) 609-625.
29. Caselles, V., Kimmel, R. ve Sapiro, G., Geodesic active contours, International journal of computer vision, 22,1 (1997) 61-79.
30. Hernandez, M. ve Frangi, A.F., Non-parametric geodesic active regions: Method and evaluation for cerebral aneurysms segmentation in 3DRA and CTA, Medical image analysis, 11,3 (2007) 224-241.
31. Sanz-Requena, R., Moratal, D., García-Sánchez, D.R., Bodí, V., Rieta, J.J. ve Sanchis, J.M., Automatic segmentation and 3D reconstruction of intravascular ultrasound images for a fast preliminar evaluation of vessel pathologies, Computerized Medical Imaging and Graphics, 31,2 (2007) 71-80.
32. Firouziyan, A., Manniesing, R., Flach, Z.H., Risselada, R., van Kooten, F., Sturkenboom, M.C., van der Lugt, A. ve Niessen, W.J., Intracranial aneurysm segmentation in 3D CT angiography: Method and quantitative validation with and without prior noise filtering, European journal of radiology, 79,2 (2011) 299-304.
33. Wu, X., Luboz, V., Krissian, K., Cotin, S. ve Dawson, S., Segmentation and reconstruction of vascular structures for 3D real-time simulation, Medical image analysis, 15,1 (2011) 22-34.
34. Li, C., Xu, C., Gui, C. ve Fox, M.D., Distance regularized level set evolution and its application to image segmentation, IEEE transactions on image processing, 19,12 (2010) 3243-3254.

35. Chang, H.-H. ve Valentino, D.J., An electrostatic deformable model for medical image segmentation, Computerized Medical Imaging and Graphics, 32,1 (2008) 22-35.
36. Caldaïrou, B., Naegel, B. ve Passat, N., Segmentation of complex images based on component-trees: Methodological tools, in International Symposium on Mathematical Morphology and Its Applications to Signal and Image Processing, Ađustos 2009, Groningen, Springer, 171-180.
37. Bogunović, H., Pozo, J.M., Cárdenes, R. ve Frangi, A.F., Automatic identification of internal carotid artery from 3DRA images, Engineering in Medicine and Biology Society (EMBC) of Annual International Conference, Ađustos 2010, Buenos Aires, IEEE,5343-5346.
38. Vermandel, M., Betrouni, N., Taschner, C., Vasseur, C. ve Rousseau, J., From MIP image to MRA segmentation using fuzzy set theory, Computerized medical imaging and graphics, 31,3 (2007) 128-140.
39. Forkert, N.D., Schmidt-Richberg, A., Fiehler, J., Illies, T., Möller, D., Säring, D., Handels, H. ve Ehrhardt, J., 3D cerebrovascular segmentation combining fuzzy vessel enhancement and level-sets with anisotropic energy weights, Magnetic resonance imaging, 31,2 (2013) 262-271.
40. Jain, R., Kasturi, R. ve Schunck, B.G., Machine vision, Vol. 5, McGraw-Hill New York, 1995.
41. Schaap, M., Neefjes, L., Metz, C., van der Giessen, A., Weustink, A., Mollet, N., Wentzel, J., van Walsum, T. ve Niessen, W., Coronary lumen segmentation using graph cuts and robust kernel regression, International Conference on Information Processing in Medical Imaging, Temmuz 2009, Williamsburg-VA, Springer, 528-539.
42. Masutani, Y., Schiemann, T. ve Höhne, K.-H., Vascular shape segmentation and structure extraction using a shape-based region-growing model, International

- Conference on Medical Image Computing and Computer-Assisted Intervention, Ekim 1998, Massachusetts, Springer, 1242-1249.
43. Sekiguchi, H., Sugimoto, N., Eiho, S., Hanakawa, T. ve Urayama, S., Blood vessel segmentation for head MRA using branch-based region growing, Systems and Computers in Japan, 36,5 (2005) 80-88.
 44. Jiang, H., He, B., Fang, D., Ma, Z., Yang, B. ve Zhang, L., A region growing vessel segmentation algorithm based on spectrum information, Computational and mathematical methods in medicine, 2013, (2013).
 45. Boskamp, T., Rinck, D., Link, F., Kummerlen, B., Stamm, G. ve Mildenerger, P., New vessel analysis tool for morphometric quantification and visualization of vessels in CT and MR imaging data sets, Radiographics, 24,1 (2004) 287-297.
 46. Passat, N., Ronse, C., Baruthio, J., Armspach, J.P., Maillot, C. ve Jahn, C., Region-growing segmentation of brain vessels: An atlas-based automatic approach, Journal of Magnetic Resonance Imaging, 21,6 (2005) 715-725.
 47. Cao, Q., Chen, Y., Yang, G., Toumoulin, C., Shu, H. ve Luo, L., Coronary vessel extraction method using an improved minimum path based region growing, 6th International Conference of Biomedical Engineering and Informatics (BMEI), Aralık 2013, Hangzhou, IEEE,127-131.
 48. Chen, Y., Cao, Q., Zhuang, Z., Yang, Z., Luo, L. ve Toumoulin, C., 3-D coronary vessel extraction using a novel minimum path based region growing, International Conference Image Analysis and Recognition, Haziran 2013, Póvoa do Varzim, Springer, 502-509.
 49. Wang, S., Li, B. ve Zhou, S., A segmentation method of coronary angiograms based on multi-scale filtering and region-growing, International Conference of Biomedical Engineering and Biotechnology (iCBEB), Mayıs 2012, Macao, IEEE,678-681.

50. Li, Y., Zhou, S., Wu, J., Ma, X. ve Peng, K., A novel method of vessel segmentation for X-ray coronary angiography images, Computational and Information Sciences (ICCIS) Fourth International Conference, Ağustos 2012, Chongqing, IEEE,468-471.
51. Frangi, A.F., Niessen, W.J., Vincken, K.L. ve Viergever, M.A., Multiscale vessel enhancement filtering, International Conference on Medical Image Computing and Computer-Assisted Intervention, Ekim 1998, MA, USA, Springer,130-137.
52. Kulathilake, K., Ranathunga, L., Constantine, G. ve Abdullah, N., Region growing segmentation method for extracting vessel structures from coronary cine-angiograms, Moratuwa Engineering Research Conference (MERCon), Nisan 2015, Moratuwa, IEEE, 142-147.
53. Almi'ani, M.M. ve Barkana, B.D., A modified region growing based algorithm to vessel segmentation in magnetic resonance angiography, Systems-Applications and Technology Conference (LISAT), Mayıs 2015, Farmingdale, IEEE, 1-7.
54. Orkisz, M., Hoyos, M.H., Romanello, V.P., Romanello, C.P., Prieto, J. ve Revol-Muller, C., Segmentation of the pulmonary vascular trees in 3D CT images using variational region-growing, IRBM, 35,1 (2014) 11-19.
55. Chang, H.H., Duckwiler, G.R., Valentino, D.J. ve Chu, W.C., Computer-assisted extraction of intracranial aneurysms on 3D rotational angiograms for computational fluid dynamics modeling, Medical physics, 36,12 (2009) 5612-5621.
56. Martínez-Mera, J.A., Tahoces, P.G., Carreira, J.M., Suárez-Cuenca, J.J. ve Souto, M., A hybrid method based on level set and 3D region growing for segmentation of the thoracic aorta, Computer Aided Surgery, 18,5-6 (2013) 109-117.
57. Passat, N., Contribution à la segmentation des réseaux vasculaires cérébraux obtenus en IRM: Intégration de connaissance anatomique pour le guidage d'outils de morphologie mathématique, Doktora Tezi, Université Louis Pasteur, Informatique, Strasbourg, 2005.

58. Passat, N., Ronse, C., Baruthio, J., Armspach, J.-P. ve Maillot, C., Magnetic resonance angiography: From anatomical knowledge modeling to vessel segmentation, Medical image analysis, 10,2 (2006) 259-274.
59. Babin, D., Pižurica, A., Bellens, R., De Bock, J., Shang, Y., Goossens, B., Vansteenkiste, E. ve Philips, W., Generalized pixel profiling and comparative segmentation with application to arteriovenous malformation segmentation, Medical image analysis, 16,5 (2012) 991-1002.
60. Babin, D., Pižurica, A., De Vylder, J., Vansteenkiste, E. ve Philips, W., Brain blood vessel segmentation using line-shaped profiles, Physics in Medicine & Biology, 58,22 (2013) 8041.
61. Pesaresi, M. ve Benediktsson, J.A., A new approach for the morphological segmentation of high-resolution satellite imagery, IEEE transactions on Geoscience and Remote Sensing, 39,2 (2001) 309-320.
62. Plaza, A., Martinez, P., Perez, R. ve Plaza, J., A new approach to mixed pixel classification of hyperspectral imagery based on extended morphological profiles, Pattern Recognition, 37,6 (2004) 1097-1116.
63. Dufour, A., Tankyevych, O., Naegel, B., Talbot, H., Ronse, C., Baruthio, J., Dokládál, P. ve Passat, N., Filtering and segmentation of 3D angiographic data: Advances based on mathematical morphology, Medical image analysis, 17,2 (2013) 147-164.
64. Tankyevych, O., Talbot, H., Dokládál, P. ve Passat, N., Direction-adaptive grey-level morphology. application to 3D vascular brain imaging, Image Processing (ICIP) 16th International Conference, Kasım 2009, Cairo, IEEE, 2261-2264.
65. Merveille, O., Talbot, H., Najman, L. ve Passat, N., Tubular structure filtering by ranking orientation responses of path operators, European Conference on Computer Vision, Eylül 2014, Zurich, Springer, 203-218.

66. Sato, Y., Nakajima, S., Shiraga, N., Atsumi, H., Yoshida, S., Koller, T., Gerig, G. ve Kikinis, R., Three-dimensional multi-scale line filter for segmentation and visualization of curvilinear structures in medical images, Medical image analysis, 2,2 (1998) 143-168.
67. Krissian, K., Malandain, G., Ayache, N., Vaillant, R. ve Troussset, Y., Model-based detection of tubular structures in 3D images, Computer vision and image understanding, 80,2 (2000) 130-171.
68. Orłowski, P. ve Orkisz, M., Efficient computation of Hessian-based enhancement filters for tubular structures in 3D images, IRBM, 30,3 (2009) 128-132.
69. Yang, J., Ma, S., Sun, Q., Tan, W., Xu, M., Chen, N. ve Zhao, D., Improved hessian multiscale enhancement filter, Bio-medical materials and engineering, 24,6 (2014) 3267-3275.
70. Bullitt, E., Aylward, S., Bernard Jr, E.J. ve Gerig, G., Computer-assisted visualization of arteriovenous malformations on the home personal computer, Neurosurgery, 48,3 (2001) 576-583.
71. Hernández-Hoyos, M., Segmentation anisotrope 3D pour la quantification en imagerie vasculaire par résonance magnétique, Doktora Tezi, Los Andes University (Colombia), Images et systèmes, 2002.
72. Agam, G. ve Wu, C., Probabilistic modeling based vessel enhancement in thoracic CT scans, Computer Vision and Pattern Recognition on Computer Society Conference, Haziran 2005, San Diego, IEEE, 649-654.
73. Wesarg, S. ve Firlle, E.A., Segmentation of vessels: the corkscrew algorithm, Medical Imaging on International Society for Optics and Photonics, Mayıs 2004, San Diego, Spie Digital Library, 1609-1621.
74. Verscheure, L., Peyrodie, L., Dewalle, A.-S., Reyns, N., Betrouni, N., Mordon, S. ve Vermandel, M., Three-dimensional skeletonization and symbolic description in

- vascular imaging: preliminary results, International journal of computer assisted radiology and surgery, 8,2 (2013) 233-246.
75. Flórez-Valencia, L. ve Morales Pinzón, A., Simultaneous skeletonization and graph description of airway trees in 3D CT images, Proceedings of the 25th GRETSI, (2015).
 76. Lacoste, C., Finet, G. ve Magnin, I.E., Coronary tree extraction from X-ray angiograms using marked point processes, Biomedical Imaging: Nano to Macro- 3rd IEEE International Symposium, Nisan 2006, Arlington, IEEE, 157-160.
 77. Flasque, N., Desvignes, M., Constans, J.-M. ve Revenu, M., Modélisation de structures tubulaires pour la visualisation 3D: application à des imageries d'angiographie par résonance magnétique, RFIA'2002-13e Congrès Reconnaissance des Formes et Intelligence Artificielle, Ocak 2002, Angers, France, 733-742.
 78. Kumar, R.P., Albregtsen, F., Reimers, M., Edwin, B., Langø, T. ve Elle, O.J., Blood vessel segmentation and centerline tracking using local structure analysis, 6th European conference of the international federation for medical and biological engineering. Eylül 2014, Dubrovnik, Croatia, Springer, 122-125.
 79. Dreyer, K.J., Hirschhorn, D., Thrall, J.H. ve PACS, M., A guide to the digital revolution, Springer, Boston, 2006.
 80. Xue, Z., Antani, S., Long, L.R., Demner-Fushman, D. ve Thoma, G.R., Window Classification of Brain CT Images in Biomedical Articles, AMIA Annual Symposium Proceedings. Kasım 2012, Chicago, American Medical Informatics Association, 1023.
 81. Comaniciu, D. ve Meer, P., Mean shift: A robust approach toward feature space analysis, IEEE Transactions on pattern analysis and machine intelligence, 24,5 (2002) 603-619.
 82. Özden, M. ve Tuna, E.P.E., Ortalama Kayma ve Dalgacık Çerçevesi ile Renkli Görüntü Kesimleme Color Image Segmentation using Mean Shift Filtering and

- Wavelet Frames, Signal Processing and Communications Applications Conference, Mayıs 2005, Kayseri, IEEE, 2165-0608.
83. Bilreiro, C., Grande, P., Brito, J., Silva, L.D., Aleixo, F. ve do Algarve, C.H., Extracranial internal carotid artery aneurysm, Head & Neck Imaging, (2013) 1563-4086.
 84. Rath, T.J., Hughes, M., Arabi, M. ve Shah, G.V., Imaging of cerebritis, encephalitis, and brain abscess, Neuroimaging Clinics, 22,4 (2012) 585-607.
 85. Bozkurt, F., Köse, C. ve Sarı, A., An inverse approach for automatic segmentation of carotid and vertebral arteries in CTA, Expert Systems with Applications, 93, (2018) 358-375.
 86. Bozkurt, F., Köse, C. ve San, A., Comparison of seeded region growing and random walk methods for vessel and bone segmentation in CTA images, Electrical and Electronics Engineering (ELECO) 10th International Conference, Aralık 2017, Bursa, IEEE, 561-567.
 87. Otsu, N., A threshold selection method from gray-level histograms, IEEE transactions on systems, man, and cybernetics, 9,1 (1979) 62-66.
 88. Eichmann, M. ve Lüssi, M., Efficient multilevel image thresholding, Uzmanlık Tezi, Hochschule für Technik Rapperswil, Switzerland, 2005.
 89. Ünver, Ö., Gamgam, H. ve Altunkaynak, B., Temel istatistiksel yöntemler. Seçkin Yayınları, İstanbul, 2011.
 90. Liu, D. ve Yu, J., Otsu method and K-means, Hybrid Intelligent Systems HIS'09-Ninth International Conference, Ağustos 2009, Shenyang, IEEE, 344-349.
 91. Sezgin, M., İmge Eşikleme Yöntemlerinin Başarım Değerlendirmesi ve Tahribatsız Muayenede Kullanımı, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2002.

92. Sezgin, M. ve Sankur, B., Survey over image thresholding techniques and quantitative performance evaluation, Journal of Electronic imaging, 13,1 (2004) 146-166.
93. Chu, C., Lee, D. ve Tay, J., Bilevel thresholding of floe images, Journal of colloid and interface science, 273,2 (2004) 483-489.
94. Mala, C. ve Sridevi, M., Multilevel threshold selection for image segmentation using soft computing techniques, Soft Computing, 20,5 (2016) 1793-1810.
95. Huang, D.-Y. ve Wang, C.-H., Optimal multi-level thresholding using a two-stage Otsu optimization approach, Pattern Recognition Letters, 30,3 (2009) 275-284.
96. Adams, R. ve Bischof, L., Seeded region growing, IEEE Transactions on pattern analysis and machine intelligence, 16,6 (1994) 641-647.
97. Revol-Muller, C., Peyrin, F., Carrillon, Y. ve Odet, C., Automated 3D region growing algorithm based on an assessment function, Pattern Recognition Letters, 23,1-3 (2002) 137-150.
98. Wu, J., Poehlman, S., Noseworthy, M.D. ve Kamath, M.V., Texture feature based automated seeded region growing in abdominal MRI segmentation, BioMedical Engineering and Informatics (BMEI) International Conference, Mayıs 2008, Sanya IEEE, 263-267.
99. Gambino, O., Vitabile, S., Re, G.L., La Tona, G., Librizzi, S., Pirrone, R., Ardizzone, E. ve Midiri, M., Automatic volumetric liver segmentation using texture based region growing, Complex Intelligent and Software Intensive Systems (CISIS)-International Conference, Şubat 2010, Krakow, IEEE,146-152.
100. Çatalbaş, M.C., Temel Bileşenler Analizi ve Kanonik Korelasyon Analizi ile İmge Tanıma ve Sınıflandırma, Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2014.

101. Lu, G., Zhang, D. ve Wang, K., Palmprint recognition using eigenpalms features, Pattern Recognition Letters, 24, 9-10 (2003) 1463-1467.
102. Ke, Y. ve Sukthankar, R., PCA-SIFT: A more distinctive representation for local image descriptors, Computer Vision and Pattern Recognition (CVPR) Computer Society Conference, Temmuz 2004, Washington, IEEE, II-II.
103. Sanchez-Reillo, R., Sanchez-Avila, C. ve Gonzalez-Marcos, A., Biometric identification through hand geometry measurements, IEEE Transactions on pattern analysis and machine intelligence, 22,10 (2000) 1168-1171.
104. Backman, N.J., Whitney, B.W., Furst, J.D. ve Raicu, D.S., A prioritized and adaptive approach to volumetric seeded region growing using texture descriptors, Computational Imaging IV. International Society for Optics and Photonics, Şubat 2006, San Jose, California, 60651A.
105. Grady, L., Random walks for image segmentation, IEEE transactions on pattern analysis and machine intelligence, 28,11 (2006) 1768-1783.
106. Kass, M., Witkin, A. ve Terzopoulos, D., Snakes: Active contour models, International journal of computer vision, 1,4 (1988) 321-331.
107. Mun, K.-J., Kang, H.T., Lee, H.-S., Yoon, Y.-S., Lee, C.-M. ve Park, J.H., Active contour model based object contour detection using genetic algorithm with wavelet based image preprocessing, International Journal of Control, Automation, and Systems, 2,1 (2004) 100-106.
108. Chopra, A. ve Dandu, B.R., Image segmentation using active contour model, Int. J. Comput. Eng. Res, 2, (2012) 819-822.
109. Sulong, G., Abdulaali, H. ve Hassan, S., Edge Detection Algorithms VS-active Contour for Sketch Matching: Comparative Study, Research Journal of Applied Sciences, Engineering and Technology, 11,7 (2015) 759-764.

110. Wu, Q., Merchant, F. ve Castleman, K., Microscope image processing, Academic press, California, 2010.
111. Hassan, M., Chaudhry, A., Khan, A. ve Kim, J.Y., Carotid artery image segmentation using modified spatial fuzzy c-means and ensemble clustering, Computer methods and programs in biomedicine, 108,3 (2012) 1261-1276.
112. Rosati, S., Molinari, F. ve Balestra, G., Feature selection applied to ultrasound carotid images segmentation, Engineering in Medicine and Biology Society (EMBC) Annual International Conference, Ağustos 2011, Boston, IEEE, 5161-5164.
113. Christodoulou, C.I., Pattichis, C.S., Pantziaris, M. ve Nicolaides, A., Texture-based classification of atherosclerotic carotid plaques, IEEE transactions on medical imaging, 22,7 (2003) 902-912.
114. Haralick, R.M. ve Shanmugam, K., Textural features for image classification, IEEE Transactions on systems, man, and cybernetics,6 (1973) 610-621.
115. Fodor, I.K., A survey of dimension reduction techniques, (2002), Lawrence Livermore National Lab., CA (US).
116. Demirci, D., Destek vektör makineleri ile karakter tanıma, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, (2007).
117. Liu, H., Feature selection, Encyclopedia of Machine Learning, 402-406, Springer, New York, 2011.
118. Aydemir, Ö., Ardışıl ileri yönlü öznelik seçim algoritmasında etkin özneliklerin belirlenmesi, Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 8,2 (2017).
119. John, G.H., Kohavi, R. ve Pfleger, K., Irrelevant features and the subset selection problem, Machine Learning Proceedings, Elsevier, (1994) 121-129.

120. Sondberg-Madsen, N., Thomsen, C. ve Pena, J.M., Unsupervised feature subset selection, Proceedings of the Workshop on Probabilistic Graphical Models for Classification, 82 (2003) 71.
121. Mitchell, T.M., Machine learning, McGraw-Hill Boston, MA, 1997.
122. Altındağ, O., Kanser Sınıflandırmada MikroRNA Ve mRNA Anlatım Bilgilerinin Entegrasyonu, Yüksek Lisans Tezi, Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2013.
123. Kotsiantis, S.B., Zaharakis, I. ve Pintelas, P., Supervised machine learning: A review of classification techniques, Emerging artificial intelligence applications in computer engineering, 160, (2007) 3-24.
124. Kohonen, T., State of the art in neural computing, ICNN'87 Int. Conf. on Neural Networks, 1987, San Diego, Vol. I, 79-90.
125. Oztemel, E., Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, 2003.
126. Haykin, S. ve Network, N., A comprehensive foundation, Neural networks, 2,2004 (2004) 41.
127. Song, Q., Hu, W. ve Xie, W., Robust support vector machine with bullet hole image classification, IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 32,4 (2002) 440-448.
128. Yakut, Y.B.E.T.Y., Elmas, B. ve Yavuz, S., Yapay Sinir Ağları ve Destek Vektör Makineleri, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 19,1 (2014).
129. Çomak, E., Destek vektör makinelerinin etkin eğitimi için yeni yaklaşımlar, Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya, 2008.
130. Özkan, Y., Veri madenciliği yöntemleri, Papatya Yayıncılık Eğitim, İstanbul, 2008.

131. İşeri, İ., Mamogram görüntülerinden makine öğrenmesi yöntemleri ile meme kanseri teşhisi, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya, 2014.
132. Pal, S.K. ve Mitra, P., Pattern recognition algorithms for data mining, CRC press, Boca Raton, Florida, 2004.
133. Phyu, T.N., Survey of classification techniques in data mining, International MultiConference of Engineers and Computer Scientists, Mart 2009, Hong Kong, 18-20.
134. Yağanoğlu, M., Bozkurt, F. ve Günay, F.B., EEG Tabanlı Beyin-Bilgisayar Arayüzü Sistemlerinde Öznitelik Çıkarma Yöntemleri, Mühendislik Bilimleri ve Tasarım Dergisi, 2,3 (2014) 313-318.
135. Gutierrez-Osuna, R., Introduction to pattern analysis, Lecture Notes, Texas A&M University, Texas, United State, 2005.
136. François, D., Rossi, F., Wertz, V. ve Verleysen, M., Resampling methods for parameter-free and robust feature selection with mutual information, Neurocomputing, 70,7-9 (2007) 1276-1288.
137. Diamantidis, N., Karlis, D. ve Giakoumakis, E.A., Unsupervised stratification of cross-validation for accuracy estimation, Artificial Intelligence, 116,1-2 (2000) 1-16.
138. Uzer, M.S., Örüntü tanıma uygulamalarında yapay zeka ve öznitelik dönüşüm metotları kullanılarak geliştirilen öznitelik seçme algoritmaları, Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya, 2014.
139. Bozkurt, F., Köse, C. ve Sari, A., Segmentation of carotid arteries in CTA images using region-based active contours and classification, Artificial Intelligence and Data Processing Symposium (IDAP), Eylül 2017, Malatya, IEEE, 1-8.
140. Tian, Y., Zhou, M.-q., Wu, Z.-k. ve Wang, X.-c., A region-based active contour model for image segmentation, Computational Intelligence and Security-CIS'09. International Conference, Aralık 2009, Beijing, China, IEEE, 376-380.

141. Chan, T.F. ve Vese, L.A., Active contours without edges, IEEE Transactions on image processing, 10,2 (2001) 266-277.
142. Sousa, L.C., Castro, C.F., António, C.C., Santos, A.M.F., dos Santos, R.M., Castro, P.M.A., Azevedo, E. ve Tavares, J.M.R., Toward hemodynamic diagnosis of carotid artery stenosis based on ultrasound image data and computational modeling, Medical & biological engineering & computing, 52,11 (2014) 971-983.
143. Tbaina, A.J., Prado, A.H. ve Bueno, J.M., 3D reconstruction of tomographic images applied to largely spaced slices, Journal of medical systems, 21,6 (1997) 353-367.
144. Calhoun, P.S., Kuszyk, B.S., Heath, D.G., Carley, J.C. ve Fishman, E.K., Three-dimensional volume rendering of spiral CT data: theory and method, Radiographics, 19,3 (1999) 745-764.
145. Crawford, C.R., Cline, H.E., Lorensen, W.E. ve Teeter, B.C., 3-D Imaging Using Normalized Gradient Shading in CT and MRI, Medical Imaging III: Image Capture and Display, International Society for Optics and Photonics, Mayıs 1989, Newport Beach, CA, Spie Digital Library, 294-301.
146. Bosma, M.K., Iso-surface volume rendering: speed and accuracy for medical applications, Doktora Tezi, University of Twente, Hollanda, 2000.
147. Lorensen, W.E. ve Cline, H.E., Marching cubes: A high resolution 3D surface construction algorithm, ACM siggraph computer graphics, Temmuz 1987, New York, ACM, 163-169.
148. Cline, H.E., Lorensen, W.E., Ludke, S., Crawford, C.R. ve Teeter, B.C., Two algorithms for the three-dimensional reconstruction of tomograms, Medical physics, 15,3 (1988) 320-327.
149. Carr, J.C., Beatson, R.K., McCallum, B.C., Fright, W.R., McLennan, T.J. ve Mitchell, T.J., Smooth surface reconstruction from noisy range data, 1st International conference on Computer graphics and interactive techniques in Australasia and South East Asia, Şubat 2003, Melbourne, Australia, ACM, 119-ff.


150. <https://itk.org/> ITK: Insight Segmentation and Registration Toolkit. 10 Şubat 2018.
151. Schroeder, W.J., Lorensen, B. ve Martin, K., The visualization toolkit: an object-oriented approach to 3D graphics, Third Edition, Kitware, New York, 2004.
152. Yushkevich, P.A., Piven, J., Hazlett, H.C., Smith, R.G., Ho, S., Gee, J.C. ve Gerig, G., User-guided 3D active contour segmentation of anatomical structures: significantly improved efficiency and reliability, Neuroimage, 31,3 (2006) 1116-1128.
153. Hameeteman, K., Zuluaga, M.A., Freiman, M., Joskowicz, L., Cuisenaire, O., Valencia, L.F., Gülsün, M.A., Krissian, K., Mille, J. ve Wong, W.C., Evaluation framework for carotid bifurcation lumen segmentation and stenosis grading, Medical Image Analysis, 15,4 (2011) 477-488.
154. Bowyer, K.W., Validation of medical image analysis techniques, Handbook of medical imaging, 2, (2000) 567-607.
155. Hemmati, H., Kamali-asl, A., Talebpour, A., Alizadeh, M. ve Shirani, S., Segmentation of carotid arteries in computed tomography angiography images using fast marching and graph cut methods, Electrical engineering (ICEE) 21st Iranian conference, Mayıs 2013, Mashhad, Iran, IEEE, 1-5.
156. Moursi, S.G. ve El-Sakka, M.R., Active contours initialization for ultrasound carotid artery images, Computer Systems and Applications-AICCSA IEEE/ACS International Conference, Nisan 2008, Doha, Qatar, IEEE,629-636.
157. Zouqi, M. ve Samarabandu, J., 2D ultrasound image segmentation using graph cuts and local image features, Computational Intelligence for Image Processing-CIIP'09. IEEE Symposium, Nisan 2009, Nashville, TN, USA, IEEE,33-40.
158. https://en.wikipedia.org/wiki/Hausdorff_distance Hausdorff distance.10 Mart 2018.

159. Valencia, L.F., Azencot, J. ve Orkisz, M., Carotid arteries segmentation in CT images with use of a right generalized cylinder model, Revista Colombiana de Computación-RCC, 11,2 (2010).
160. Wong, W.C., So, R.W. ve Chung, A.C., Principal curves: a technique for preliminary carotid lumen segmentation and stenosis grading, MIDAS Journal, 1 (2009) 1-10.
161. Zuluaga, M.A., Orkisz, M., Leyton, E.J.D., Dore, V., Pinzon, A.M. ve Hoyos, M.H., Adaptations of MARACAS algorithm to the segmentation of the carotid bifurcation and stenosis quantification in CTA images, Proceedings of Carotid Lumen Segmentation and Stenosis Grading Challenge, 1 (2009) 1-10.
162. Freiman, M., Frank, J., Weizman, L., Nammer, E., Shilon, O., Joskowicz, L. ve Sosna, J., Nearly automatic vessels segmentation using graph-based energy minimization, The Midas Journal, 1 (2009) 1-10.
163. Mille, J., Benmansour, F. ve Cohen, L., Carotid lumen segmentation based on tubular anisotropy and contours without edges, The Midas Journal, 1 (2009) 1-10.
164. Krissian, K. ve Garcia, S., A minimal cost path and level set evolution approach for carotid bifurcation segmentation, The Midas Journal, 1 (2009) 1-10.
165. Tang, H., van Walsum, T., Hameeteman, R., Shahzad, R., van Vliet, L.J. ve Niessen, W.J., Lumen segmentation and stenosis quantification of atherosclerotic carotid arteries in CTA utilizing a centerline intensity prior, Medical physics, 40,5 (2013).
166. Gülsün, M.A. ve Tek, H., Segmentation of carotid arteries by graph-cuts using centerline models, Medical Imaging 2010: Visualization, Image-Guided Procedures, and Modeling, International Society for Optics and Photonics, Şubat 2010, San Diego, California, Spie Digital Library, 762530.
167. Cuisenaire, O., Fully automated segmentation of carotid and vertebral arteries from CTA, MICCAI 2009 Carotid lumen segmentation and stenosis grading challenge, Eylül 2009, London, Kitware Inc, 1-10.


168. van Velsen, E.F., Niessen, W.J., de Weert, T.T., de Monyé, C., van der Lugt, A., Meijering, E. ve Stokking, R., Evaluation of an improved technique for lumen path definition and lumen segmentation of atherosclerotic vessels in CT angiography, European radiology, 17,7 (2007) 1738-1745.
169. Manniesing, R. ve Niessen, W.J., Automatic segmentation of the internal carotid arteries through the skull base, Medical Imaging, International Society for Optics and Photonics, Mart 2007, San Diego, Spie Digital Library, 65120I.
170. Manniesing, R., Schaap, M., Rozie, S., Hameeteman, R., Vukadinovic, D., van der Lugt, A. ve Niessen, W., Robust CTA lumen segmentation of the atherosclerotic carotid artery bifurcation in a large patient population, Medical image analysis, 14,6 (2010) 759-769.
171. Freiman, M., Joskowicz, L., Broide, N., Natanzon, M., Nammer, E., Shilon, O., Weizman, L. ve Sosna, J., Carotid vasculature modeling from patient CT angiography studies for interventional procedures simulation, International journal of computer assisted radiology and surgery, 7,5 (2012) 799-812.
172. Behrens, S., Automatic level set based cerebral vessel segmentation and bone removal in CT angiography data sets, German Conference on Pattern Recognition, Eylül 2013, Saarbrücken, Springer, 237-242.
173. Hemmati, H., Kamli-Asl, A., Talebpour, A. ve Shirani, S., Semi-automatic 3D segmentation of carotid lumen in contrast-enhanced computed tomography angiography images, Physica Medica: European Journal of Medical Physics, 31,8 (2015) 1098-1104.

7. EKLER


Ek 1. Tersinir Yöntem Sonrası Kemik Bölütlemelerine Ait Örnek Görüntüler




Ek Şekil 1. Bir BTA'nın 150-155 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri




Ek Şekil 2. Bir BTA'nın 156-161 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri




Ek Şekil 3. Bir BTA'nın 169-173 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri



Ek Şekil 4. Bir BTA'nın 174-178 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri




Ek Şekil 5. Bir BTA'nın 190-194 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri




Ek Şekil 6. Bir BTA'nın 195-199 arası dilimlerinde gerçekleştirilen kemik bölütleme görüntüleri

Ek 2. Tersinir Yöntem Sonrası Damar Bölütlemelerine Ait Örnek Görüntüler



Ek Şekil 7. Bir BTA'nın 157-165 arasındaki farklı dilimlerde tersinir yöntem sonrası gerçekleştirilen damar bölütleme görüntüleri



Ek Şekil 8. Bir BTA'nın 197-202 arasındaki farklı dilimlerde tersinir yöntem sonrası gerçekleştirilen damar bölütleme görüntüleri

ÖZGEÇMİŞ

24.11.1982 yılında Erzurum'da doğdu. İlk, orta ve lise öğrenimini Erzurum'da tamamladı. 2003 yılında Dokuz Eylül Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü (İNG)'nde lisans programına başladı ve 2007 yılında bu bölümden mezun oldu. 2010 yılına kadar İstanbul'da özel firmada Yazılım Uzman Yardımcısı olarak çalıştı. 2010 yılında Erzurum Atatürk Üniversitesi Bilgisayar Uygulama ve Araştırma Merkezi'nde Uzman olarak çalışmaya başladı. 2011 yılında Atatürk Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünde Araştırma Görevlisi olarak göreve başladı. 2012 yılında Atatürk Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans öğrenimini tamamladı. Atatürk Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümündeki araştırma görevliliği halen devam etmektedir. Yabancı dil olarak iyi seviyede İngilizce bilmektedir.

SCI/SCI-E indekslerine giren dergilerde yayınlanan makaleler

1. Bozkurt, F., Köse, C., & Sarı, A., "An inverse approach for automatic segmentation of carotid and vertebral arteries in CTA", Expert Systems with Applications, 93, 358-375, 2018.

Uluslararası Dergi ve Konferanslar kapsamında yapılan yayınlar

1. Bozkurt, F., Köse, C., & Sari, A., "Segmentation of carotid arteries in CTA images using region-based active contours and classification", In Artificial Intelligence and Data Processing Symposium (IDAP), 2017 International (pp. 1-8). IEEE, 2017.
2. Bozkurt, F., Köse, C., & San, A., Comparison of seeded region growing and random walk methods for vessel and bone segmentation in CTA images, In Electrical and Electronics Engineering (ELECO), 2017 10th International Conference on (pp. 561-567). IEEE, 2017.