

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**OMUZ MANYETİK REZONANS GÖRÜNTÜLERİNDEN
HUMERUS BÖLÜTLENMESİ VE HİLL-SACHS LEZYONLARININ
TESPİTİ**

AYSUN SEZER

**DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ PROGRAMI**

**DANIŞMAN
DOÇ. DR. SONGÜL ALBAYRAK**

İSTANBUL, 2015

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**OMUZ MANYETİK REZONANS GÖRÜNTÜLERİNDEN
HUMERUS BÖLÜTLENMESİ VE HİLL-SACHS LEZYONLARININ
TESPİTİ**

Aysun SEZER tarafından hazırlanan tez çalışması 25.11.2015 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Doç. Dr. Songül ALBAYRAK
Yıldız Teknik Üniversitesi




Jüri Üyeleri

Prof. Dr. Nizamettin AYDIN
Yıldız Teknik Üniversitesi



Doç. Dr. Olcay KURŞUN
İstanbul Üniversitesi



Doç. Dr. M. Elif KARSLIGİL
Yıldız Teknik Üniversitesi



Doç. Dr. Mustafa Ersel KAMAŞAK
İstanbul Teknik Üniversitesi



ÖNSÖZ

Doktora tez konumu belirlememde, veri setini oluşturmamda, el ile bölütlemde, PD ağırlıklı MR görüntülerini gruplamamda ve doktora sürecini tamamlamamda bana desteğini ve güvenini esirgemeyen eşim Uzm. Dr. Hasan Basri Sezer'e sonsuz duygularıyla teşekkür ederim.

Çalışmalarımızı yönlendiren, sevgisini ve güleryüzünü esirgemeyen danışman hocam Doç. Dr. Songül Albayrak 'a teşekkür ederim.

Çalışmalarım sırasında önemli katkılarda bulunan ve yönlendiren Sayın Prof. Dr. Nizamettin Aydın ve Sayın Doç. Dr. Olcay Kurşun'a teşekkür ederim.

Yıldız Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü çalışanlarına çalışmam süresince gösterdikleri destek ve anlayışları için teşekkürlerimi sunuyorum.

Eylül, 2015

Aysun SEZER

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ.....	vii
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ.....	ix
ÇİZELGE LİSTESİ	xii
ÖZET	xiii
ABSTRACT.....	xv
BÖLÜM 1	
GİRİŞ	1
1.1 Literatür Taraması	2
1.2 Tezin Amacı.....	13
1.3 Hipotez.....	14
BÖLÜM 2	
VERİSETİNİN VE OMUZUN YAPISININ MR GÖRÜNTÜLERİYLE TANITIMI ..	17
2.1 Omuzun Anatomik Yapısı ve Çıkığa Etkisi	17
2.2 Humerus Başında Görülen Lezyonlar	18
2.2.1 Hill-Sachs Lezyonlu Humerus Başı.....	19
2.2.2 Ödemli Humerus Başı.....	22
2.3 Manyetik Rezonans Görüntüleme ve Kullanım Alanları	22
2.4 Omuzun Manyetik Rezonans Görüntülerinin İncelemesi.....	23
2.4.1 Omuz MR Görüntülemeye Kullanılan Puls Sekanslar	24
2.4.2 MR Görüntü Protokolleri.....	25
2.5 Omuz MR Görüntü Anatomisi	25
2.5.1 Aksiyel kesitler:	25
2.5.2 Koronal kesitler	27
2.5.3 Sagittal Kesitler.....	27
2.6 Veri seti ve Özellikleri.....	27

BÖLÜM 3

HUMERUS BAŞININ PROTON DENSİTE AĞIRLIKLI OMUZ MANYETİK REZONANS GÖRÜNTÜ KESİTLERİNDEN BÖLÜTLENMESİ.....	29
3.1 Yayın Taraması.....	31
3.2 Görüntü Ön İşleme Adımları	34
3.2.1 Benek Azaltan Eş yönsüz Yayılım (Speckle Reducing Anisotropic Diffusion) SRAD Yöntemi	35
3.2.2 Homomorfik Filtre	38
3.2.3 İlgili Alanın Tespit Edilmesi (ROI: Region of Interest).....	40
3.2 Segmentasyon Metotları	42
3.2.1 Active Contours Without Edges (ACWE).....	42
3.2.2 Signed Pressure Force Model (SPF).....	44
3.2.3 Gaussian Mixture Model (GMM).....	45
3.2.4 Fuzzy C- Means (FCM) Method	47
3.3 Postprocessing	49
3.4 Uygulama Sonuçları ve Değerlendirilmesi.....	51

BÖLÜM 4

HUMERUS BAŞLARINDAN ÇIKARILAN DOKU VE ŞEKİL ÖZELLİKLERİ	52
4.1 Yayın Taraması.....	55
4.2 Doku ve Şekil Özellikleri	60
4.2.1 Gray Level Co-occurrence Matrix (GLCM).....	61
4.2.2 Pyramid of Histogram Orientation Gradients (PHOG)	64
4.3 Transform Tabanlı Doku Özelliklerinin Çıkarılması	67
4.3.1 Curvelet Transform Tabanlı İkinci Dereceden İstatistiksel Doku Analizi	67
4.3.2 Contourlet Transform Tabanlı İkinci Dereceden İstatistiksel Doku Analizi.....	70
4.3.3 Hermite Transform Tabanlı İkinci Dereceden İstatistiksel Doku Analizi	72
4.4 Shearlet Transform Tabanlı PHOG Yöntemi ile Şekil Analizi	75
4.5 Şekil ve Doku Özelliklerinin Bir Arada Kullanılmasıyla MR Görüntülerinin Sınıflandırılması.....	76
4.6 Bağımsız Eğitim ve Test Kümelerinin Sınıflandırma Başarıları	76

BÖLÜM 5

SONUÇ VE ÖNERİLER.....	79
KAYNAKLAR	83
ÖZGEÇMİŞ	90

SİMGE LİSTESİ

$p_i^{(r)}$	Ayrık önsel olasılık (discrete prior probability)
ε	Belirlenen hata miktarı
$q_0(t)$	Benek ölçeklendirme fonksiyonu
ω	C konturunun iç kısmı (ön plan)
∇	Del opearatörü
Div	Diverjans (divergence) operatörü
$\delta(\phi)$	Dirac fonksiyonları
$P_{i,j}$	GLCM matrisi
$H(\phi)$	Heaviside fonksiyonları
Δ	Laplace Operatörü
λ_1	Kontura uygulanan iç kuvvetler
λ_2	Kontura uygulanan dış kuvvetler
μ	ortalama
$\partial\omega$	Konturu (C) tanımlar
$\Omega \setminus \varpi$	Parametresi ise konturun dış kısmını yani arka planı belirler.
spf	Signed pressure force fonksiyonu
$p_{ij}^{(r+1)}$	Sonrasal olasılık
v	Yayılım hızı kontrol
$c(q)$	Yayılım katsayısı
$q(x, y; t)$	Yerel varyasyon katsayısı
C	Yumuşatma katsayısı
var	Varyans

KISALTMA LİSTESİ

AD	Anisotropic Diffusion – Eş yönsüz Yayılım
AC	Articular Cartilage of Glenoid
ACL	Anterior Cruciate Ligament
ACWE	Active Contour Without Edge
BT	Bilgisayarlı Tomografi
DHT	Dairesel Hough Transform
FCM	Fuzzy C Means – Bulanık C Ortalamalar
GLCM	Gray Level Cooccurency Matrix – Gri Seviye Eş-oluşum Matrisi
GMM	Gaussian Mixture Model
KNN	K-Nearest Neighbor
MR	Magnetic Resonance – Manyetik Rezonans
MLP	Multilayer Perceptron
ROI	Region of Interest – İlgi Alanı
SAR	Sentetik Açıklık Radar – Synthetic Aperture Radar
SNR	Signal Noise Ratio – Sinyal Gürültü Oranı
SPF	Signed Pressure Force
SRAD	Speckle Reducing Anisotropic Diffusion – Benek Azaltan Eş yönsüz Yayılım
SVM	Support Vector Machine

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 İki boyutlu CT görüntülerinden soldaki resim normal omuzu sağdaki iki resim ise fusion alanında deformasyonu göstermektedir.	5
Şekil 1.2 Humerus ve glenoid bölgesi segmentasyon sonucu kırmızı ve mavi bölgeler olarak ayırt edilmiştir. Sağdaki resimde birleşme alanında deformasyon olan görüntülerin segmentasyon sonucudur.	6
Şekil 1.3 Dört sınıf kullanılarak elde edilen segmentasyon sonuçları (soldaki şekil: K-Means, ortadaki şekil: Bayesian Mixture Model, sağdaki şekil: active contour without edge).	7
Şekil 1.4 Menüsküs bölgesinin histogram uygulama sonucu görünümü [4].....	9
Şekil 1.5 Menüsküs bölgesinin segmentasyon sonuçları [4]	9
Şekil 1.6 Birinci görüntü normal ACL ikici görüntü ise yırtık bulunan ACL görüntüsüdür.	10
Şekil 1.7 Diz eklemine anatomisi	11
Şekil 1.8 Kemik ve cropping maskeleri.....	12
Şekil 2.1 Etkili glenoid kavsi	18
Şekil 2.2 Bozulmuş eklem reaksiyon kuvvetinin etkisiyle humerus başının glenoid kavsiinden çıkmasının şematik olarak gösterimi.	19
Şekil 2.3 Hill-Sachs lezyonu.....	20
Şekil 2.4 Farklı hastalardan alınmış Hill-Sachs lezyonlu PD ağırlıklı MR görüntüleri .	21
Şekil 2.5 Sağ en alttaki MR normal humerus başına aittir. Diğer MR görüntülerinde Hill Sachs lezyonuna rastlanmamıştır fakat ödem bulunmaktadır.	21
Şekil 2.6 Birinci satırdaki MR görüntülerinde az da olsa ödem görülmektedir. İkinci ve üçüncü satırda sadece normal ve ödemli humerus başına ait görüntüler verilmiştir.....	22
Şekil 2.7 Omuz bölgesinde MR görüntü protokolleri.....	25
Şekil 2.8 Omuz aksiyel T1 görüntüsü.....	26
Şekil 2.9 Omuz aksiyel T2 MR görüntüsü	26
Şekil 2.10 Omuz koronal T2 MR görüntüsü.....	27
Şeki 2.11 Omuz sagittal MR görüntüsü.....	27
Şekil 3.1 Bölütme aşamalarının blok diyagramı ile gösterimi.....	30
Şekil 3.2 a) BT b) T1 ağırlıklı MR c) PD ağırlıklı MR görüntü kesitinde humerus başı görünümüleri d) 1)Biceps tendonu 2) Subscapularis tendonu 3)Humerus başı 31	

Şekil 3.3	Birinci satırda T1 ikinci satırda PD ağırlıklı görüntüler yer almaktadır a) T1 ve b)PD ağırlıklı MR görüntüleri c),d) manuel olarak humerus başlarının bölütlenmesi gösterilmektedir. Üçüncü ve dördüncü sütunda ACWE (e,f) ve SPF (g,h) metotları ile bölütlenme sonuçları yer almaktadır. Son sütunda ise ACWE (i,j) metodunun iki seviye (level set) fonksiyonu uygulanarak elde edilen bölütlenme sonucu yer almaktadır.	35
Şekil 3.4	a) MR görüntüsüne, homomorfik filtre b) SRAD c) önce SRAD daha sonra homomorfik filtre d)önce homomorfik filtre sonra SRAD uygulandığında ACWE metodu ile ikili (binary) olarak bölütlenme başarısı.	39
Şekil 3.5	a) Orjinal PD ağırlıklı MR görüntüsü, b) SRAD metodu uygulandıktan sonra elde edilen görüntü c) Homomorfik filtre uygulandıktan sonra elde edilen görüntü d) SRAD ve arkasından homomorfik filtre uygulandığında elde edilen sonuç görüntüsü.....	40
Şekil 3.6	a) Orjinal PD ağırlıklı MR görüntüsü b) SRAD ve homomorfik filtre uygulamasından sonra elde edilen görüntü c) DHT ile elde edilen humerus başı görüntüsü d) Başlangıç çemberinin büyütülmesi ile elde edilen ilgili alan.	41
Şekil 3.7	a) Orijinal PD ağırlıklı sol ve b) sağ omuz MR görüntüsü ve DHT yöntemi ile elde edilen çalışma alanları (ROI).....	41
Şekil 3.8	a) Orjinal PD ağırlıklı omuz MR görüntüsü, (b) Herhengi bir ön işlem adımı uygulamadan ACWE metodu ile yapılan bölütlenme (c) SRAD ve homomorfik filtre uygulanarak gerçekleştirilen ön işlem adımından sonra ACWE metodu ile elde edilen bölütlenme sonucu, (d) Belirlenen alana içerisinde (c) maddesindeki aynı işlemleri gerçekleştirilmesi sonucu elde edilen sonuç görüntüsü.	44
Şekil 3.9	a) DHT ile saptanılan ilgili alanın omuz MR görüntüsü. (b) FCM method ile kümeleme sonucu. (c) GMM method ile elde edilen bölütlenme sonucu.	49
Şekil 3.10	a) Aksiyal PD ağırlıklı MR görüntüsü, b) biceps ve subscapularis tendonları kırmızı alan ile gösterilmiştir. Humerus başı ve skapula bölgeleri mavi ve yeşil alan ile ifade edilmiştir.	50
Şekil 3.11	Son işlem adımları a) DHT ile bulunan ROI, b) İlgili alanda gerçekleştirilen bölütlenme sonucu, c) morfolojik işlemler ve temel bileşenler analizi sonucu elde edilen görüntü, d) Ödemden kaynaklanan beyaz piksellerin filling işlemi ile giderilmesi, e) Bölütlenme sonucu.	50
Şekil 3.12	Normal, ödemli ve Hill-Sachs lezyonlu omuz başlarının manuel, SPF ve ACWE metodları ile bölütlenmesi. (a) orijinal PD görüntüleri, (b) uzman tarafından yapılan manuel bölütlenme, (c) ACWE metodu, (d) SPF metodu ile bölütlenme sonuçlarının gösterimi.	51
Şekil 4.1	Önerilen bilgisayar destekli tanı sistemin genel akış diagramı	60
Şekil 4.2	PD ağırlıklı sol omuz görüntülerinde a) ödemli humerus başı b) normal humerus başı c) uzman tarafından yapılan manuel bölütlenme d) ACWE metodu ile gerçekleştirilen bölütlenme e) otomatik olarak alınan ödemli ve f) normal görüntü parçaları (image patches).	61
Şekil 4.3	GLCM matrisinin oluşturulmasının görsel ifadesi.	62
Şekil 4.4	a) Ödemli omuz MR görüntü parçası a) PHOG metodunun sıfırıncı piramit seviyesi b) PHOG metodunun birinci piramit seviyesi c) PHOG metodunun ikinci piramit seviyesi için elde edilen histogramın gösterimi.	66
Şekil 4.5	Çok çözünürlüklü (multiscale) ve çok yönlü (multidirectional) olarak MR görüntülerinin contourlet transformu ile dekompozisyonu.	71

Şekil 4.6 Hermite transformunu PD ağırlıklı MR görüntülerine uygulamamız sonucunda elde edilen alt bant (band-pass subimages) görüntülerinin gösterimi (Hermite katsayıları $D_{m,n-m}$ için $m = 0,1, \dots, n$, ve $n=3$, ile m parametresi ile x , $n-m$ parametresi ile y yönünde değişim.).....	73
Şekil 4.7 Farklı doku analiz yöntemlerinin (Hermite, curvelet, contourlet tabanlı GLCM ve GLCM yönteminin doku analizi) farklı sınıflandırıcılarla (SVM, MLP ve KNN) karşılaştırılmasının grafiklerle gösterimi.	74

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 1.1 Sınıflandırmanın sınıf karışıklık matrisi.	58
Çizelge 1.2 Algoritmalara göre sınıflandırma başarısı.....	58
Çizelge 3.1 ACWE ve SPF metotları ile elde edilen bölütleme başarılarının ön işlemde önce ve sonra için gösterimi.	57
Çizelge 3.2 ACWE, SPF, GMM ve FCM metotları ile ön işlemde sonra elde edilen bölütleme başarılarının gösterimi.....	58
Çizelge 4.1 GLCM özelliklerinin simetrik olmayan yapıda farklı uzaklık ve açısal parametreleri ile hesaplama ($\theta_1 = 0^\circ, 45^\circ, 90^\circ$ and 135°).	69
Çizelge 4.2 GLCM özelliklerinin simetrik yapıda farklı uzaklık ve açısal parametreleri ile hesaplama ($\theta_1 = 0^\circ$ ve 180°).	69
Çizelge 4.3 PHOG özellikleri ile humerus başının sınıflandırma başarılarının farklı parametrelerle incelenmesi (K= histogram aralığı (bin), R = oryantasyon aralığı ve L = piramit seviyesi)	70
Çizelge 4.4 Curvelet tabanlı ikinci dereceden istatistiksel doku özelliklerinin farklı sınıflandırıcılar ile sınıflandırma başarısı oranları.	75
Çizelge 4.5 Contourlet tabanlı ikinci dereceden istatistiksel doku özelliklerinin farklı. sınıflandırıcılar ile sınıflandırma başarısı oranları	76
Çizelge 4.6 Hermite tabanlı ikinci dereceden istatistiksel doku özelliklerinin farklı sınıflandırıcılar ile sınıflandırma başarısı oranları	79
Çizelge 4.7 FDST katsayıları ile PHOG tabanlı şekil özelliklerinin sınıflandırma başarısı (K=8, R=[0,360] ve L=3).	81
Çizelge 4.8 Hermite tabanlı ikinci dereceden istatistiksel doku özelliklerinin farklı sınıflandırıcılar ile sınıflandırma başarısı oranları	82
Çizelge 5.1 Önerilen doku analiz yöntemlerinin farklı sınıflandırıcılarla hassasiyet, belirginlik ve doğruluk parametreleri ile karşılaştırılmalı olarak analizi.	85
Çizelge 4.9 Rastgele seçilen bağımsız 10 farklı veri seti üzerinde SVM metodu ile farklı doku ve şekil özelliklerin sınıflandırma başarılarının analiz sonuçları.	85

ÖZET

OMUZ MANYETİK REZONANS GÖRÜNTÜLERİNDEN HUMERUS BÖLÜTLENMESİ VE HILL-SACHS LEZYONLARININ TESPİTİ

Aysun SEZER

Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

Tez Danışmanı: Doç. Dr. Songül ALBAYRAK

Proton dansite (PD) ağırlıklı MR görüntülerinde homojenlik, sinyalin gürültüye oranının düşük olması ve kemik sınırlarının açıkça belirgin olmaması problemleri mevcuttur. PD ağırlıklı görüntülerin bu özellikleri PD görüntülerinin bölütlenmesini hatta gözle algılanmasını zorlaştırmaktadır. Çalışmanın amacı bilgisayar destekli tanı (BDT) sistemi geliştirerek normal ve anormal (ödemli ve Hill-Sachs deformiteli) humerus başı görüntülerini Hermite transformundan ve PHOG (Pyramid of histograms of orientation gradient) metodundan türetilen doku ve şekil özellikleri ile tanıyabilmek ve ACWE (active contour without edge) modelinin PD ağırlıklı görüntülerden humerus başını bölütlemedeki verimliliğini belirlemektir. Gürültünün standart sapmasını SDN (standard deviation of noise) ilgili alandan ROI (region of interest) tahmin ederek SRAD (speckle reducing anisotropic diffusion) metodunun kullanım alanını PD ağırlıklı MR görüntüleriyle genişlettik. Otomatik olarak dairesel Hough transform ile başlangıç konturunun yerini belirleyerek bölgesel tabanlı metotların başlangıç konturunun yerini

belirleme probleminin üstesinden geldik. Signed pressure force (SPF) model, Fuzzy C-means ve Gaussian mixture modelleri karşılaştırma amacıyla uygulandı ve dört metodun bölütleme sonuçları aynı zamanda alan uzmanının manuel olarak gerçekleştirdiği sonuçlarla karşılaştırıldı. Hermite transform tabanlı doku özelliklerinin humerus kemiğini sınıflandırma performansı curvelet, contourlet ve GLCM (gray level co-occurrence matrix) tabanlı doku tanımlayıcıları ile karşılaştırılarak değerlendirildi. Hermite tabanlı doku özellikleri, görüntü şekillerini yerel ve düzenini uzaysal olarak tanımlayan PHOG ile birleştirildi. Çıkarılan özellikler MLP (Multi-Layer Perceptron), SVM (Support Vector Machine) ve KNN (K- Nearest Neighbors) metotları ile değerlendirilerek normal ve anormal alanları tanımlama performansları değerlendirildi. Önerilen yaklaşım kendi veri setimiz olan 79 normal, 140 anormal (91 ödemli ve 49 Hill-Sachs lezyonlu) PD ağırlıklı humerus başı MR görüntüleri üzerinde test edildi. Hermite tabanlı doku analizi ve PHOG metodu ile en yüksek sınıflandırma başarısı SVM metodu ile % 99.54 elde edildi. Elde ettiğimiz sonuçlar önerilen sistemin normal ve anormal PD ağırlıklı MR görüntülerinin sınıflandırılmasında ümit verici olduğunu belirtmektedir. Hermite transform tabanlı özellik analizi ile PD ağırlıklı MR görüntülerinden kemik lezyonlarını sınıflandırma açısından literatürde örnek çalışmadır.

Anahtar Kelimeler: PD ağırlıklı MRG, Active Contour Model, Kemik bölütleme, Speckle Reducing Anisotropic Diffusion, Hermite transform, Çok çözünürlüklü (Multiresolution) doku analizi

ABSTRACT

SEGMENTATION OF HUMERAL HEAD FROM MAGNETIC RESONANS SHOULDER IMAGES AND DETERMINATION OF HILL-SACHS LESIONS

Aysun SEZER

Department of Computer Engineering

PhD. Thesis

Adviser: Assoc. Prof. Dr. Songül ALBAYRAK

Proton density (PD) weighted MR images present inhomogeneity problem, low signal to noise ratio (SNR) and cannot define bone borders clearly. Segmentation of PD weighted images is hampered with these properties of PD weighted images which even limit the visual inspection. The objective of this research is to develop a computer based diagnosis (CBD) system which is capable of recognizing normal and abnormal (edematous and Hill-Sachs deformities) humeral head images by using texture and shape features derived from Hermite transform and PHOG (Pyramid of histograms of orientation gradient) method and determine the effectiveness of segmentation of humeral head from axial PD MR images with active contour without edge (ACWE) model. We extended the use of speckle reducing anisotropic diffusion (SRAD) in PD MR images by estimation of standard deviation of noise (SDN) from ROI. To overcome the problem of initialization of the initial contour of these region based methods the location of the initial contour was automatically determined with use of circular Hough transform. For comparison signed pressure force (SPF) model, Fuzzy C-means and Gaussian mixture models were applied and segmentation results of all four methods were also compared with the manual segmentation results of an expert. The performance of Hermite transform based texture features in classification of humeral bone was compared with curvelet, contourlet and

gray level co-occurrence matrix (GLCM) based texture feature descriptors. Hermite based texture feature combined with PHOG which captures the local image shape and its spatial layout. To measure the performance of the extracted features, we deployed MLP (Multi-Layer Perceptron), SVM (Support Vector Machine) and KNN (K- Nearest Neighbors) methods and demonstrated their power in differentiating the normal and abnormal regions. The proposed approach was tested on our own dataset which consists of 79 normal, 140 abnormal (91 edematous and 49 Hill-Sachs) humeral heads in PD weighted MR images. The highest classification accuracy of Hermite based texture analysis and PHOG method was 99.54 % by SVM. Our results suggest that the proposed system is a promising tool for classification of normal and abnormal bone from PD weighted MR images. This study is unique in the literature of using PD weighted MR images and Hermite transform based texture analyses to classify bone lesion.

Keywords: PD weighted MRI, Active Contour Model, Bone Segmentation, Speckle Reducing Anisotropic Diffusion, Hermite transform, Multiresolution based texture analyses

BÖLÜM 1

GİRİŞ

Bilgisayar destekli sistemlerin artmasıyla görüntü işleme yöntemiyle bilgi çıkarımına olan ihtiyaç her geçen gün artmaktadır. Sektörlerin genelinde görüntüden elde edilen veriler karar destek sistemi tarafından kullanılmaktadır. Özellikle medikal uygulamaların yapıldığı sektörlerde görüntü işleme ve bilgi çıkarımı karar almada kritik rol oynamaktadır. Medikal alanlarda bilgisayar destekli görüntü analizlerinin çeşitliliği, operasyonların bilgisayar ile yapılmaya başlanması ve paralelinde veri boyutunun artması bilgisayar destekli karar destek sistemlerine olan ihtiyacı artırmıştır.

Çalışmamız kapsamında medikal görüntüleme tekniklerinden olan manyetik rezonans (MR) görüntüleri kullanılarak omuz başı bölgesinde meydana gelen lezyonları saptamaya çalışılmıştır. Uygulama sonucunda elde edilecek bilgi kesin tanı içermemektedir. Uygulama sonuçları ortopedi doktorlarına ve radyoloji uzmanlarına karar vermelerinde destek sağlayacaktır. Radyoloji uzmanları MR görüntülerini okuyabilmektedir. Fakat ortopedi uzmanının anatomik ve klinik bilgisi olmadan son tanı koyulamamaktadır. MR görüntüleri kullanılarak patolojileri saptamak için anatomik bilgi tek başına yeterli değildir. Bu bilgiyi MR üzerindeki görüntü ile eşleştirmek gerekmektedir. Dolayısıyla aynı MR görüntüsü üzerine özellikle patoloji inceleniyorsa uzmanlar tarafından farklı yorumlar yapılabilmektedir. Bunun en önemli sebebi MR görüntüsünün netliği ve kişinin algısıdır. Algılardaki farklılıklar karar vermeyi zorlaştırmaktadır ve genellikle alınan kararlar klinik çalışmalarla desteklenmektedir. Dolayısıyla omuzda lezyon olabilir denilen hastanın hikayesine ve klinik muayenesine bakılır. Omuz vücutta bulunan en hareketli eklemdir ve yapısı oldukça komplekstir. Omuz eklemi hareket ettiren kasların humerus kemiğe uyguladığı net eklem reaksiyon kuvveti etkili glenoid kavisini geçerse

omuzda çıkık oluşmaya başlar. Glenoid kavsini artıran yapılardan biri labrumdur. Dolayısıyla labrumun hasar görmesi omuz çıkığına etki eder.

Labrumu hasarlı olan hastalarda genellikle Hill-Sachs lezyonuna rastlanmaktadır. Labrum takoz blok etkisi yaparak humerus başının etkili glenoid kavsini geçmesini engeller. Labrum dejenere olduğunda bu yapı bozulur ve humerus başı yerinden çıkarak omuz çıkığı rahatsızlığı ortaya çıkar.

Anterior (ön ve üst) çıkıkta humerus başının glenoidin anterior kenarına çarpması nedeniyle humerus başı arkasında çökme kırığı oluşur ve bu lezyon Hill-Sachs olarak adlandırılır. Lezyon incelediğimiz için proton dansite ya da T2 ağırlıklı MR kesitleri kullanabiliriz. Hill-Sachs lezyonu proton dansite ağırlıklı aksiyal kesitlerde daha iyi görülebilmektedir. Humerus başı MR görüntülerinden bölütlendikten sonra humerus başında çökme varsa Hill-Sachs lezyonu, çökme yok fakat humerus başında kemik iliği ödemi oluşmuş ise ödemli olarak etiketlenecektir. Humerus başını sınıflandırmak için Hill- Sachs, ödemli humerus başı ve normal olmak üzere üç etiket kullanılacaktır.

Raporun birinci bölümünde literatür taramasına, tezin amacına ve katkılarına yer verilmiştir. Literatür tarama sürecinde omuz bölgesinde bölütleme ile ilgili birtakım çalışmalara rastlanılmıştır fakat omuz lezyonları üzerine yapılmış çalışmalara rastlanılmamıştır. Dolayısıyla literatür taramasına vücudun diğer bölgelerinde rastlanabilecek yumuşak doku lezyonları taraması eklenmiştir. Raporun ikinci bölümünde omuzun anatomik yapısı, kırığın patofizyolojisi omuzda görülen lezyonlar ve bu lezyonların MR görüntülerinden anatomik yapı bilgisi ile nasıl ayırt edilebileceği ele alınmıştır. Raporun üçüncü ve dördüncü kısmında humerus başının bölütlenmesi ve sınıflandırılması, yapılan örnek çalışmaların taranması ve kullanılan yöntemlerin ayrıntılı olarak ele alınması sağlanmıştır. Son bölümde ise uygulama sonucu elde edilen sonuçların karşılaştırılmalı olarak değerlendirilmesi sağlanmıştır.

1.1 Literatür Taraması

Literatürde görüntü segmentasyonları ile ilgili oldukça fazla yaklaşım mevcuttur fakat volumetrik medikal görüntülerde segmentasyon yaklaşımlarını beş sınıfta incelemek mümkündür. Bunlar eşik değer tabanlı (threshold based) , sınır tabanlı (boundary based), bölge tabanlı (region based), görev odaklı hibrid (task oriented hybrid metod) ve atlas

tabanlı bölütleme metodları olarak özetlenebilir. Eşik değeri tabanlı yöntemi genellikle yarı otomatik ve piksellerin parlaklık bilgisine bakılarak ilgili bölgelerin sınıflandırılmasını sağlar. Eğer eşik değerini kullanıcı belirliyorsa sistemin başarısı kullanıcının başarısına bağlı olarak değişir. Ayrıca farklı dokuların aynı yoğunluk değeri ile ifade edilebildiğinden birçok medikal çalışmada tek başına uygulandığında olumlu sonuç vermemiştir. Sınır tabanlı metotta ise iç içe geçmiş sınıfların birbirinden ayırt edilmesi için genellikle filtreleme yapılır fakat volümetrik medikal görüntülerde dokular arasında geçişler oldukça yumuşak olduğundan anatomik yapıların sınıflandırmasında yüksek başarı sağlanamamıştır. Dolayısıyla kontur kapatma (contour closing) gibi yaklaşımlarla ön işlemler yapılır fakat bu ön işlemlerin pratikte uygulanması oldukça zordur. Bölge tabanlı (Region based) yaklaşım ise piksellerin belirlenen referans noktasından itibaren komşuluk ve homojenlik bilgilerini kullanarak pikselleri birleştirme işlemi ile gerçekleştirilir. Bölge tabanlı yaklaşım interaktiftir ve piksellerin birleştirilme işleminin hangi noktaya kadar devam ettirileceği belirlenmelidir. Kompleks yapıdaki medikal görüntülerin bölütlenmesinde genel olarak belirlenen referans noktasından itibaren ne kadar büyütüleceği genişlik, şekil, boyut, anatomik yapı gibi bilgiler ile desteklenir. Ayrıca komşu piksel değerleri ve ilgili alanın yoğunluk bilgisi de kullanılmaktadır. Tek başına yoğunluk ve geometrik tabanlı yaklaşımların medikal uygulamalarda segmentasyonu istenilen başarıyı sağlamadığından iki yöntem bir arada kullanılmıştır. Hybrid yöntem hem yoğunluk hem anatomik bilgiyi ele aldığından daha iyi sonuç vermiştir. Fakat medikal görüntülerde anatomik yapının iyi bir şekilde görüntüden çıkarılabilmesi için anatomik yapı, lokasyon, şekil ve bunlar arasında ilişki kurabilen bir yöntem ihtiyacı vardır. Dolayısıyla atlas tabanlı görüntü bölütleme yöntemi birçok medikal görüntü bölütlenmesinde yaygın olarak kullanılmıştır.

Atlas tabanlı görüntü segmentasyonu rijit (rigid) ve rijit olmayan (non rigid) görüntü çakıştırma yöntemleri ile yapılmaktadır. Rijit yöntemle görüntü çakıştırdığımızda görüntü üzerinde döndürme, öteleme ve ölçeklendirme yapılabilir. Ancak rijit yöntemde objenin yapısında çok fazla değişiklik yapılmadıysa görüntü eşleştirmesinde başarılı olabilir. Segmente edilecek bölge rijit değilse, anatomik yapılarda olduğu gibi her görüntüde değişiklik oranı fazlaysa bu yöntemle görüntü çakıştırma istenilen başarıyı sağlayamayabilir. Fakat rijit (non rigid) olmayan yöntemle görüntü çakıştırdığımızda döndürme, öteleme ve ölçeklendirmenin yanında anatomik varyasyonlarda ele alınmış

oluruz. Medikal görüntülerde özellikle yumuşak doku ve bu dokularda meydana gelen patolojiler incelenecekse rijit olamayan (non rigid) yöntemle görüntü çakıştırmak oldukça zordur. Omuz başında meydana gelen lezyonların büyüklüğü hastalığın türüne ve seviyesine göre çok fazla farklılık göstermektedir. Dolayısıyla oluşturulacak bir ya da daha fazla atlas ile görüntü bölütlenmesini başarılı bir şekilde sağlamak oldukça zordur. Veri setimizin karakteristik özelliklerine en uygun olan bölütleme yöntemi bölgesel tabanlı aktif kontur model yaklaşımlarıdır.


Literatür çalışması süresince omuz bölgesi bölütleme çalışmalarına oldukça az rastlanılmıştır ve bunlardan sadece bir tanesinde kısmen patoloji çalışılmıştır. Literatür çalışmasında öncelikle omuz bölgesinde yapılan bölütleme çalışmalarına yer verilmiştir. Daha sonra vücudun diğer bölgelerinde ortopedik rahatsızlıklara yol açan yırtık ve patoloji çalışmaları incelenmiştir. Bu anlamda diz kapağında menüsküs denilen yırtık, ön ve arka çapraz bağ yırtığı ve bel kısmında vertebra diskleri dejenerasyon çalışmalarına rastlanılmıştır. Bölütleme çalışması olarak diz kapağında menüsküs bölgesi, ön çapraz bağ (ACL), vertebra disklerinin segmentasyonu incelenmiştir.

Omuz bölgesinde yapılan çalışmalar:

Glenoid bölgesi implantasyonlarının ameliyat öncesi planlamasını yapabilmek için CT görüntülerinde üç boyutlu modelleme yapılması gerekmektedir. Bu amaçla J. Chaoui tarafından yapılan çalışmada CT görüntülerinde kemiksel bölgeler, humerus başı ve glenoid bölgesi tanımlama tabanlı bölütleme (Recognition Based Segmentation) yöntemi ile bölütlenmesi sağlanmıştır [1]. Kemik yapısının homojen olmayan doku dağılımından görüntülerde kemik bölgesinin segmentasyonunu yapmak oldukça zor bir çalışmadır. Ayrıca kemik bölgelerdeki zayıf kenarlar, iç bölgelerdeki daralmalar, CT görüntülerindeki bulanıklık ve kısmi volüm etkisi (partial volume effect) bu tür çalışmaların zorluğunu daha da artırmaktadır. Bu zorluklara rağmen CT görüntülerinden kemik bölgelerdeki çıkıntıları, kayıpları, şekilsel değişiklikleri, eklem bölgelerdeki kayıpları yakalamak mümkündür.[1]

Humerus başı yuvarlaktır ve glenoid denilen omuz eklem oyğunun içinde yer alır. İki bölgenin birleştiği yerde yumuşak eklemler mevcuttur. Bu dokular ve kaslar sayesinde omuz hareketleri sağlanabilmektedir. CT görüntülerinden humerus başı ve glenoid bölgesi arasındaki birleşme (fusion) alanı ve bu alanlardaki deformasyonlar

görülebilmektedir[1]. CT görüntülerinde birleşme alanındaki deformasyonlu omuz ve sağlam omuz görüntüleri yer almaktadır (Şekil 1.1), (Şekil 1.2).




Şekil 1.1 İki boyutlu CT görüntülerinden soldaki normal omuzu, sağdaki iki görüntü ise fusion alanında deformasyonu göstermektedir.

Yapılan çalışmada glenoid bölgesi ve humerus başının otomatik olarak “recognition based algoritması” ile bölütlenmesi sağlanmıştır. Öncelikle humerus ve skapula bölgesine ait vokseller etiketlenmiştir. Matematiksel morfolojik filtrelemeden sonra üç boyutlu şekil tanıma (shape recognition) algoritması uygulanmıştır [1]. Birleşme bölgesi Fourier tanımlayıcılar (Fourier descriptors) ve kontur model sayesinde tamamen otomatik olarak ayırt edilebilmiştir (Çizelge 1.1).


Çizelge 1.1: Sınıflandırmanın sınıf karışıklık matrisi [1]

	Sistem Tahmini %			
Sınıf	Humerus	Scapula	Fusion	Rejected
Humerus	96	0	0	4
Scapula	0	88.89	0	10.08
Fusion	0	7.02	91.31	0
Rejected	0	0	0.7	97.5



Şekil 1.2 Humerus ve glenoid bölgesi segmentasyon sonucu kırmızı ve mavi bölgeler olarak ayırt edilmiştir. Sağdaki resimde birleşme alanında deformasyon olan görüntülerin segmentasyon sonucudur.

MR görüntülerinden faydalanan omuz bölgesindeki humerus başı, tubercle, ekleme ait kıkırdak (articular cartilage), kas ve scapula başının segmentasyonu ve sınıflandırılması yapılmıştır [2] (Çizelge 1.1). Sınıflandırma işleminden önce veri seti ön işlemlere tabi tutulmuştur. Gri tonlamada homojenliği düzenlemek için homomorfik filtreleme işleminden sonra homojenliği sağlanmış görüntülere adaptif filtre uygulanarak gürültü temizlenmiştir. Son olarak da “dynamical range” operatörü uygulanarak görüntüler normalize edilip kontrastlık bilgisi artırılmıştır. Sınıflandırma metotları olarak “k-means” algoritması, “bayesian mixture model” ve “active contour without edge” algoritması kullanılmıştır. Dört sınıf kullanılarak humerus başı, tubercle, ekleme ait kıkırdak (articular cartilage), kas ve scapula başı bölgeleri her bir metod ile sınıflandırılmaya çalışılmıştır. Humerus başı ve tubercle’nin büyük bölümü, articular cartilage “k-means” algoritması ile bulunamamıştır. Fakat kas ve scapula başı bölgelerinin bulunmasında “k-means” başarı sağlamıştır. “Bayesian mixture model” ise articular cartilage ve humerus başı, tubercle bölgelerinin bulunmasında olumlu sonuç verirken active contour without edge algoritması tüm bölgelerde sınıflandırmayı başarı ile sağlamıştır [2] (Çizelge 1.2).



Şekil 1.3 Dört sınıf kullanılarak elde edilen segmentasyon sonuçları (soldaki şekil: K-Means, ortadaki şekil: Bayesian Mixture Model, sağdaki şekil: active contour without edge).

Çizelge 1.2: Algoritmalarla göre sınıflandırma başarıları [2]

	Sınıflandırma Başarıları		
	K-Means	Bayesian Mixture Model	Active Contour without Edge
Humerus Başı	Başarılı	Başarılı	Başarılı
Articular Cartilage	Başarılı	Başarılı	Başarılı
Kas Doku	Başarısız	Başarısız	Başarılı
Scapula Başı	Başarısız	Başarısız	Başarılı

Bölge tabanlı ve “Gradient based supervised” yöntemi ile MR görüntülerinden humerus başı bölgesinin segmentasyonu sağlanabilmektedir [3]. Nguyen tarafından yapılan çalışmada deneyimli bir kişiye humerus başı bölgesinden bir nokta seçtirilerek isointensity konturlar kümesi seçilen referans noktasına göre oluşturulmuştur. En iyi isointensity kontur ise kontur gradyanı alınarak belirlenmiştir. Amaç istenilen bölgeyi en iyi gösteren MR dilimini seçmektir. Yine referans noktası kullanılarak “region growing” algoritması ile humerus başı segment edilmiştir. Elde edilen sonuç radyoloji uzmanının manüel olarak segment ettiği veri ile karşılaştırılmıştır. Bütün veri seti üzerindeki başarı ise % 96.32 olarak belirlenmiştir [3].


Bölge tabanlı (Region based) segmentasyonun başarıları seçilen referans noktasına ve alanın ne kadar büyütülebileceğini kestirmeye bağlıdır. Alanın ne kadar genişletileceğine özellikle homojen ve karmaşık yapıda olan medikal görüntülerde şekil, büyüklük parlaklık bilgileri kullanılarak karar verilir. Bölge tabanlı segmentasyon yöntemi ile kenar bilgileri yöntemini bir arada kullanarak karmaşık yapıda olan omuz MR görüntülerinin bölütlenmesi sağlanabilmektedir. Öncelikle ilgili alan dikdörtgen pencerelerle sınırlandırılmıştır. Bu alanda Sobel filtresi kullanılarak kemiksel bölgelerin kenar bilgileri elde edilmiştir. Elde edilen kontur bilgileri kısmi volüm etkisinden dolayı istenilen

durumda değildir. Bu konturlar kullanılarak histogram bilgisi çıkartılmıştır. Bu histogram bilgilerinden faydalanarak referans noktası belirlenip alan büyütülmesi gerçekleştirilmiştir. Alan büyütülmesinde hangi piksellerin birbiri ile bağlanabileceği bilgisi yine kenar bilgileri uyumuna bakılarak karar verilmiştir. Sistemin başarısı radyoloji uzmanının elle yaptığı bölütleme sonucuna olan benzerliği ile ölçülmüştür [3].


Diz kapağı bölgesinde yapılan çalışmalar:

Femur ile tibia arasında sağ ve solda iki yarım ay şeklinde menisk denen bir kıkırdak bulunur. Diz eklemi yapan elemanlar arasında en çok zedelenen menisk denilen yarım ay şeklindeki iç ve dış kıkırdak disklerdir. Genellikle bu kıkırdak disklerin kapsülleri yırtılır ve ince olan orta parçaları eklem içine uzanarak onu düz tutulamayacak şekilde kenetleyebilir. Halk arasında menüsküs denilen hastalık yük altında kalan dizin bükülmesi sonucu oluşan disk yırtılmasıdır. Yarım ay şeklinde olan kıkırdak diskler keçi boynuzunun yapısına da benzetilmektedir. Bu nedenle tıp literatüründe ön ve arka menüsküs boynuzu olarak adlandırılır (Şekil 1.4). Literatürde menüsküs yırtığını bulmaya yönelik bir çok MR görüntü işleme yöntemleri kullanılmıştır. Yapılan bir çalışmada istatistiksel metotlar kullanılarak diz kemikleri MR görüntülerinden çıkarılmıştır. Kemik bölgeleri (Femur ve Tibia) kıkırdak bölgelerine göre daha az yoğunluğa sahip bölgelerdir. MR dilimlerinde kemik bölgesi ayrıldıktan sonra horizontal ve vertikal histogram yöntemi uygulanarak menüsküs bölgesi dikdörtgen bölge olarak ayrılmıştır [4].

Menüsküsün geometrik yapı bilgisi kullanılarak farklı boyutlarda üçgen şablonlar oluşturulmuştur (Şekil 1.5). Şablon eşleme (Template matching) yöntemi ile üçgensel şekle sahip menüsküs boynuzları saptanmıştır. Menüsküs bölgesi koyu renkte üçgene benzerken yırtığın olduğu bölgeler açık renktedir. Yani yüksek yoğunluktaki pikseller yırtığın olduğu yerde düşük yoğunluktaki pikselleri çevrelemektedir. Yoğunluk bilgisi kullanılarak belirlenen eşik değerinin üstündeki değerlerde hastanın menüsküs yırtığının bulunduğu belirlenmiştir. Bu yöntem diğer 30 MR görüntüsüne uygulanarak % 93.5 oranla menüsküs yırtığı saptanmıştır[4].



Şekil 1.4 Menüsküs bölgesinin histogram uygulama sonucu görünümü [4]




Şekil 1.5 Menüsküs bölgesinin segmentasyon sonuçları [4]

Yarı otomatik olarak menüsküs yırtığının bulunması da mümkündür. Yarı otomatik denilmesinin sebebi belirli bir noktanın (seed) ve MR dilimlerinin seçiminin manuel olarak yapılmasıdır. Görüntü üzerinde bir başlangıç noktası seçildikten sonra yoğunluk bilgisi kullanılarak oluşturulan maske ile yoğunluk değeri 120 ile 450 arasında olan pikseller görüntüden silinmiştir. Bu aralıkta menüsküs mevcut değildir. İkinci bir mask kullanılarak tibia ve femur kemikleri görüntüden çıkarılmaya çalışılmıştır fakat kemiklerle birlikte eklem (cartilage) dokunun bir kısmı da çıkarıldığında bu maske kenar yakalama ve range filtre algoritmaları ile desteklenmiştir. İlgilenilen alanda (region of interest), alınan başlangıç noktası ile otomatik olarak eşik değerleri belirlenmiştir. Gauss yoğunluk dağılımı kullanılarak ilgili alanlar dört kısımda ele alınmıştır. Bunlar menüsküs bölgesi, kemik bölgesi, eklemler ve menüsküs içinde yoğunluğu yüksek olan alanlardır.


Bu bölgelerde tanımlama, eşik değeri belirleme, segmentasyon, koşullu silme ve silinecek pikselleri belirleme aşamaları uygulanarak segmentasyon işlemi tekrarlı olarak gerçekleştirilmiştir. 10 normal 14 menüsküs hastası MR görüntüleri kullanılmıştır (Şekil 1.6). Önerilen yöntemin başarısını ölçmek için uzman kişi tarafından manuel olarak bölütlenen menüsküs bölgesi ile sistemin bölütlediği menüsküs bölgesi benzerliğine bakılmıştır ve benzerlik oranı % 0.8 olarak hesaplanmıştır [5].

Menüsküs yırtığı tespiti yarı otomatik olarak gerçekleştirildiği gibi tam otomatik olarak da saptanabilmektedir. Bu önerilen tam otomatik segmentasyonda MR görüntülerinden kullanılacak olan dilim (slice) otomatik olarak seçilmiştir. Bu amaçla her bir dilimde menüsküs alanının oranı hesaplanarak bu orana bağlı pencereler oluşturulup ilgili alan seçilmiştir. Bu alanda menüsküs bölgesini bulmak için yoğunluk bilgisi, farklı şekil kısıtları (shape constraint) ve istenilmeyen bölgeleri çıkarmak için sınırlayıcı kutu (bounding box) yöntemleri uygulanmıştır. Segmentasyonu sağlanan menüsküs yırtığının dejenerasyon tipi belirlenmiştir ve sistemin hassasiyet (sensitivity) değeri % 83.87 olarak saptanmıştır [6].

Menüsküs bölgesini ayırt etmek için yapılan çalışmalarda genellikle piksellerin yoğunluk bilgisi kullanılmıştır. Yoğunluk tabanlı yaklaşımla birlikte görüntüde bir başlangıç (seed) noktası belirlenerek bölgesel genişletme (region growing) tekniği uygulanarak menüsküs segmentasyonu sağlanmıştır [7]. Diğer yaklaşımlar ise aktif şekil (active shape) [8] model ve yılan (snake) modelidir [9][10].




Şekil 1.6 Birinci görüntü normal ACL ikinci görüntü ise yırtık bulunan ACL görüntüsüdür.



Şekil 1.7 Diz ekleminin anatomisi

KNN algoritması kullanılarak MR görüntülerinden ön ve arka çapraz bağların sınıflandırılması sağlanmıştır (Şekil 1.6), (Şekil 1.7). Sınıflandırmada hiyerarşik yapı kullanılmıştır. Önce iki sınıf belirlenerek arka plan ve bağ doku (ligament) ayrılmıştır. Sonra üç sınıf ile tibial bağ, femoral bağ ve arka plan sınıflandırılmıştır. Radyoloji uzmanı ilgili alanı seçerken lokasyon ve yoğunluk bilgisini kullanmıştır. Bu durum göz önüne alınarak özellik belirlemede (candidate feature) yoğunluk ve geometrik bilgiler dikkate alınmıştır. KNN sınıflandırması için approximate nearest neighbor algoritması kullanılmıştır. Sistemin hassaslığı (sensitivity) %90 olarak hesaplanmıştır [11]. Folkeson bu çalışmasını genişleterek üç sınıf yerine iki sınıf kullanarak sınıflandırmayı yapabilmektedir. Bu amaçla eşik değeri belirlemiştir. Tibial ve femoral bağ sınıfına ait değilse ve belirlenen eşik değer aralığındaysa arka plana aittir diyerek iki sınıfta sınıflandırmıştır [12].

ACL segmentasyonu için başka bir çalışmada morfolojik operasyonlar ve "active contour" yöntemi uygulanmıştır. Tibia ve femur kemikleri yapısı göz önüne alınarak kemik mask ve kesme işlemi için cropping mask oluşturulmuştur (Şekil 1.8). Kemik mask kullanılarak MR görüntülerinden kemik bölgesi çıkarılmıştır. ACL yapısı 45 derece civarında eğimli yapıda olduğundan 45 ve 60 derecelik eğimlerle morfolojik işlemler (line structuring element) uygulanarak ACL bölgesine ait olmayan bölgeler kemik bölgeleriyle birlikte MR görüntülerinden çıkarılmıştır. Önerilen yöntem 111 MR görüntüsüne uygulanarak ACL segmentasyonu sağlanılmıştır. Sistem belirginlik (specifity) değeri %99.4 olarak hesaplanmıştır [13].



Şekil 1.8 Kemik ve cropping maskeleri

Yoğunluk tabanlı çapraz bağ segmentasyonunda watershed tabanlı bölütleme algoritması uygulanmıştır. Bu yöntemde pikseller yoğunluk değerlerine göre küçükten büyüğe sıralanarak bir dizide saklanılmıştır. Eşik değeri belirlenerek watershed algoritması uygulanmıştır. Watershed yöntemi dar alanlarda ve bulanıklığı fazla olan görüntülerde iyi sonuç vermemektedir[14]. Bu yöntem atlas tabanlı hizalama (atlas based registration) yöntemi ile desteklenerek segmentasyon başarıları artırılmıştır[15]. Ama piksellerin yoğunluk bilgisi ve KNN algoritması uygulanarak yapılan segmentasyon yöntemi önerilen yöntemlerden daha hızlı çalışmaktadır. Ayrıca düşük çözünürlükteki MR görüntülerinde de iyi sonuç vermektedir. Folkeson çalışmasında bütün vokselleri kullanarak sınıflandırma yapmak yerine çapraz bağ kısmına ait olan vokselleri sınıflandırmıştır. Çapraz bağ kısmına ait vokselleri hiyerarşik yapı kullanarak sınıflandırma ile tespit etmiştir.[11][12][16].

Şekil ve Model tabanlı (Shape ve Model based) yaklaşımla çapraz bağ segmentasyon çalışmaları da mevcuttur. Yılan yayılım (Diffusion snake) algoritması bu amaçla kullanılmıştır. Eğitim ve segmentasyon verileri olmak üzere veri seti iki gruba ayrılmıştır. Eğitim verileri kullanılarak segmentasyonu yapılacak bölgenin geometrik yapısı ve varyasyonları oluşturulmaya çalışılmıştır. Eğitim veri seti üzerinde belirlenen elle belirlenen noktalar (landmark) kullanılarak görüntü şablonu oluşturulmuştur. Diğer görüntü setinde bu şablon kullanılarak segmentasyon yapılmıştır[17]. Fakat bu yöntem

ile görüntüdeki bazı sınır bölgeleri ayıramamıştır. Bu sorunun üstesinden gradient based snake algoritması gelmiştir [18].

Active Shape model kullanarak ön çapraz bağlardaki yırtıklar varyasyonları verilen popülasyonda yakalanabilmiştir. Morfolojik atlas sağlıklı kişilerin görüntüleri kullanılarak çıkarılmıştır. Bu atlas ve active shape model kullanılarak verilen bir MR görüntüsünde çapraz bağ zedelenmesinin olup olmadığı tespit edilebilmiştir [19].

Atlas tabanlı yaklaşımı ile bel bölgesinde omurlar arası diskler ve bu disklerdeki bozulmalar T1 formunda alınan MR görüntülerinden yararlanılarak bulunabilmiştir. Disklerin segmentasyonunda olasılıksal atlas yaklaşımı kullanılmıştır. Ortopedi uzmanı görüntülerden bir tanesinde diskleri manuel olarak segmente etmiştir. Bu görüntü referans görüntüsü olarak alınarak rijit landmark yöntemi ile 49 MR görüntüsü ile olasılıksal (probabilistic) disk atlas oluşturulmuştur. Oluşturulan atlas ve rijit landmark yöntemiyle görüntü karşılaştırıldıktan sonra Fuzzy c-means (FCM) algoritması ile piksellerin hangi dokunun elemanı olduğu belirlenmiştir. Piksel değerleri kemik, disk ve cerebrospinal fluid olarak üç sınıfta gruplandırılmıştır. Atlas FCM yöntemi normal disklerde %89.2, dejenere olan disklerde ise %84.4 başarı ile sınıflandırılmıştır [20].

1.2 Tezin Amacı

Çalışmamızın amacı proton dansite ağırlıklı aksiyal MR kesitlerinden humerus bölgesinin segmentasyonunu sağlayarak bu alanlarda meydana gelen omuz lezyonlarını otomatik olarak tanımlayabilecek bilgisayar destekli tanı sistemi geliştirmektir. Omuz rahatsızlığına neden olan birçok lezyon bulunmaktadır. Çalışmamızda omuzda ağrıya neden olan humerus başındaki ödem ve genellikle cerrahi müdahale gerektiren Hill-Sachs lezyonu incelenecektir.

Omuzda görülen lezyonların saptanması PD ağırlıklı görüntülerin gürültü içermesi, yumuşak dokular arasındaki geçişlerin yumuşak olmasından dolayı gözle bu bölgelerin belirlenip tanı koymasını zorlaştırmaktadır. Radyoloji uzmanları MR görüntülerini değerlendirdikten sonra ortopedi uzmanlarınca bu değerlendirmeler klinik bulgularla desteklenerek son karar verilmektedir. Önerdiğimiz sistem tanı amacıyla değil uzmanlara tanı koymakta destek olabilecek bir sistem sağlamak amacıyla yapılmıştır. PD ağırlıklı görüntülerde omuz lezyonlarını doğru olarak saptamakta kişinin uzmanlık alanı,

görüntüdeki algı, deneyimi, çalışma süresi gibi parametreler etki etmektedir. Bu parametreler sağlanamadığı durumlarda hasta yanlış tanı ile tanımlanabilmektedir. Önerdiğimiz sistem ile alan uzmanına tanı ve tedavi süresinden önce ön bilgi vermeyi amaçlıyoruz.

1.3 Hipotez

Medikal görüntülerde ilgili alanı ortaya çıkarmak ve patolojileri yakalamak oldukça zor çalışmalardır. Medikal görüntüleme teknikleri (ultrason, bilgisayarlı tomografi (BT), manyetik rezonans) kullanılarak elde edilen görüntülerde dokular arasındaki geçişler oldukça yumuşaktır. Aynı yoğunluk değeri ile farklı dokular görüntülenebilir. Dokular arasındaki bu yumuşak geçiş ilgili alanın sınırlarını bulanıklaştırır (blurred boundaries). Medikal görüntülerde yumuşak doku geçişlerinin yol açtığı bulanıklık problemi kısmi volüm etkisi (partial volume effect) olarak adlandırılır. Kısmi volüm etkisi yanında inter ve intra modality olarak adlandırdığımız görüntüleme problemleri de vardır. Intra modality problemi iki durumda ortaya çıkar. Görüntü alınırken hastanın hareket etmesinden dolayı görüntüde kaymalar olabilir. Ayrıca görüntü aynı cihaz kullanılarak alınsa bile görüntünün alındığı objeler değiştiğinden anatomik varyasyonlar ortaya çıkar bu da görüntünün segmentasyonunu zorlaştırır. Inter modality problemi ise aynı objenin görüntüleri farklı cihazlardan alınıp çıktılarını birleştirerek bilgi çıkarımı yapılmasıdır. Çalışmamız kapsamında biz sadece aynı cihazla farklı kişilerin görüntülerini değerlendireceğimiz için intra modality problemi ile ilgileneceğiz. Farklı kişilerin görüntüleri aynı cihazla bile görüntülense MR görüntüleri arasında yoğunluk farklılıkları bulunmaktadır. Hatta aynı hastanın görüntülerinde farklı MR kesitlerinde bile yoğunluk farklılıklarına rastlanmaktadır. Bu durum ise “compact region” problemi olarak nitelendirilir. Partial volume effect, inter intra modality, compact region gibi problemlerden dolayı medikal görüntülerin segmentasyonunu yapmak zordur ve bu problem merkezi problem (central problem) olarak adlandırılır.

MR görüntüleri kullanılarak yapılmış bölütleme çalışmaları mevcuttur. T1 baskılı MR görüntüleri yumuşak dokuyu göstermez ve anatomik yapıları özellikle kemik bölgelerini göstermekte oldukça başarılıdır. Fakat bu görüntülerde lezyon incelemesi mümkün değildir. Humerus başında meydana gelen ödemi ancak PD baskılı MR görüntülerinde saptamak mümkündür. PD ağırlıklı MR görüntüleri diğer görüntüleme tekniklerine göre

daha gürültülü verilerdir. Bunun yanı sıra yumuşak dokuları ve patolojileri göstermesi kemik bölgesinin bölütlenmesini zorlaştırmaktadır. Dokular arasında geçişler oldukça yumuşaktır. Lezyonlu görüntüler ile çalıştığımız için birçok görüntüde kenar bilgileri deforme olmuştur hatta bazı görüntülerde tamamen yok olmuştur. Gürültü giderimi ve bölütleme aşamasında kenar bilgilerine hassasiyeti az olan yöntemlerin seçilmesi gerekmektedir.

Rician gürültü olarak adlandırılan gürültü giderimi için benek azaltan eş yönsüz yayılım (Speckle Reducing Anisotropic Diffusion SRAD) yöntemi kullanıldı. Bu yöntem ultrason ve uydu görüntülerinde kullanılabilen ve benek azaltan bir yöntem olarak bilinmektedir. SRAD metodu sadece benek gürültüyü azaltmak için değil standart sapması (Standart deviation of noise) (SDN) belirlenen her türlü gürültü giderimi için kullanılabilir. SRAD yöntemi ile gürültü giderimi PD ağırlıklı MR görüntülerine ilk kez uygulanması sağlandı. Görüntüdeki homojenliği düzenlemekte SRAD yöntemi tek başına yeterli olmayacağından homomorfik (homomorphic) filtre ile desteklenerek medikal görüntülerin genel problemi olan homojenlik sağlanmaya çalışıldı. SRAD yöntemi yumuşatma işlemini kenar bilgilerinin paraleli doğrultusunda gerçekleştirdiğinden hem kenar bilgilerini korudu hem de eş yönsüz yayılım (anisotropic diffusion) yönteminin gerçekleştiremediği komşu piksellerde gürültü kalmasını engelledi.

Görüntülerde homojenlik sağlandıktan sonra bölgesel tabanlı ACWE (active contour without edge) ve SPF (signed pressure force) yöntemleri ile dairesel Hough transformu ile belirlenen ilgili alanlarda humerus başının bölütlenmesi sağlatıldı. Bölgesel tabanlı yöntemlerden ACWE görüntünün kenar bilgisi zayıf hatta hiç olmayan görüntülerde başarılı sonuçlar vermektedir. Çünkü kenar tabanlı yöntemler gibi sadece gradyan bilgisine dayalı olarak başlangıç konturuna uygulanacak iç ve dış kuvveti belirlemez. Gradyan bilgisi olsa da olmasa da belirlenen iç ve dış kuvvetleri Mumford-shah optimizasyon tekniği ile düzenlemektedir. Bu özelliği bizim veri setimizin zayıf tarafını tamamlamaktadır. Fakat bölgesel tabanlı yöntemler görüntünün homojen olduğunu varsaymaktadır ve bu yöntemlerin başarısı başlangıç konturunun yerini belirlemeye göre değişmektedir. Bu problemleri çözmek için birçok çalışma yapılsa da henüz tam olarak çözüm üretilmemiştir. Çalışmamızda bu sorunları aşmak için homojenlik SRAD ve homomorfik filtre ile sağlandı. Başlangıç konturunun yeri de otomatik olarak dairesel

Hough transformu yardımıyla belirlendi. Omuz başı yuvarlak yapıda olduğu için dairesel Hough transformuyla omuz bölgesinin üzerine başlangıç konturu konumlandırılarak önerilen yöntemlerin başarısı artırıldı. Bölütleme başarısı GMM (gaussian mixture model), k-means ve fuzzy c-means gibi yöntemlerle bölütlenerek karşılaştırmalı çalışması yapıldı.

Bölütleme işleminden sonra her bir çalışma MR grubu için şekil ve doku özellikleri çıkarıldı. Şekil özelliklerinden Histogram oriented gradients (HOG) yönteminin geliştirilmiş hali olan Pyramid of Histogram orientation gradients (PHOG) kullanılarak hem uzaysal (spatial) hem de frekans alanında şekil özellikleri çıkarıldı. PHOG yöntemi yüz ve yüzdeki ifadeleri tanımak için yaygın olarak kullanılmasına rağmen medikal görüntülerde şekil özelliği çıkarmak için çok az sayıda kullanılmıştır.

Doku özellikleri çıkarmak için GLCM (gray level co-occurrence) tabanlı ikinci dereceden istatistiksel yöntemler kullanılmıştır. Bu yöntemin başarısı wavelet, curvelet, contourlet ve shearlet gibi transformlarından elde edilen katsayılar üzerinden yapılan istatistiksel ölçümlerle artırılmış çalışmalar mevcuttur. Çalışmamızda bu yöntemlerin yanı sıra wavelet tabanlı olmayan, yerel ve ortogonalite özelliği barındıran Hermite transformu kullanılarak GLCM tabanlı doku özellikleri hem uzaysal hem de frekans alanından çıkarılmıştır.

Görüntülerin normal, ödemli ve Hill-Sachs lezyonlu olarak başarıyla sınıflandırılabilmesi ancak doku ve şekil özelliklerinin bir araya getirilmesi ile mümkündür. SVM (support vector machine), MLP (multilayer perceptron) ve KNN sınıflandırıcıları ile karşılaştırılmalı olarak önerilen sistemin performansı ölçülmüştür.

PD ağırlıklı görüntüler ile literatür taraması süresince vücudun herhangi bir bölgesinde yapılmış çalışmaya rastlanılmamıştır. Çalışmamız SRAD yönteminin MR görüntülere uygulanması, bölgesel tabanlı yöntemlerin başlangıç konturu yerini belirleme ve homojenliğin sağlanması, doku özelliklerinin Hermite transform tabanlı çıkarılması ve orijinal veri seti kullanılması bakımından özgündür.

BÖLÜM 2

VERİSETİNİN VE OMUZUN YAPISININ MR GÖRÜNTÜLERİYLE TANITIMI

2.1 Omuzun Anatomik Yapısı ve Çıkığa Etkisi


Omuz eklemi anatomik olarak kıkırdakla örtülü iki adet kemik yapı ve bunları birbirine bağlayan eklem kapsülü, glenohumeral bağlar, kıkırdak, rotator manşet kasları ve diğer kaslardan oluşan bir komplekstir. Omuz eklemi (joint) vücutta bulunan en hareketli eklemdir. Bu hareket kabiliyeti omuzun kemik yapılarının kısıtlı olmamasından kaynaklanır. Bu nedenle omuz ekleminin dengesi kemikleri bağlayan bağlar, kaslar ve kıkırdak yapıda olan labrum tarafından sağlanır (Şekil 2.1). Omuz ekleminin statik dengeleyicileri labrum, glenohumeral (kürek kemiğiyle humerus arasında) ligamanlar (bağlar) ve dinamik dengeleyicisi rotator manşet kasları ve diğer kaslardır [21].

Omuz eklemi vücutta en sık çıkıkla karşılaşılan büyük eklemdir. Yüksek hareket kabiliyeti dengesinin belli bir ölçüde azalmasına yol açar. Aynı zamanda vücudun en aktif eklemlerinden biri olması vücudun kendini koruma refleksinde rol alması nedeniyle de sıkça yaralanmaktadır. Kazar ve Relovszky omuz çıkıklarının tüm eklem çıkıklarının yaklaşık %45'ni oluşturduğunu tespit etmişler ve bu çıkıkların da %85'inin anterior (öne doğru) çıkıklar olduğunu göstermişlerdir [22]. Hastanın yaşam kalitesi ve sportif aktiviteleri üzerindeki olumsuz etkileri düşünüldüğünde, omuz çıkıklarının kesin tedavi gerektiren bir durum olduğu açıktır.

Çıkığın Patofizyolojisi:

Net eklem reaksiyon kuvveti: Eklemi hareket ettiren kaslar tarafından humerus kemiğine uygulanan kuvvettir (Şekil 2.1).

Etkili glenoid kavsi: Humerustan aktarılan reaksiyon kuvvetini karşılama kapasitesine sahip olan glenoid kavsidir. Net eklem reaksiyon kuvvetinin etkili glenoid kavsinin geçmesiyle çıkık oluşmaya başlar. Bu kavis doğuştan veya travmatik olaylar (glenoid kenar kırıkları, Bankart lezyonu) sonucunda bozulabilir.




Şekil 2.1 Etkili glenoid kavsi

Glenoid konkavitesi glenoid kemik yüzeyin ve bunu örten kıkırdak-labrumun birleşmesi sonucu oluşmuştur. Glenoid yüzeyi neredeyse düz bir eklem yüzeyine sahiptir. Bu haliyle stabilizeye büyük bir katkısı olmayan glenoid, ancak kıkırdak ve labrum sayesinde konkav bir yüzeye sahip olmuştur. Cooper ve arkadaşlarının [23] tanımlamasına göre; labrum glenoid eklem kıkırdağına dar bir fibrokartilaj (içinde fibröz doku ihtiva eden kıkırdak) geçiş bölgesi ile bağlanan fibröz bir halkadır. Labrum etkili glenoid kavsinin arttırarak çıkığı engelleyen bir takoz vazifesi görür. Labrumun tek başına çıkarılması eklem dengesini % 20 oranında azaltır[24].

2.2 Humerus Başında Görülen Lezyonlar

Omuz bölgesinde görülen birçok lezyon mevcuttur. Fakat biz humerus başında meydana gelen Hill–Sachs ve kemik iliği ödemi lezyonları inceleyeceğiz. Humerus kemiğine uygulanan net eklem reaksiyon kuvveti genellikle bankart lezyonu olan kişilerde glenoid kavsinin bozulmasıyla azalmış denge stabilize açısından dolayı omuz çıkığına neden olur (Şekil 2.2). Labrum glenohumeral eklem stabilizesinden birkaç yolla etkilidir. Glenoid soketin derinliğinin yaklaşık %50'lik kısmını fibröz bir yapı olan labrumun sağladığını

göstermişlerdir. Labrumun stabilize edici etkisini, yokuş aşağı duran arabanın kaymasını engelleyen takoz-blok şekline benzetmişlerdir. Labrum kapsüloligamentöz yapılar için tutunma noktası olarak da işlev görür. Bunun yanı sıra labrum temas yüzeyini artırarak yük taşıyıcı bir etkiye de sahiptir. Rotator manşet kasılmaları sırasında labrumun belirgin derecede stabilizeyi artırıcı etkisi olduğunu, bunu da konkavite kompresyon mekanizmasıyla rotator manşetin humerus başını glenoide bastırması sonucu meydana getirdiğini göstermişlerdir. Bankart lezyonu, rotator manşet kasılması sırasında meydana gelen konkavite kompresyon etkisini bozarak takoz-blok mekanizmasını bozar.



Şekil 2.2 Bozulmuş eklem reaksiyon kuvvetinin etkisiyle humerus başının glenoid kavsinden çıkmasının şematik olarak gösterimi.

Tekrarlayan omuz çıkığı olmayan gençlerde tek başına ön ve üst kısımdaki labrum yırtığı genellikle görülmez. Ön ve üst kısımdaki labrumda glenoide gevşek yapışma veya defekt olması genelde labrum yırtığından çok yapısal bir durumdur .


2.2.1 Hill-Sachs Lezyonlu Humerus Başı


1880’de Eve omuz çıkığı olduktan 12 saat sonra ölen bir hastanın otopsisinde humerus başının posterolateralinde derin bir oluk olduğunu fark etmiştir [24]. Bundan sonra bir çok yazar bu defekti tespit etmiş ve 1940 yılında Hill ve Sachs yayınladıkları derlemede humerus başındaki kompresyon kırığı ile ilgili tüm bilgileri net bir şekilde tariflemişlerdir. Bu lezyon da kendi adları ile anılmaya başlanmıştır (Şekil 2.3).




Şekil 2.3 Hill-Sachs lezyonu

Hill-Sachs lezyonu, anterior çıkıkta humerus başının glenoidin anterior kenarına çarpması nedeniyle humerus başı arkasında oluşan bir çökme kırığıdır. Humerus başının %30'dan büyük kısmını ilgilendiren bir defektin varlığı öne doğru instabilite gelişmesine neden olabilir [25]. Anatomik olarak humerus oluğu Hill Sachs lezyonuyla karışabilir ancak Hill Sachs lezyonu daha yukarıda görülür (Şekil 2.4) ve (Şekil 2.5).






Şekil 2.4 Farklı hastalardan alınmış Hill-Sachs lezyonlu PD ağırlıklı MR görüntüleri



Şekil 2.5 Sağ en alttaki MR normal humerus başına aittir. Diğer MR görüntülerinde Hill Sachs lezyonuna rastlanmamıştır fakat ödem bulunmaktadır.

2.2.2 Ödemli Humerus Başı

Çalışmamızda humerus başı MR görüntülerinden segmentasyon yapıldıktan sonra Hill-Sachs lezyonu, ödemli ve normal olarak üç sınıfta sınıflandırılacaktır. Humerus başında çökme varsa bu görüntüler Hill-Sachs olarak etiketlenecek, Hill-Sachs yok fakat kemik iliği ödemi oluşmuş humerus başı da ödemli olarak etiketlenecektir (Şekil 2.6)



Şekil 2.6 Birinci satırdaki MR görüntülerinde az da olsa ödem görülmektedir. İkinci ve üçüncü satırda sadece normal ve ödemli humerus başına ait görüntüler verilmiştir.

Ödem bulunan PD ağırlıklı görüntülerde yoğunluk değerlerinde artış görülür. Bu yoğunluk artışı Hill-Sachs lezyonu bulunan hastalarda da görülebilmektedir. Fakat lokasyon olarak humerus başının kenar kısmında çökme kırığının meydana geldiği bölgelerde yer almaktadır. MR görüntüleri hastalık şikayeti ile gelen hastaların klinik muayenesinden sonra uygun görüldüğü için alınmıştır. Dolayısıyla bizim normal MR olarak gruplandırdığımız MR görüntülerin de de az da olsa ödem bulunmaktadır. Ödem hem bölütleme hem de sınıflandırma aşamasında çalışmamızı zorlaştırmaktadır.

2.3 Manyetik Rezonans Görüntüleme ve Kullanım Alanları

Görüntüleme teknolojileri arasında en etkileyici olanlardan biri manyetik rezonans görüntülemidir. MR görüntüleme ağrısız, alerjiye yol açacak ilaç verilme zorunluluğu

olmayan ve x-ışını gibi zararlı olabilecek araçlar kullanmayan bir tanı tekniğidir. Hasta güçlü bir elektromıknatıs içeren bir silindirin içinde yatarken, vücuttaki hidrojen atomlarının enerji salmasına yol açan radyo dalgaları gönderilerek işlem gerçekleştirilir. H^+ iyonları normal ortamlarda kendi eksenlerinde titreşim hareketi yaparlar. Bu iyonlar bir manyetik alana girdiklerinde ise manyetik alanın yönüne göre (N kutbuna) dizilme eğilimi gösterir ve bu yön doğrultusunda titreşim hareketlerine devam ederler. Üzerlerine yüksek radyo frekans dalgası uygulandığında ise bu protonlar radyo frekans dalgalarının bazılarını soğurur bazılarını ise yayarlar. Bu durum protonların (H^+ iyonları) yoğunluk, dağılım ve dizilişlerine göre değişiklikler gösterir. MR cihazı protonların radyo frekans ve manyetik alan altındaki bu özelliklerine dayanarak görüntülerini oluşturur.

MR görüntüleme vücudun tüm doku ve organlarından radyasyon kullanılmaksızın ayrıntılı görüntülenebilmesine olanak veren en gelişmiş tıbbi görüntüleme yöntemidir. Günümüzde MR özellikle yumuşak dokuları görüntülemeye kullanılır. Yumuşak dokuların görüntülenmesinde çözünürlüğü yüksektir. MR görüntüleme tekniğinin tıpta kullanım alanları oldukça yaygındır. Örneğin beyin tümörlerinin araştırılması, sinir kılıflarını inceleyip çoklu (multiple) skleroz bulgularının değerlendirilmesi, beyin kanaması ve eklem rahatsızlıklarını değerlendirmek gibi karışık ve zor işlemler gerçekleştirilebilir. Ayrıca kaslar, bağlar, kan damarları, kalp, karaciğer ve böbrek gibi organlar hastalık yönünden taranabilir. Elde edilen görüntüleri değerlendiren bir radyoloji uzmanı bilgisayar aracılığıyla ek bazı işlemler yaparak daha detaylı ve farklı bilgiler (3 boyutlu görüntüler, fonksiyonel görüntüler, biyokimyasal incelemeler, anjiyografi görüntüleri) elde edebilir. Kas-iskelet sistemi hastalıklarında (ortopedi) da yine MR menüsküs zedelenmeleri başta olmak üzere spora bağlı yada bağımsız gelişen patolojilerde yüksek doğruluk oranında ve noninvaziv (hastaya zarar vermeyen) radyolojik tanı yöntemi haline gelmiştir. Bağ zedelenmeleri, kemik berelenmesi, tendon yırtıkları, bel fıtığı (disk hernisi), kas hasarları gibi birçok hastalıkta yüksek doğruluk oranında tanı koyma olanağı sağlamaktadır.

2. 4 Omuzun Manyetik Rezonans Görüntülerinin İncelemesi

Manyetik rezonans görüntüleme omuz patolojilerini değerlendirmede son yıllarda artan öneme sahiptir. MR'ın diğer görüntüleme modalitelerine göre avantajları; mükemmel yumuşak doku kontrastı, multiplanar çözünürlük kapasitesi, iyonize radyasyon

kullanılmaması ve noninvaziv olması gibi özellikleridir. Ancak direkt grafi, USG artrografiden daha pahalıdır. Omuz MR görüntüleme rotator cuff lezyonları ve glenohumeral instabilitenin değerlendirilmesinde temel inceleme yöntemi kabul edilmektedir. Çalışmamızda omuz başı Hill-Sachs ve kemik ödemi lezyonları MR görüntüleri kullanılarak incelenecektir.

2.4.1 Omuz MR Görüntülemede Kullanılan Puls Sekanslar

Omuz görüntülemede gradyan eko ve konvansiyonel spin eko sekansları kullanılmaktadır.

Konvansiyonel spin eko sekansları: Omuz lezyonlarının teşhisi için geliştirilmiş major kriterler konvansiyonel puls sekanslarına dayanır. T1 ve T2 ağırlıklı, proton dansite ağırlıklı sekanslar omuz MR görüntülemesinde çok sık kullanılır.

T1 ağırlıklı kesitler, yumuşak doku ve kemik yapıların anatomik detaylarını daha iyi gösterir ve periartiküler (eklem çevresi) yağlı planların, kemik iliğinin değerlendirilmesinde özellikle kullanılır. T1 ağırlıklı kesitlerde çekim zamanı kısadır.

T2 ağırlıklı kesitler, yumuşak doku ödemi ve patolojik sıvı koleksiyonlarının yüksek sinyal yoğunluğu göstermesi nedeniyle rotator cuff, kapsüloabral kompleks ve çevresindeki sinyal değişimlerinin gösterilmesinde tercih edilir.

Proton dansite ağırlıklı incelemede, sinyalin gürültüye oranı (signal to noise ratio, SNR) düşük olmasına rağmen anatomik detaylar, rotator cuff, kapsulo-labral yapıları görüntülemede hassasiyeti fazladır. T2 ağırlıklı ve proton dansiteli incelemelerde inceleme zamanı uzundur. Bu da hareket artefaktları oluşmasına neden olur. T1 ağırlıklı kesitlerde; kas ve hyalin kıkırdak orta yoğunlukta; T2 ağırlıklı kesitlerde, yağ içeren yapılar, hyalin kıkırdak, bursal sıvı koleksiyonu yüksek sinyal yoğunluğunu gösterir. T1 ve T2 ağırlıklı kesitlerde; glenoid labrum, rotator cuff tendonları, eklem kapsülü, kortikal kemik gibi fibröz yapılar sinyalsiz, yani siyah görülür (Hareketli protonlardan yoksundur).

Gradient eko görüntüleme: Görüntüleme zamanı spin eko sekanslara göre daha kısadır. Gradient eko kesitlerde doku kontrastı farklı olarak kas sinyal yoğunluğu yüksek, kemik iliğinin yoğunluğu düşüktür. Gradient eko sekanslar rotator cuff görüntülenmesinde yumuşak dokuların yüksek sinyal yoğunluğu göstermesi nedeniyle yalancı pozitif


sonuçlar verebilir. Gradient eko özellikle glenoid labrumu değerlendirmede kullanılır. Fakat bizim elimizdeki MR görüntülerinde bu görüntü sekansı bulunmamaktadır.

2.4.2 MR Görüntü Protokolleri

Aksiyel plan: Üstten alta kadar 4 mm'lik aksiyel kesitler alınır. Anatomik detayların T1 ağırlıklı kesitlerde, labrum patolojilerinin de T2 ağırlıklı kesitlerde gösterilmesinde kullanılır (Şekil 2.7).

Koronal oblik plan: Supraspinatus kasının eksenine paraleldir. Önden arkaya doğru bir incelemedir. ; T1,T2 ve proton dansite ağırlıklı sekanslar kullanılabilir.

Sagittal oblik plan: Koronal oblik plana dik kesitler alınır . Sagittal oblik planda T1,T2 ağırlıklı veya gradient eko sekanslar kullanılır. Korako-akromial ark ve Rotator cuff anatomisi bu planda iyi görülür.




Şekil 2.7 Omuz bölgesinde MR görüntü protokolleri

2.5 Omuz MR Görüntü Anatomisi

Yerleşimleri farklı olduğu için her bir kesitte farklı anatomik yapılar farklı şekillerde görünmektedir.

2.5.1 Aksiyel kesitler:

Rotator manşet kasları, deltoid kası, labrum ve eklem kıkırdağını değerlendirmede kullanılır (Şekil 2.8), (Şekil 2.9).



Şekil 2.8 Omuz aksiyel T1 görüntüsü




Şekil 2.9 Omuz aksiyel T2 MR görüntüsü

Labrum; glenoid çevresinde düşük sinyal intansitesindedir. Normalde aksiyel kesitlerde labrumun ön kısmı arka kısmından daha yuvarlak ve küçüktür. *Glenohumeral eklem kıkırdağı*; glenoid kavitenin konkasitesi boyunca T1 ağırlıklı kesitlerde orta intansitede T2 ağırlıklı kesitlerde yüksek sinyal yoğunluğunda görülür. Glenohumeral eklem kıkırdağı en iyi yağ baskılamalı T2 ağırlıklı kesitlerde değerlendirilir.

Medial glenohumeral ligaman(bağ); labrum anteriorunda düşük sinyal intansiteli ince bir bant şeklindedir. İnferior glenohumeral bağ inferior glenohumeral eklemden geçen kesitlerde gevşek bir yapıdadır. Superior glenohumeral bağ korakoid ve biceps tendonu seviyelerinde görülür. Humerus başını aksiyel planda homojen olmayan yoğunlukta gösterir.

2.5.2 Koronal kesitler


Rotator manşet kaslarından en sık yaralanan supraspinatus kasının en iyi bu kesitlerde görülür (Şekil 2.10).



Şekil 2.10 Omuz koronal T2 MR görüntüsü

2.5.3 Sagittal Kesitler

Deltoid, rotator manşet kas grupları sagittal plan kesitlerde değerlendirilir (Şekil 2.11).



Şeki 2.11 Omuz sagittal MR görüntüsü

2.6 Veri seti ve Özellikleri

MR cihazının uzay çözünürlüğü bilgisayarlı tomografi cihazınınkinden çok farklı değildir. 64X64 düşük matris değeriyle başlayan MR görüntüleri bugünlerde 256X256 hatta 512X512 yüksek matris değerlerinde yüksek çözünürlüklü görüntüler üretebilmektedir. MR çalışma prensibi doğrultusunda yumuşak dokuları BT ye ve diğer

nükleer görüntüleme cihazlarına oranla daha iyi görüntüleyebilir. MR ile diğer yöntemlerin aksine hastanın herhangi bir şekilde pozisyonu değiştirilmeden kesit planı değiştirilebilmektedir. Buna multiplanar görüntüleme denir.

Yumuşak dokularda meydana gelen lezyonları inceleyeceğimiz için PD ağırlıklı MR görüntüleri kullandık. Humerus başında meydana gelen lezyonlar MR'ın aksiyal kesitlerinde görülebilmektedir. Çalışmamızda iki boyutlu görüntüleri analiz ettik çünkü bu lezyonlar hakkında 3 boyutlu görüntülerden bilgi çıkarımı yapmak zordur. Alan uzmanları değerlendirme yaparken iki boyutlu MR kesitlerini inceleyerek tanıyı belirleyebilmektedir. Çalışmamızda kullandığımız MR görüntüleri, Şişli Etfal Eğitim ve Araştırma hastanesinden toplanmıştır. 1.5 T (tesla) dicom görüntüleri 256X256 çözünürlükte ve kesitler arası 4mm'dir. Toplanan veri seti 79 normal, 140 anormal (91 ödemli ve 49 Hill-Sachs lezyonlu) olmak üzere 219 adet PD ağırlıklı humerus başı MR görüntülerinden oluşmaktadır.

BÖLÜM 3

HUMERUS BAŞININ PROTON DENSİTE AĞIRLIKLI OMUZ MANYETİK REZONANS GÖRÜNTÜ KESİTLERİNDEN BÖLÜTLENMESİ


BT (bilgisayarlı tomografi) ve T1 ağırlıklı MR görüntüleri kemik bölgelerini benzer yoğunluk değerleri ile göstermektedir. Yumuşak dokuları ise PD ağırlıklı MR görüntüleri kadar başarılı göstermemektedir. Kemik bölgesinin bölütlenmesi dolayısıyla bu görüntüleme teknikleri ile gerçeklemek PD görüntülerine kıyasla oldukça kolaydır. Fakat hem T1 hem de BT görüntüleri kemik bölgesindeki patolojiler hakkında bilgi veremez. Bu görüntüleme teknikleri ile sadece anatomik yapıda olan bozulmaları gözlemleyebiliriz. Humerus başında meydana gelen patolojileri inceleyeceğimiz için çalışmamızı PD ağırlıklı MR görüntüleri ile gerçekleştirdik. PD ağırlıklı MR görüntüleri diğer görüntüleme modalitelerine göre daha fazla gürültü içermektedir. Sinyalin gürültüye oranı oldukça düşüktür ve bu gürültü Rician noise olarak adlandırılmaktadır [26]. PD ağırlıklı görüntülerde dokular arası geçişler oldukça yumuşaktır ve homojen olmayan görüntülerdir. PD görüntülerinin bu özellikleri uzmanların tanıyı belirlemesini zorlaştırdığı gibi hem manuel hem de görsel olarak bölütlemeyi de zorlaştırmaktadır.

PD görüntülerinden humerus başını bölütlemeye başlamadan önce görüntü ön işleme (pre-processing) tabi tutuldu. Görüntüdeki Rician noise benek azaltan eş yönsüz yayılım (Speckle Reducing Anisotropic Diffusion SRAD) yöntemi ile düzenlendi. Görüntüdeki homojenliği düzenlemekte SRAD yöntemi tek başına yeterli olmayacağından Homomorphic filtre ile desteklendi. Homojenliği sağlanan PD ağırlıklı MR görüntülerine dairesel Hough transformu uygulandı. Humerus başı dairesi bir yapıda olduğu için bu

yöntem ile humerus başı alanı yakalanarak ilgili alan (Region of interest ROI) belirlendi. Active contour without edge methodu (ACWE) ile hem normal hem de patoloji bulunan MR görüntüleri bölütlendi. ACWE metodunun başarısı başlangıç konturun yerine oldukça bağlıdır. Başlangıç konturu bölütlenme yapılacak nesneye ne kadar yakınsa bölütlenme başarısı da buna bağlı olarak değişmektedir. Çalışmamızda başlangıç konturu circular Hough transformu ile otomatik olarak bölütlenmesi yapılacak omuz başı bölgesine konumlandırıldı. ACWE algoritması ile yapılan bölütleme sonrasında humerus başına yapışık şekilde bulunan tendonlar segmentasyon başarısını negatif olarak etkilemektedir. Görüntü bölütleme sonrası işlemler (post-processing) ile görüntü bölütleme başarısı artırıldı.

ACWE metodu ile bölütlenmesi yapılan normal ve patolojik humerus başlarının başarısı uzman kişiler tarafından yapılan manuel bölütleme sonuçları ile Sorensen-Dice metrik kullanılarak karşılaştırıldı. Ayrıca ACWE metodu diğer bölütleme yöntemleri olan Signed pressure force, Gaussian mixture model, k-means ve fuzzy C-means metodları ile karşılaştırıldı.

Omuz ağrısı şikayeti ile gelen hastalardan alınan 1.5 T aksiyal PD ağırlıklı MR görüntüleri çalışmada kullanılmıştır. MR kesitlerinin kalınlığı 4 mm'dir. 79 normal, 91 ödemli ve 49 Hill-Sachs lezyonlu MR omuz görüntüleri olmak üzere toplam 219 MR görüntüleri Şişli Hamidiye Etfal Eğitim ve araştırma hastanesinden temin edilmiştir. Normal ve lezyonlu PD ağırlıklı MR görüntülerin bölütlemesi başarı ile sağlanmıştır. Sistemin blok diyagramı (Şekil 3.1) 'de verilmiştir.




Şekil 3.1 Bölütleme aşamalarının blok diyagramı ile gösterimi

3.1 Yayın Taraması

T1 ağırlıklı MR ve BT görüntülerinde kemik bölgeleri ile yumuşak doku bölgeleri arasında belirgin kontrastlık farklılıkları mevcuttur. Ayrıca kemik dokudan yumuşak dokuya geçiş sınırları oldukça keskindir. Dolayısıyla T1 ağırlıklı MR ve BT görüntüleri kullanılarak yapılan kemik ve yumuşak doku bölgelerinin segmentasyon başarıları görüntü kalitesinin zayıflığına rağmen oldukça tatmin edici düzeydedir.

PD ağırlıklı MR görüntülerinde sinyalin gürültüye oranı diğer görüntüleme tekniklerine oranla çok düşüktür. (Şekil 3.2)'de CT, T1 MR görüntüsü ve PD ağırlıklı MR görüntülerinde humerus başı gösterilmektedir. PD ağırlıklı MR görüntülerinde yumuşak doku ile kemik bölgesi arasındaki geçişler oldukça yumuşaktır ve bölgeler arası kontrastlık farkı oldukça düşüktür. Bu durum PD görüntülerinde hem manuel hem de bilgisayar destekli otomatik segmentasyonu zorlaştırmaktadır (Şekil 3.2).



Şekil 3.2 a) BT b) T1 ağırlıklı MR c) PD ağırlıklı MR görüntü kesitinde humerus başı görünümleri d) 1)Biceps tendonu 2) Subscapularis tendonu 3)Humerus başı

PD görüntülerinde mevcut olan Rician noise düzenlemek için medyan filtre gibi gürültünün görüntüde toplam şeklinde ifade edilen filtreler kullanmak yeterli değildir. Medikal görüntülerde gürültü çarpım şeklinde ifade edildiğinden, medikal görüntü uygulamalarında araştırmacılar doğrusal olmayan yayılım filtrelerini kullanmaya yönelmiştir. Yaygın olarak Lee filtresi, Frost filtresi, Eş yönsüz yayılım (Anisotropic diffusion) (AD) ve SRAD yöntemi yaygın olarak kullanılmıştır [27]. Eş yönsüz yayılım filtresi BT, MR ve ultrason görüntülerinde başarılı bir şekilde kullanılmıştır [26] [28] [29]. Eş yönsüz yayılım filtresi gradyen ve diverjans metotlarına dayalı olup homojen bölgelerde yumuşatma işlemi gerçekleştirirken kenar bölgelerde yumuşatma işlemi uygulamamaktadır. Dolayısıyla görüntüde kenar piksellerin komşuluklarında gürültü kalmasına neden olmaktadır. PD ağırlıklı görüntülerde bölütlemenin daha iyi

yapılabilmesi için kenar bilgilerini yumuşatma işlemi sırasında koruyan ve özellikle kenar piksellerde gürültü bırakmayan bir yöntem ihtiyacı duyulmaktadır.

SRAD metodu eş yönsüz yayılım yönteminden farklı olarak yumuşatma işlemini kenar piksellerinin paraleli doğrultusu yerine normali doğrultusunda gerçekleştirdiğinden kenar piksellerin komşuluklarında gürültü bırakmamaktadır [30]. SRAD metodu benek gürültü azaltmak amacıyla yaygın olarak uydu ve ultrason görüntülerinde kullanılmıştır. SRAD metodu sadece benek gürültüyü azaltmak için değil standart sapması (Standart deviation of noise) (SDN) belirlenen her türlü gürültü için kullanılabilir [26]. SDN değeri PD ağırlıklı görüntülerden hesaplanarak SRAD yöntemi veri setimizde uygulanabilir hale getirilmiştir.

Medikal görüntü uygulamalarında ön işlem ile görüntü homojenliği sağlandıktan sonra arka plan ve objelerin pikselleri çeşitli bölütleme yöntemleri ile bölütlenmektedir. Aktif kontur metodu bölütlemeye yaygın olarak kullanılmaktadır ve uygulama sonuçları oldukça tatmin edicidir. Aktif kontur metodunu, görüntü üzerinde oluşturulan başlangıç konturuna belirlenen kısıtlarla uygulanan iç ve dış kuvveti optimize ederek görüntünün bölütlenmesini sağlar. Aktif kontur modelleri kenar tabanlı (edge-based) [30] [31] ve bölgesel tabanlı yaklaşımlar olarak iki grupta incelenebilir [32] [33] .

Kenar tabanlı yöntemler görüntünün gradyan bilgisini kısıt olarak kullanır ve gradyan ile konturun hareketini kontrol eden kuvvetleri oluştururlar. T1 ve BT gibi kenar bilgileri belirgin olan kemik bölgelerinin bölütlenmesi için uygun olan bu yaklaşım kenar geçişlerinin yumuşak hatta kenar bilgilerinin tamamen kaybolduğu patolojik PD ağırlıklı görüntülerde başarılı bir şekilde kullanımı mümkün değildir [30].

Bölge tabanlı aktif kontur metotlar gradyan bilgisi olsa da olmasa da çalışabilen yöntemlerdir. Konturun hareketini gradyan bilgisi olmadığı yerde kontur içinde ve dışında kalan alanın istatistiksel bilgilerini kullanarak kontura yön verebilmektedir. Bu özelliği sayesinde kenar bilgileri zayıf hatta hiç olmayan görüntülerde de çalışabilmektedir. Bölgesel tabanlı yöntemlerin kenar tabanlı yöntemlere olan diğer üstünlüğü ise başlangıç konturunun yerine bağlılıkları daha azdır. Bu yöntem iç ve dış sınırları başarıyla saptayabilmektedir. Bölgesel tabanlı yöntemlerden yaygın olarak kullanılan yöntem Chan-Vese metodudur [33]. Basitleştirilmiş Mumford–Shah optimizasyon yöntemi ile iç ve dış kuvvetlerin optimizasyonunu sağlayarak aktif

konturun görüntü üzerinde manipülasyonunu sağlarlar [35]. Chan-Vese modelinin homojen olan görüntülerde çalışabilmektedir varsayımına dayalıdır ve bu da bu yöntemin en büyük sınırlayıcısıdır. Medikal görüntülerin en büyük ortak özelliği homojen olmayan görüntüler olmasıdır [36]. Chan-Vese, Tsai ve ark. Piecewise smooth (PS) modeli geliştirerek bu sınırlamayı aşmak istemişlerdir [37]. Fakat bu yaklaşım Chan-Vese modelinin kısıtlarını kısmen karşılayabilmiş ve hesaplama maliyeti oldukça yüksek olduğundan yaygın kullanım alanı bulamamıştır. Li ve ark. Local binary fitting (LBF) yöntemi ile aktif konturun homojenlik problemini çözmeye çalışmışlardır [38]. Bu bağlamda aktif konturun içinde istatistiksel bilgiler özellikle objenin ortalama yoğunluk bilgisini kullanmışlardır. Fakat homojen olmayan görüntülerde aynı obje uniform olmayan bir dağılım gösterdiğinden birden fazla ortalama yoğunluk bilgisi kullanılması gerektirmiştir. Ni ve ark. LBF yönteminin kısıtlarını aşmak için yoğunlukların histogram bilgisini kullanarak aktif konturun hareketini yönetmek istemişlerdir. Fakat onların çalışmaları da doğa görüntülerinde olumlu sonuç vermemiştir [39] [40].

Ge ve ark. Structure tensor ve duality teorisine dayalı eş yönsüz yayılım ile yeni bir regularization terimi belirlemişlerdir [41]. Homojenlik problemini kısmen çözümleseler de başlangıç konturunun yerini belirleme kısıtını aşamamışlardır. Başlangıç konturu ile ilgili yapılan çalışmalarda mevcuttur. Wang ve ark. yerel ve global yoğunluk bilgilerini bir araya getirmeyi planlamışlardır [42]. Fakat başlangıç konturu objenin kenarlarına yakın bölgede konumlandırıldığında bölütlenmesi yapılacak nesnenin kenar bölgelerinde fazla aşınma olduğu saptanmıştır.

Aktif kontur yönteminin iki limitasyonu olan başlangıç konturu [43] [44] ve homojen görüntülerde uygulanabilir varsayımı hala tam olarak çözülememiştir [45] [46] [47]. Çalışmamızda bu iki problemi mevcut yöntemlerin birlikte uygulanması şeklinde ele aldık. Başlangıç konturunu belirlemek için humerus başının anatomik bilgisinden yararlandık. Dairesel Hough transformu kullanarak dairemsi yapıdaki humerus başını görüntüden otomatik olarak saptadık ve başlangıç konturunu doğrudan nesnenin üzerinde konumlandırdık. Homojenlik problemini ise SRAD ve homomorfik filtre ile sağlamaya çalıştık.

Literatürde kemik bölgesinin bölütlenmesi ile ilgili kısıtlı sayıda çalışma bulunmaktadır. Kemik bölgelerinin ve yumuşak dokuların segmentasyon çalışmaları BT (bilgisayarlı

tomografi) ve T1 ağırlıklı MR görüntüleri kullanılarak yapılan çalışmalar mevcuttur. T1 ağırlıklı MR ve BT görüntüleri kemik bölgelerinin gösteriminde PD ağırlıklı görüntülere oranla oldukça başarılıdır. Literatürde bu görüntüleme teknikleri kullanılarak yapılan çalışmaların sonuçları da oldukça yüksektir.


Perez ve ark. tarafından yapılan çalışmada kemik bölgeleri ve yumuşak dokuların segmentasyonu T1 ağırlıklı koronel MR görüntüleri kullanılarak gerçekleştirilmiştir. Density mixture [48] ve Chan-Vese metotları kullanılarak kemik ve yumuşak doku bölgelerinin segmentasyonu sağlanılmıştır. Yumuşak dokuların segmentasyon başarısı düşük olmasına rağmen kemik bölgelerinin segmentasyon başarısı oldukça yüksektir [2]. Chan-Vese modeli gibi bölgesel tabanlı (region based) yöntem ile gradyan tabanlı eğiticili öğrenme yöntemleri kullanılarak MR T1 ağırlıklı kesitlerden kemik bölgesinin segmentasyonu Nguyen ve ark. ile birlikte yapılmıştır. Segmentasyon başarısı ortalama % 96.32 olarak hesaplanılmıştır [49]. Kemik yapıda olan Femur bölgesinin BT görüntülerinden graph cuts, Chan-Vese ve önerdikleri ACWE yöntemleri ile segmentasyonu Morar ve ark. tarafından yapılmıştır [50]. Chaoui ve ark. kemik yapıdaki humerus ve scapula bölgelerinin birleşme alanlarının BT görüntülerinden segmentasyonunu sağlamışlardır [51].

Çalışmamızda, PD ağırlıklı aksiyal omuz MR görüntüleri kullanılmıştır. Literatürde PD görüntüleri üzerinde omuz görüntülerinin bölütlenmesi ile ilgili çalışmaya rastlanılmamıştır. ACWE, SPF, GMM, Fuzzy C-means ve K-means yöntemleri kullanılarak humerus başının segmentasyonu gerçekleştirilmiş ve başarıları karşılaştırılmıştır. Çalışmanın ikinci bölümünde kullanılan materyal ve metotlar, görüntü ön işleme, ACWE yöntemi hakkında bilgi verilmiştir. Üçüncü bölümde çalışmanın uygulama sonuçlarına yer verilmiştir.

3.2 Görüntü Ön İşleme Adımları

Medikal görüntülerde homojenliğin sağlanması ve gürültünün giderilmesi bölütleme başarısını oldukça etkilemektedir. PD görüntüleri, T1 ve BT görüntülerine oranla daha gürültülü ve dokular arası geçişler daha yumuşaktır. Ayrıca PD görüntüleri patolojileri de gösterdiğinden görüntü ön işleme tabi tutulmadan bölütlenmesi zordur.

(Şekil 3.3)’de, birinci satırda T1 ağırlıklı ikinci satırda ise PD ağırlıklı MR görüntüleri ve bu görüntülerin bölütlenme sonuçları verilmektedir. Her iki görüntüye de homojenliği sağlamak amacıyla herhangi bir ön işlem yapılmamıştır. İkinci sütunda (Şekil 3.3 c) ve (Şekil 3.3 d) manuel olarak humerus başlarının bölütlenmesi gösterilmektedir. Üçüncü ve dördüncü sütunda ACWE ve SPF metotları ile bölütlenme sonuçlarına yer verilmiştir. Son sütunda ise ACWE metodunun iki seviye (level set) fonksiyonu uygulanarak elde edilen bölütlenme sonucu yer almaktadır. (Şekil 3.3)’de görüldüğü gibi T1 ağırlıklı görüntülere hiçbir ön işlem uygulanmamasına rağmen humerus başı başarılı bir şekilde bölütlenirken PD ağırlıklı görüntülerde humerus başı uygulanan yöntemlerden hiçbiri ile düzgün bölütlenememiştir.



Şekil 3.3 Birinci satırda T1 ikinci satırda PD ağırlıklı görüntüler yer almaktadır a) T1 ve b)PD ağırlıklı MR görüntüleri c),d) manuel olarak humerus başlarının bölütlenmesi gösterilmektedir. Üçüncü ve dördüncü sütunda ACWE (e,f) ve SPF (g,h) metotları ile bölütlenme sonuçları yer almaktadır. Son sütunda ise ACWE (i,j) metodunun iki seviye (level set) fonksiyonu uygulanarak elde edilen bölütlenme sonucu yer almaktadır.

PD ağırlıklı görüntülerde bölütlenme işlemine geçilmeden önce etkin bir ön işlem gerçekleştirilmelidir. Bu bağlamda SRAD yöntemi uygulanarak gürültü giderimi ve homomorfik filtre ile görüntülerdeki homojenlik sağlanmaya çalışılmıştır.

3.2.1 Benek Azaltan Eş yönsüz Yayılım (Speckle Reducing Anisotropic Diffusion) SRAD Yöntemi

MR görüntüleri yüksek çözünürlüklü ve sinyalin gürültüye oranı yüksek olan görüntüler ya da yüksek çözünürlük ve sinyalin gürültüye oranı düşük olan görüntüler olarak iki grupta ele alınabilir. Hem çözünürlüğün yüksek hem de gürültünün az olmasını sağlamak

için çekim süresinin uzun tutulması gerekmektedir. Bu da hasta konforu açısından çok mümkün değildir. Çekim süresi daha kısa olan PD görüntüleri, T1 görüntülerine göre daha gürültülü verilerdir.

Gürültü azaltmak için yaygın olarak kullanılan Gaussian ya da medyan filtre PD görüntülerindeki gürültüleri azaltmak için yeterli değildir. Bu filtreler gürültünün görüntüde toplam şeklinde (additive noise) ifade edilen görüntüler için uygundur. Benek azaltan eş yönsüz yayılım yöntemi olarak literatürde yaygın olarak kullanılan SRAD metodu çalışmamızda PD ağırlıklı MR görüntülerinde çarpım şeklinde ifade edilen gürültüyü azaltmak amacıyla kullanılmıştır. Anisotropic diffusion (AD) yöntemi de bu amaçla kullanılan yöntemler arasındadır. Fakat AD yöntemi görüntüde yumuşatma işlemini kenar bilgilerinin paraleli doğrultusunda gerçekleştirdiğinden görüntüdeki objelerin kenar komşuluklarındaki piksellerde gürültü kalmasına neden olur [27][28]. SRAD yöntemi yönlü olma özelliği ile bu sorunu çözebilmiştir. SRAD metodu ile görüntüde yumuşatma işlemi kenar bilgilerinin normal doğrultusunda gerçekleştirilir. Bizim çalışmada kullandığımız görüntüler gibi kenar bilgileri zayıf olan görüntülerde SRAD metodu kenar bilgilerini koruyarak yumuşatma işlemini gerçekleştirir ve gürültünün büyük oranda giderilmesini sağlar [30].

SRAD metodu Lee ve eş yönsüz yayılım (anisotropic diffusion) filtrelerinin önemli avantajlarının birleşimidir. Eş yönsüz yayılım yönteminin kısmi türev fonksiyonu (3.1) ile sürekli uzayda tanımlanmıştır.

Verilen iki boyutlu $I_0(x,y)$ işareti için t zaman boyutunda güncelleme (3.1) ile sağlanmaktadır ve c fonksiyonu yumuşatma fonksiyonu (diffusion coefficient) olarak tanımlanır. $c(0)=1$, $c(\infty)=0$ olacak şekilde azalan bir fonksiyon belirlenir; div ise diverjans (divergence) operatörüdür.

$$\frac{\partial I}{\partial t} = \text{div}[c(|\nabla I|)\nabla I] \quad (3.1)$$

$$I(t = 0) = I_0 \quad (3.2)$$

Ω alanında tanımlanan $I_0(x, y)$ görüntüsü, SRAD metodunun kısmi türev fonksiyonuna göre elde edilen çıkış görüntüsü $I(x, y; t)$ ise t yayılım anında x ve y pozisyonunda elde edilen görüntünün piksel değerleridir, Ω parametresinin sınırlarını $\partial\Omega$ parametresi belirler, $\vec{n}$ ise $\partial\Omega$ parametresine normaldir.

$$\frac{\partial I(x, y; t)}{\partial t} = \text{div}[c(q)\nabla I(x, y; t)] \quad (3.3)$$

$$I(x, y; 0) = I_0(x, y), \left(\frac{\partial I(x, y; t)}{\partial \vec{n}} \right) |_{\partial\Omega} = 0 \quad (3.4)$$

SRAD yöntemi eş yönsüz yayılım yönteminin kısmi türev fonksiyonunun formatını kullanır. İkisi arasındaki temel farklılık yumuşatma fonksiyonundan kaynaklanmaktadır. (3.1) ve (3.3). $I(x, y; t)$, t yayılım anında x ve y noktalarında elde edilmesi beklenen görüntüdür. ∇ gradyen operatörü; div diverjans operatörü; $c(q)$ ise yayılım katsayısıdır.

$$c(q) = \left[\frac{1}{1 + \left[q^2(x, y; t) - q_0^2(t) \right] / [q_0^2(t)(1 + q_0^2(t))]} \right] \quad (3.5)$$

$q(x, y; t)$ ise yerel varyasyon katsayısı (ICOV) olarak tanımlanır. Ayrıca kenar belirleme fonksiyonu olarak da kullanılabilir.

$$q(x, y; t) = \sqrt{\frac{\left(\frac{1}{2} \right) \left(\frac{|\nabla I|}{I} \right)^2 - \left(\frac{1}{16} \right) \left(\frac{\nabla^2 I}{I} \right)^2}{\left[1 + \left(\frac{1}{4} \right) \left(\frac{\nabla^2 I}{I} \right)^2 \right]}} \quad (3.6)$$

$q_0(t)$ benek ölçeklendirme fonksiyonudur ve homojen bir bölgeden hesaplanır. $\text{var}[z(t)]$ ve $\overline{z(t)}$ parametreleri t zamanında homojen bölgeden hesaplanan varyans ve ortalama değerleri gösterir.

$$q_0(t) = \frac{\sqrt{\text{var}[z(t)]}}{\overline{z(t)}} \quad (3.7)$$

SRAD yöntemi, ICOV ve benek ölçeklendirme fonksiyonunu Lee filtresinden türetmiştir. Bu çalışmada benek ölçeklendirme fonksiyonunu homojen olan bir alandan hesaplamak yerine [26] dokuların yoğun olduğu humerus başı bölgesinden hesaplayarak genellikle benek gürültü azalımı için ultrason ve uydu görüntülerinde [28],[30] kullanılan SRAD yöntemini PD ağırlıklı MR görüntülerinde kullanılabilir hale getirdik.

3.2.2 Homomorfik Filtre

MR görüntüleme teknolojisinde kaydedilen ilerlemelere rağmen günümüzde alınan MR görüntülerinde homojenlik problemi hem gözle hem de manuel olarak bölütleme ve sınıflandırma başarısını etkilemektedir. MR görüntülerinde homojenliği düzenlemek için kullanılan birçok yöntem vardır. Homomorfik filtre bu yöntemler arasında yaygın olarak kullanılan bir yöntemdir. Perez ve ark. T1 ağırlıklı MR görüntülerinde kemik ve yumuşak doku bölütlenmesinde ön işlem olarak homomorfik filtreyi kullanmıştır. İnsan gözüyle kolay algılanamayan bu homojenlik bilgileri görüntüden homomorfik filtre ile başarıyla kaldırılmıştır. Homomorfik filtre görüntüdeki çarpım şeklinde ifade edilen gürültüyü düzenlemek için kullanılabilir. Yaygın olarak görüntüdeki düzensiz dağılım gösteren ışığı düzenlemek için kullanılmıştır. Homomorfik filtre, görüntüyü yüksek ve alçak frekanslı bileşenlere ayırır ve çarpım durumundaki gürültünün alçak frekanslı bileşenlerde bulunduğunu varsayarak düzenleme işlemini gerçekleştirir [52].

Homomorfik filtreye göre, görüntüdeki her bir piksel değeri $f(x,y)$ yüksek frekanslı bileşenlerle (high-frequency reflectance component) alçak frekanslı (low-frequency illumination component) bileşenlerin çarpımı şeklinde ifade edilir (3.8).

$$f(x,y) = i(x,y) r(x,y) \quad (3.8)$$

Görüntü iyileştirmede (enhancement), homomorfik sistemler birbirinden bağımsız çarpım durumundaki yüksek ve alçak frekanslı bileşenleri birbirinden ayırmak için logaritmik transform kullanır (3.9).

$$g(x,y) = \ln(f(x,y)) = \ln[i(x,y) r(x,y)] = \ln(i(x,y)) + \ln(r(x,y)) \quad (3.9)$$

Fourier dönüşüm (3.9) eşitliği uygulanarak, $G(u,v)$, $I(u,v)$ ve $R(u,v)$ parametreleri $g(x,y)$, $\ln(i(x,y))$ ve $\ln(r(x,y))$ için sırasıyla elde edilir.

$$G(u,v) = I(u,v) + R(u,v) \quad (3.10)$$


Frekans alanında (domain) yüksek geçirgen filtre $H(u,v)$ uygulanarak yüksek frekanslı bileşenler korunurken alçak frekanstaki bileşenlerde düzensiz olarak dağılan ışık etkisi ortadan kaldırılır.

$$\tilde{G}(u,v) = I(u,v)H(u,v) + R(u,v)H(u,v) \quad (3.11)$$


Ters Fourier dönüşüm (3.11) eşitliği uygulanarak $\tilde{g}(u,v)$ fonksiyonu elde edilmiştir

$$\tilde{g}(u,v) = \tilde{i}(u,v) + \tilde{r}(u,v) \quad (3.12)$$

Görüntüdeki logaritmik dönüşümlerin etkisini kaldırarak düzenlenmiş görüntüyü elde etmek için $\exp(\tilde{g}(u,v))$ uygulanmıştır. Homomorfik sistemlerde genelde yüksek geçirgenli Butterworth filtre kullanılmıştır. Çalışmamızda yüksek geçirgenli filtre olarak Gaussian filtresi kullanılarak homojenlik sağlanmıştır (Şekil 3.5).



Şekil 3.4 a) MR görüntüsüne, homomorfik filtre b) SRAD c) önce SRAD daha sonra homomorfik filtre d) önce homomorfik filtre sonra SRAD uygulandığında ACWE metodu ile ikili (binary) olarak bölütleme başarısı.



Şekil 3.5 a) Orjinal PD ağırlıklı MR görüntüsü, b) SRAD metodu uygulandıktan sonra elde edilen görüntü c) Homomorfik filtre uygulandıktan sonra elde edilen görüntü d) SRAD ve arkasından homomorfik filtre uygulandığında elde edilen sonuç görüntüsü

Görüntüye sadece homomorfik filtre yada SRAD uygulandığında ACWE metodu ile bölütlenme başarısının düşük olduğu Sorenson-Dice metriğe göre saptanmıştır (Şekil 3.4). Önce SRAD daha sonra homomorfik filtrenin uygulanması ise homomorfik filtre uygulanıp ardından SRAD ile gürültü temizlemekten daha iyi sonuçlar vermiştir.


3.2.3 İlgili Alanın Tespit Edilmesi (ROI: Region of Interest)

Örüntü tanıma ve bölütleme çalışmalarında Hough transform görüntüdeki eğrileri bulmak için kullanılmıştır. Dairesel Hough transformu (DHT) ise daire denklemindeki parametrelerin seçimine göre görüntüdeki çemberleri tespit etmeye yardımcı olur [53].


Humerus başı yuvarlağımsı bir yapıdadır. DHT kullanılarak MR görüntülerinden humerus başının yeri otomatik olarak tespit edilmeye çalışılmıştır. Bu uygulamada kenar belirlemede Sobel filtresi kullanılmıştır. İki boyutlu konvolüsyon ile Sobel filtresi görüntüye uygulanmış ve kenarlar belirlenmiştir. Adaptif eşikleme yöntemi kullanılarak görüntü siyah beyaz hale getirilmiştir. Olası çemberlerin yarıçap aralığı ve şekil belirlemede kullanılan akümülatör eşik değeri parametre olarak alınmıştır. Uygulamalarda yalnızca istenen yarıçap aralığındaki çemberlerin aranması ile hem istenmeyen şekillerin bulunması önlenmiş hem de başarımda iyileştirme sağlanmıştır.

DHT yöntemi ile bulunan çemberler humerus başını tam olarak kapsamamaktadır. Bazı görüntülerde elde edilen çemberlerin dışarısında humerus başının bir kısmı yer almaktadır. Bu nedenle bütün görüntülerde DHT ile bulunan dairelerin yarıçapları aynı oranda artırılmıştır. Böylece 210 MR görüntüsündeki humerus başlarının çemberlerin

içerisinde yer alması sağlanmıştır. DHT ile bulunan ilgili alan ve genişletilen alan bilgisi (Şekil 3.6)'da verilmiştir.



Şekil 3.6 a) Orjinal PD ağırlıklı MR görüntüsü b) SRAD ve homomorfik filtre uygulamasından sonra elde edilen görüntü c) DHT ile elde edilen humerus başı görüntüsü d) Başlangıç çemberinin büyütülmesi ile elde edilen ilgili alan.



Şekil 3.7 a) Orijinal PD ağırlıklı sol ve b) sağ omuz MR görüntüsü ve DHT yöntemi ile elde edilen çalışma alanları (ROI)

İlgili alanın belirlenmesi, çalışmamızın en kritik noktasını oluşturmaktadır. Homojensizlik, humerus başına bağlı olan yumuşak dokular ve gürültüden dolayı PD ağırlıklı görüntülerin bölütlenmesi özellikle lezyonlu görüntülerde oldukça zordu. İlgili alan bilgisi kullanılarak çalışma alanı daraltıldı ve yumuşak dokuların büyük bir kısmı

bertaraf edildi (Şekil 3.7). Ayrıca ACWE metodunun en büyük problemi olan başlangıç konturunun yerinin belirlenmesi yine DHT metodu ile gerçekleştirildi.

3.2 Segmentasyon Metotları

3.2.1 Active Contours Without Edges (ACWE)

ACWE metodu Chan-Vese modelde görüntü üzerinde başlangıç konturu belirlenir. Bu kontura uygulanan iç ve dış kuvvetlerle konturun görüntüde segmentasyonu yapılması istenen objelerin sınırlarını çevrelemesi sağlanır. İç kuvvet uygulanan dış kuvvetten büyükse kontur genişler. Dış kuvvet iç kuvvetten büyük olduğunda ise kontur daralır. Bu işlemler iki kuvvetin toplamı sıfıra yakınsayınca kadar iteratif olarak gerçekleştirilir [33]. Bu noktada Chan-Vese modeli kuvvetlerin toplamını minimize eden bir optimizasyon problemine dönüşür. Dolayısıyla bu yöntem Mumford-Shah optimizasyon probleminin özel bir kullanımı olarak da tanımlanır [35] [36].

$\omega \subset \Omega$ ile tanımlanan $C = \partial\omega$ konturun (C), iç kısmı (ön plan) ω parametresi ile tanımlanır. $\Omega \setminus \omega$ parametresi ise konturun dış kısmını yani arka planı belirler. Chan-Vese model (3.14) eşitliği ile tanımlanan level set eşitsizliklerini kullanarak aşağıdaki enerji fonksiyonlarını minimize etmeyi sağlar.

$$F(c_1, c_2, C) = \lambda_1 \int_{\Omega} |u_0(x, y) - c_1|^2 H(\phi(x, y)) dx dy + \lambda_2 \int_{\Omega} |u_0(x, y) - c_2|^2 (1 - H(\phi(x, y))) dx dy \quad (3.13)$$

Chan-Vese modelinin level set formülü (3.14) ile ifade edilir.

$$\begin{aligned} C = \partial\omega &= \{(x, y) \in \Omega : \phi(x, y) = 0\} \\ \omega &= \{(x, y) \in \Omega : \phi(x, y) > 0\} \\ \Omega \setminus \bar{\omega} &= \{(x, y) \in \Omega : \phi(x, y) < 0\} \end{aligned} \quad (3.14)$$

Alınan u_0 görüntüsünde konturun iç kısmında kalan piksellerin ortalama değeri c_1 ve dış kısmında kalan piksellerin ortalama değeri c_2 olarak tanımlanır. c_1 ve c_2 parametreleri (3.15) ve (3.16) eşitliklerinin minimize edilmesi ile sağlanır.

$$c_1(\phi) = \frac{\int_{\Omega} u_0 H(\phi(x, y)) dx dy}{\int_{\Omega} H(\phi(x, y)) dx dy} \quad (3.15)$$

$$c_2(\phi) = \frac{\int_{\Omega} u_0 (1 - H(\phi(x, y))) dx dy}{\int_{\Omega} (1 - H(\phi(x, y))) dx dy} \quad (3.16)$$

Heaviside $H(\phi)$ ve Dirac $\delta(\phi)$ fonksiyonları kullanılarak Chan-Vese modelinde tanımlanan enerji fonksiyonu aşağıdaki gibi (3.17) ile ifade edilebilir [33].

$$\frac{\partial \varphi}{\partial t} = \delta(\phi) \left[\mu \nabla \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - v - \lambda_1 (1 - c_1)^2 + \lambda_2 (1 - c_2)^2 \right] \quad (3.17)$$

$v \geq 0, \lambda_1 \geq 0, \lambda_2 \geq 0, \mu \geq 0$ parametreleri sabittir; v parametresi ile yayılım hızı kontrol edilir; λ_1 ve λ_2 parametreleri ile kontura uygulanan iç ve dış kuvvetler ayarlanır. Eğer μ değeri yüksek alınırsa görüntüden büyük objelerin segmentasyonu sağlanır. Bu değer küçük alındığında ise büyük objelerle birlikte küçük objelerin de segmentasyonu yapılır [31].

ACWE modelin en büyük avantajı görüntünün gradyan bilgisine dayalı olmamasıdır. Başlangıç konturunun içinde ve dışındaki alanı kullanarak istatistiksel bilgi çıkarımı gerçekleştirir. Böylece bizim verilerimiz gibi kenar bilgileri olmayan ya da zayıf olan görüntülerde de başarılı sonuçlar üretebilmektedir.

Bu yöntemin en büyük kısıtı ise çalıştığı görüntülerin homojen olduğunu varsayması ve başlangıç konturunun yerine göre bölütleme başarısının değişmesidir. Başlangıç konturu ve görüntünün homojenliği problemleri ile ilgili çalışmalar yapılsa da henüz tam olarak bu problemlere çözüm üretilmemiştir. Önerilen yöntemler bizim veri setimizde kullanılmaya uygun değildir. Lezyonların yeri ve büyüklüğü hastaya göre değişmektedir. Ayrıca Hill-Sachs lezyonu olan görüntülerde anatomik yapı da değişmektedir. Görüntüler arasında hatta görüntü içerisinde bu denli büyük değişim varken ACWE metodu uygulama sırasında homojensizlik problemine çözüm üretmek zordur. Dolayısıyla görüntü üzerinde ön işlem ile bu problemler çözüldükten sonra ACWE metodu uygulanabilmiştir.

Çalışmamızda homojenlik ve gürültü problemi SRAD ve homomorfik filtre ile çözümlendikten sonra ACWE metodu uygulandığında bölütleme başarısı istenilen seviyede olmamıştır. ACWE metodunda başlangıç konturu DHT metodu ile humerus başı üzerinde tanımlandığında sistemin başarısı oldukça artmıştır. Çalışmayı aynı proseslerle sadece DHT ile belirlenen alanda gerçekleştirdiğimizde hem çalışma süresi kısalmış hem de bölütleme başarısı oldukça artmıştır (Şekil 3.8).



Şekil 3.8 a) Orjinal PD ağırlıklı omuz MR görüntüsü, (b) Herhengi bir ön işlem adımı uygulamadan ACWE metodu ile yapılan bölütleme (c) SRAD ve homomorfik filtre uygulanarak gerçekleştirilen ön işlem adımından sonra ACWE metodu ile elde edilen bölütleme sonucu, (d) Belirlenen alana içerisinde (c) maddesindeki aynı işlemleri gerçekleştirilmesi sonucu elde edilen sonuç görüntüsü.

3.2.2 Signed Pressure Force Model (SPF)

Omuz MR görüntülerinin bölütlemesini ACWE metodu ile gerçekleştirdikten sonra literatürde medikal görüntülerin bölütlenmesinde başarılı bulunan SPF metodu ile de bölütleme gerçekleştirerek ACWE metodunun performansını değerlendirmeye çalıştık.

SPF model, kenar tabanlı Geodesic Active Contour (GAC) model ile bölgesel tabanlı Chan-Vese modelinin birleşmesi ile elde edilmiştir [45]. GAC modelden farklı olarak SPF model konturun iç ve dış bölgesinde kalan alanlardan istatistiksel bilgiler çıkarır ve bu bilgileri gradyan bilgisi olmadığı yerde başlangıç konturun hareketini kontrol etmek amacıyla kullanır. ACWE metodu global bölütleme özelliğine sahipken SPF model başlangıç konturunun bölütleme yapılacak nesneyle kesişim ya da komşuluk halinde tanımlandığında hem global hem de yerel bölütleme gerçekleştirebilmektedir. Zhang ve ark. SPF modelinin homojen olmayan zayıf kenar bilgileri içeren görüntülerde iyi sonuç verebildiğini belirtmişlerdir [45]. ACWE metodu ise görüntünün homojen olduğunu

kabul ederek çalışabilen bir metottur [33] [36]. SPF modelinin bu avantajı bizim veri setimizde duyduğumuz ihtiyacı karşılamaktadır. Omuz MR görüntüleri hem homojen olmayan görüntülerdir hem de kenar bilgileri zayıf hatta patoloji bulunan görüntülerde tamamen belli olmayan nesne sınırları mevcuttur.

SPF fonksiyonu (3.18) eşitliği ile tanımlanmıştır [45].

$$spf(I(x)) = \frac{I(x) - \frac{c_1+c_2}{2}}{\max(|I(x) - \frac{c_1+c_2}{2}|)} \quad (3.18)$$

Belirlenen başlangıç konturunun iç kısmında kalan piksellerin ortalama değeri c_1 , dış kısmında kalan piksellerin ortalama değeri ise c_2 ile tanımlanmıştır.

$$c_1(\phi) = \frac{\int_{\Omega} u_0 H(\phi(x, y)) dx dy}{\int_{\Omega} H(\phi(x, y)) dx dy} \quad (3.19)$$

$$c_2(\phi) = \frac{\int_{\Omega} u_0 (1 - H(\phi(x, y))) dx dy}{\int_{\Omega} (1 - H(\phi(x, y))) dx dy} \quad (3.20)$$

SPF modelinin level set fonksiyonu (3.14) eşitliği ile tanımlanmıştır. α parametresi kontura uygulanan balon kuvveti tanımlamaktadır. Kenar tabanlı aktif kontur modellerde balon kuvvetini belirlemek oldukça zordur. Bu kuvvet büyük ya da küçük belirlendiğinde bölütleme başarısını negatif etkilemektedir. Fakat SPF model kontur konumuna göre istatistiksel bilgi çıkarımı yaptığı için kenar tabanlı aktif kontur modellerin bu problemini aşabilmiştir.

$$\frac{\partial \phi}{\partial t} = spf(I(x)) \cdot \left(\frac{\nabla \phi}{|\nabla \phi|} + \alpha \right) |\nabla \phi| + \nabla spf(I(x)) \cdot \nabla \phi \quad (3.21)$$

3.2.3 Gaussian Mixture Model (GMM)

GMM verinin birden fazla Gauss dağılımı ile ifade edilerek kümelendirilmesine dayanır. Farklı dokular için farklı Gauss dağılımı kullanılır. Hatta homojen olmayan aynı doku

birden fazla Gauss dağılımı kullanılarak ifade edilir. GMM model bölütleme çalışmalarında çok farklı alanlarda yaygın olarak kullanılmıştır.

Bölgesel aktif kontur modelin bölütleme başarısını karşılaştırmak amacıyla kümeleme metotlarından en başarılı ve yaygın olarak medikal görüntü bölütlemelerinde kullanılan GMM modeli seçtik. GMM kümeleme modeli ile PD ağırlıklı omuz MR görüntülerin sadece ilgili alanı (ROI) kullanarak ikili bir şekilde sınıflandırmayı sağlamak için expectation maximization (EM) algoritmasını kullandık (Şekil 3.9).

Vektör olarak ifade edilen görüntümüz x_j , $j= 1,2,..n$ ve $i \in \{1,2,..k\}$, alınan bölge sayısı ise k parametresi ile tanımlanmıştır. Gaussian karışım modelinin dağılımı aşağıdaki (3.22) ve (3.23) eşitlikleri ile ifade edilmiştir [54].

$$f(x) = \sum_{i=1}^k p_i N(x|\mu_i, \sigma_i^2) \quad (3.22)$$

p_i parametresi ağırlıkları tanımlamaktadır ve $p_i > 0$ için $\sum_{i=1}^k p_i = 1$ koşulunu sağlamalıdır.

$$N(\mu_i, \sigma_i^2) = \frac{1}{\sigma_i \sqrt{2\pi}} \exp\left(-\frac{(x - \mu_i)^2}{2\sigma_i^2}\right) \quad (3.23)$$

EM-MAP algoritmasının adımları

1. Diğer kümeleme algoritmalarında olduğu gibi Gaussian karışım modelinde de başlangıç parametrelerinin $\theta^{(0)}$ belirlenmesi gerekmektedir. Başlangıç parametrelerini belirlemek için öncelikle K-means algoritmasını kullanarak DHT ile belirlenen alanın kümelenmesi kabaca sağlanmıştır. Bu kümeleme bilgisi kullanılarak başlangıç parametreleri olan ortalama değer ($\mu_k^{(0)}$), varyans ($\sigma_k^{(0)}$) ve ($p_k^{(0)}$) parametresinin başlangıç ağırlıkları belirlendi [54].

$$\theta^{(0)} = (p_1^{(0)}, \dots, \mu_1^{(0)}, \dots, \mu_k^{(0)}, \sigma_1^{(0)}, \dots, \sigma_k^{(0)}) \quad (3.24)$$

2. E- Step

$p_i^{(r)}$ parametresi ile ayırık önsel olasılık (discrete prior probability) r adımı için tanımlanmaktadır ve $p_{ij}^{(r+1)}$ ise bir sonraki adım için hesaplanan sonrasal olasılık (discrete posterior probability) değerini ifade etmektedir. Bayes kuralına göre:

$$p_{ij}^{(r+1)} = p^{(r+1)}(i|x_j) = \frac{p_i^{(r)} N(x_j|\mu_i^{(r)}, \sigma_i^{2(r)})}{f(x_j)} \quad (3.25)$$

3. M-Step

$$\hat{p}_i^{(r+1)} = \frac{1}{n} \sum_{j=1}^n p_{ij}^{(r)} \quad (3.26)$$

$$\hat{\mu}_i^{(r+1)} = \frac{\sum_{j=1}^n p_{ij}^{(r+1)} x_j}{n\hat{p}_i^{(r+1)}} \quad (3.27)$$

$$\hat{\sigma}_i^{2(r+1)} = \frac{\sum_{j=1}^n p_{ij}^{(r+1)} (x_j - \hat{\mu}_i^{(r+1)})^2}{n\hat{p}_i^{(r+1)}} \quad (3.28)$$

E-step ve M-step belirlenen hata miktarına yakınsayınca kadar tekrar edilir. GMM metodu ile sadece normal omuz MR görüntülerinin segmentasyonu sağlanabilmiştir. Patoloji içeren görüntülerin bölütlenmesi homojensizliğin yüksek olmasından dolayı sağlanamamıştır. (Şekil 3.9).

$$\sum_i e_i^2 < \varepsilon \quad (3.22)$$

3.2.4 Bulanık C- Ortalamaları (Fuzzy C- Means) (FCM) Method

Bölgesel tabanlı ACWE metodunun bölütleme başarısını diğer bir kümeleme yöntemi olan FCM ile de karşılaştırmasını sağladık. FCM metodu bölütlemeye görüntü üzerinde homojenliği sağlamada ve sınıflandırmada yaygın olarak birçok medikal uygulamada kullanılmıştır.

FCM algoritmasında her bir örnek için kümeler üyeliği değerleri 0 ile 1 arasında bir ilk değer atanır. Her bir pikselin belirlenen küme merkezlerine olan mesafelerinin toplamını

minimize edecek şekilde üyelik değerleri güncellenerek kümeleme işlemi bütün pikseller için gerçekleştirilir. Bir örneğin toplam üyelik değeri 1 olmak zorundadır.

FCM algoritması için maliyet fonksiyonu (3.23) eşitliği ile tanımlanır [55]. Piksel yoğunluk değeri hangi kümeleme merkezine daha yakınsa ona yüksek üyelik değeri, uzak olanlara ise düşük üyelik değeri atanarak maliyet fonksiyonu minimize edilmeye çalışılır.

$X=(x_1, x_2,...x_N)$ parametresi N pikseli bir görüntüyü tanımlamaktadır ve bu görüntü c adet kümeye maliyet fonksiyonu ile ayrılacaktır.

$$J = \sum_{j=1}^N \sum_{i=1}^c u_{ij}^m ||x_j - v_i||^2 \quad (3.23)$$

x_j pikselinin i. sınıfa olan üyeliği u_{ij} parametresi ile tanımlanmıştır. Küme merkezleri ise v_i değişkeni ile belirtilmiştir. Bulanık katsayısı (Fuzzy coefficient) m parametresi ile belirlenmiş ve bu çalışma için m=2 alınmıştır.

Üyelik değeri aşağıda tanımlanan fonksiyonla güncellenmiştir.


$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{||x_j - v_i||}{||x_j - v_k||} \right)^{2/(m-1)}} \quad (3.24)$$

Her bir sınıf merkezi ise (3.25) eşitliği ile güncellenmiştir:

$$v_i = \frac{\sum_{j=1}^N u_{ij}^m x_j}{\sum_{j=1}^N u_{ij}^m} \quad (3.25)$$

FCM model ile sadece normal olan görüntülerin iki sınıf olarak bölütlenmesi sağlanılmıştır (Şekil 3.9). FCM grup içindeki benzerliklerin gruplar arasındaki benzerliklerden daha büyük olmasını amaçlamaktadır. Farklı yoğunluklara sahip kümeler içeren omuz MR görüntüleri için kümeleme işlemi zordur. K-means ve FCM kümeleme yöntemlerinin performansı küme merkezlerinin başlangıç değerlerine bağlıdır. Hem FCM


hem de k-means yöntemi patoloji içeren MR görüntülerinin bölütlenmesini sağlayamamıştır.



Şekil 3.9 a) DHT ile saptanılan ilgili alanın omuz MR görüntüsü. (b) FCM method ile kümeleme sonucu. (c) GMM method ile elde edilen bölütleme sonucu.

3.3 Postprocessing

ACWE yöntemi ile yapılan humerus başı segmentasyonunda, humerus başı ile birlikte humerus başını ifade eden piksellerin değerlerine çok yakın değerlerde olan yumuşak dokularda segmentasyon sonucunda yer almaktadır. Özellikle (Şekil 3.10) ile gösterilen biceps tendonu ve subscapularis tendonu humerus başı olarak etiketlenmiştir. Ayrıca başlangıçta dairesel hough transformu ile belirlenen çemberin yarıçapının genişletilmesi ile scapula bölgesinin uç kısımları da humerus bölgesi olarak kümelenmiştir. Hem skapulanın hem de tendonların humerus başı olarak segment edilen bölgeden çıkarılması için bir dizi morfolojik işlemler ve bağlantılı bileşenler analizi (connected component labeling) yapıldı. Histogram bilgisi kullanılarak önce omuzun sağ ya da sol omuz olduğu belirlendi. Skapula bölgesi omuz ile aynı yönde ve DHT ile belirlenen çemberin kenar kısmında humerus başına genellikle yapışık şekilde konumlanmaktadır. Bu anatomik bilgi eşliğinde sadece scapula alanında aşındırma işlemi (erosion) gerçekleştirildi. Görüntünün tamamında yapılan aşındırma işlemi sistemin başarısını düşürmektedir. Bizim amacımız humerus başına yapışık şekilde bulunan skapulanın görüntüden dairesel yapı elementi kullanarak aşındırılmasını sağlamaktır. Bu işlemten sonra bağlantılı bileşen analizi uygulanabilir hale gelmiştir. Görüntünün tersi alınarak temel bileşen analizi uygulandığında birbirinden bağımsız alanlar etiketlenebildi. En büyük ikinci alan ise bizim humerus başı bölgesini etiketlemektedir. Bu alan belirlendikten sonra diğer alanlar (tendonlar, scapula vs.) elimine edildi (Şekil 3.11).




a

b

Şekil 3.10 a) Aksiyal PD ağırlıklı MR görüntüsü, b) biceps ve subscapularis tendonları kırmızı alan ile gösterilmiştir. Humerus başı ve skapula bölgeleri mavi ve yeşil alan ile ifade edilmiştir.

Veri seti ağrı ile hastaneye başvuran ve MR görüntüsü alınması uygun olan hastalardan oluşmaktadır. Dolayısıyla normal olarak etiketlenen omuz MR görüntülerinde de kısmen ödem bulunmaktadır. Ödemli olan ve Hill-Sachs lezyonu bulunan hastaların omuz MR görüntülerinde ödemli bölge yüksek yoğunluk değerleri ile ifade edilmiştir. Segmentasyon sonucunda bu bölgelerde beyaz olarak etiketlendi. Humerus başının sınırları bulunduğundan sonra ödem için yapılan etiketlenme bilgisi doldurma (filling) operasyonu ile değiştirildi. Böylece patolojisi yüksek olan bulgularda da başarılı bölütleme gerçekleştirildi.



a

b

c


d

e

Şekil 3.11 Son işlem adımları a) DHT ile bulunan ROI, b) İlgili alanda gerçekleştirilen bölütleme sonucu, c) morfolojik işlemler ve temel bileşenler analizi sonucu elde edilen görüntü, d) Ödemden kaynaklanan beyaz piksellerin filling işlemi ile giderilmesi, e) Bölütleme sonucu.

3.4 Uygulama Sonuçları ve Değerlendirilmesi

Uygulamalar matlab aracı kullanılarak Windows XP platformunda geliştirilmiştir. Ayrıca matlab ortamında geliştirilen araç ve fare yardımıyla uzmanların humerus başını manuel olarak segmentasyonunu yapmaları sağlanılmıştır.



Şekil 3.12 Normal, ödemli ve Hill-Sachs lezyonlu omuz başlarının manuel, SPF ve ACWE metodları ile bölütlenmesi. (a) orijinal PD görüntüleri, (b) uzman tarafından yapılan manuel bölütleme, (c) ACWE metodu, (d) SPF metodu ile bölütleme sonuçlarının gösterimi.

Uygulama sonucunda elde edilen sonuçların başarısını değerlendirmek için uzmanların manuel olarak segment ettikleri görüntüler kullanıldı. ACWE yöntemi ile segment edilen her bir görüntü piksel piksel manuel olarak segment edilen görüntü ile karşılaştırıldı. Sorensen-Dice metriği kullanılarak iki kümenin birbirine benzerliği tespit edildi. Bu

metrik 0 ve 1 aralığında değerler üretir. Benzerliğin maksimum olduğu durumda 1 değeri, minimum olduğu durumda ise 0 değeri elde edilir. 33 MR görüntüsünün ACWE yöntemi ile segmentasyon başarıları ortalama olarak % 91 bulunmuştur. En düşük başarı oranı % 82.76 , en yüksek başarı oranı % 96.46 olarak belirlenmiştir.

Dairesel Hough transformu ile ROI alanının belirlenmesi hem segmentasyon başarılarını artırmıştır hem de ACWE algoritmasının iterasyon sayısını büyük oranda azaltmıştır. Humerus başının segmentasyon başarılarını düşüren en önemli etken ise tendonlar ve humerus başında oluşan ödemdir. (Şekil 3.10) ile gösterilen biceps ve subscapularis tendonu humerus başı ile birleşik yapılardır ve bu dokular arasındaki geçişler oldukça yumuşaktır. Kenar geçişleri arasında kontrastlık bilgisinin az olması yanı sıra bu dokuların şekilleri ve yerleri anatomik yapı farklılığından görüntüden görüntüye değişmektedir.

Kullandığımız veri setinde bazı görüntülerde az oranda bazı görüntülerde ise daha yüksek oranda ödem bulunmaktadır. Ödem bulunan bölgelerde yoğunluk değerleri yükselmektedir. Yoğunluk değerindeki bu değişim segmentasyon başarılarını azaltmaktadır (Çizelge 3.1).

Çizelge 3.1 ACWE ve SPF metotları ile elde edilen bölütleme başarılarının ön işlemden önce ve sonra için gösterimi.

<u>Ön işlem gerçekleştirilmeden önce bölütleme başarıları [%]</u>					<u>Ön işlem gerçekleştirildikten sonra bölütleme başarıları [%]</u>			
Yöntem ve Veri seti Eleman Sayısı	Normal Humerus Başı	Ödemli Humerus Başı	Hill-Sachs Humerus Başı	Ortalama Başarı	Normal Humerus Başı	Ödemli Humerus Başı	Hill-Sachs Humerus Başı	Ortalama Başarı
Kullanılan MR sayısı	81	100	38	219	81	100	38	219
ACWE Yöntemi	90.79	88.40	86.53	88.95	92.17	90.20	88.90	90.70
SPF Yöntemi	88.42	87.18	83.25	86.95	90.30	89.32	84.71	88.88

Çizelge 3.2 ACWE, SPF, GMM ve FCM metotları ile ön işlemden sonra elde edilen bölütleme başarılarının gösterimi.

	81 Normal MR Görüntüsü için Bölütleme Başarısı [%]			
Bölütleme Yöntemleri	ACWE Yöntemi	SPF Yöntemi	GMM Yöntemi	FCM Yöntemi
Ortalama bölütleme başarıısı	92.17	90.30	83.25	76.83
Maksimum bölütleme başarıısı	97.27	96.12	87.54	83.59
Minimum bölütleme başarıısı	85.76	82.91	64.39	59.18

ACWE, SPF, GMM ve FCM metotları ile ön işlemden sonra elde edilen bölütleme başarılarının gösterimi (Çizelge 3.2) ile verilmiştir. Bu yöntemlerin başarıısı ACWE yöntemine göre oldukça düşüktür. Hatta ödemli ve Hill-Sachs lezyonlu görüntülerde bölütlemeyi sağlayamamıştır.

BÖLÜM 4

HUMERUS BAŞLARINDAN ÇIKARILAN DOKU VE ŞEKİL ÖZELLİKLERİ

Şekil, renk ve doku parametreleri, kompleks yapıda olan medikal görüntülerde nesnenin tanımlanmasında önemli rol oynamaktadır. Aynı renk ve şekilde olan nesnelerin ayırt edilmesinde doku özelliğinden faydalanılarak farklı objeler başarı ile sınıflandırılabilir. Bölütlenmesi tamamlanan normal, ödemli ve Hill-Sachs lezyonlu humerus başlarının sınıflandırılmasını gerçekleştirmek için doku ve şekil özelliklerinden faydalanılmıştır.

Humerus başı yuvarlağımsı bir yapıya sahiptir. Fakat lezyon görülen omuz MR'larında bu yapı bozulmaktadır. Özellikle Hill-Sachs lezyonu bulunan görüntülerde humerus başında kırıktan dolayı çökme meydana gelir. Şekil farklılığı normal ve ödemli görüntüleri Hill-Sachs lezyonlu görüntülerden ayırt etmemizi sağlayabilecek bir faktördür. Ödemli MR görüntülerinde, özellikle ödemin bulunduğu alanlarda yoğunluk değerleri oldukça çok artmaktadır. Normal olarak sınıflandırdığımız görüntülerde de az da olsa ödem görülmektedir. Hill-Sachs lezyonlu MR görüntülerinde ise genellikle çökme kırığının bulunduğu alanlarda ödeme rastlanmaktadır. Doku özelliklerinden faydalanarak normal MR görüntüleri lezyonlu görüntülerden ayırt edilebilir. Doku ve şekil özellikleri birlikte kullanılarak MR görüntülerinin sınıflandırılması sağlanabilir.

4.1 Yayın Taraması

Görüntüden elde edilen doku, şekil ve renk özellikleri nesnelerin tanımlanmasında oldukça etkilidir. Bu özellikler hem sınıflandırmada hem de bölütlenme de başarılı bir şekilde kullanılabilir. Fakat karmaşık yapıdaki görüntüleri tanımlamakta bu özellikleri tek başına kullanmak istenilen başarıyı vermeyebilir. Dolayısıyla şekil, doku ya da şekil, renk ve şekil, doku ve renk parametreleri birlikte kullanılarak bilgisayar destekli tanı ve teşhis sistemlerinde başarılı sonuçlar elde edilmektedir [56] [57].

Görüntüden çıkarılan özellikler amacına göre istatistiksel (statistical), yapısal (structural), model tabanlı (model based) ve transform tabanlı (transform based) olmak üzere dört bölümde incelenebilir [58] [59]. İstatistiksel olarak görüntüden özellik çıkarmada yaygın olarak Gray Level Co-occurrence Matrix (GLCM) metodu kullanılmaktadır. GLCM matrisi kullanılarak belirli bir açıda ve uzaklıkta bulunan piksellerin frekansını tutarak oluşturulan matris ile ortalama, entropi, varyans gibi istatistiksel ölçümler yapılarak dokuların ayırt edici özellikleri çıkarılmaktadır.

GLCM metodu medikal görüntülerin sınıflandırılmasında ve bölütlendirilmesinde de yaygın olarak kullanılmıştır. Doyle ve ark. Prostat biyopsi görüntülerinden oluşturdukları görüntü parçalarını (patches) kullanarak GLCM matrisi oluşturmuşlardır. GLCM matrisi ile Haralick özellikleri çıkarılarak hastalıklı ve normal prostat görüntülerini %92.4 başarıyla SVM (support vector machine) metodu ile sınıflandırabilen bilgisayar destekli tanı sistemini geliştirmişlerdir [60]. Guang-Ming ve ark. akciğer kanseri hastalığının tanısını GLCM tabanlı istatistiksel doku analizi ve bulanık (fuzzy) SVM algoritması kullanarak B tipi ultrason görüntülerini %97 başarıyla sınıflandırmışlardır. [61]. Huan ve ark. PET- bilgisayarlı tomografi görüntüleri kullanarak boyun ve beyin kanseri hastalığının tanısını GLCM ve komşu piksellerin yoğunluk farklılığı (neighborhood grey tone difference matrices) bilgisini kullanarak KNN metoduyla %89 hassasiyet değeriyle sınıflandırmıştır [62]. Liu ve ark. ultrason görüntülerinden meme kanseri hastalığını GLCM ve kernel SVM metotları kullanarak % 94.64 başarıyla tanımlamışlardır [63].

İstatistiksel tabanlı olan GLCM metodunun başarısı yapısal, model ve transform tabanlı yöntemler ile desteklenerek istenilen nesnelerin bölütlenme ve tanımlanma başarısı artırılmıştır. Sertel ve ark. çocukluk döneminde görülen otonom sinir sistemi

(neuroplastoma) hastalığını GLCM tabanlı istatistiksel doku analizi, local binary pattern (LBP) ve KNN metodu ile %88.4 başarıyla sınıflandırmışlardır [64]. Korchine ve ark. MR ve bilgisayarlı tomografi görüntüleri ile belirlenen trabeküler (trabecular) kemik bölgesinde osteoperetik rahatsızlığının teşhisini Fractal ve GLCM tabanlı metotlar kullanarak %85.71 başarıyla tanımlamışlardır [65]. Zhang ve ark. beyin MR görüntülerinden doku sertleşmesi (multiple sclerosis) tanısını gradient matrix, run length matrix, GLCM, autoregressive model ve wavelet analizi yardımıyla elde edilen özelliklerle başarıyla sınıflandırmışlardır [66]. GLCM matrisinin tek başına kullanımı ile belirtilen yöntemlerin hepsini birlikte kullanılması ile elde edilen başarıyı karşılaştırdıklarında GLCM tabanlı istatistiksel yöntemle yapılan sınıflandırmadan oldukça yüksek başarı elde edildiğini belirtmişlerdir.

İstatistiksel tabanlı yöntemler, şekil, renk ve diğer doku özellikleri özellikle birlikte kullanıldığında yüksek başarılı sonuçlar verse de bu yöntemler görüntünün sadece uzaysal alanda (spatial domain) ifade edilen gizli özelliklerini ortaya çıkarmayı sağlar. Fakat çoklu çözünürlük (multiresolution yada multiscale) ve çoklu yönlülük (multidimensional) tabanlı doku analizi (MTAT multiresolution texture analysis techniques) yöntemleri hem uzaysal alanda hem de frekans alanında (frequency domain) görüntünün detaylı özelliklerini ortaya çıkarmayı sağlar [67].

Wavelet ve wavelet tabanlı ridgelet, curvelet, contourlet ve shearlet transformları görüntüye uygulanarak frekans alanında istatistiksel doku analizinde olumlu sonuçlar verdiğinden dolayı son dönemlerde yaygın olarak kullanılmıştır. Castro ve ark. hasar görmüş domuz spermatozaları sınıflandırmak için görüntülere wavelet ve curvelet transformu uyguladıktan sonra her bir görüntü çıktısı için GLCM matrisi oluşturmuşlardır [68]. GLCM matrislerinden birinci ve ikinci dereceden istatistiksel analizlerini gerçekleştirerek % 97 başarıyla sınıflandırmayı sağlamışlardır. Curvelet transform tabanlı istatistiksel analizin sınıflandırma başarısı wavelet transform tabanlı istatistiksel analizden daha başarılı olduğunu ortaya koymuşlardır. Deteri ve ark. doku sınıflandırmasını gerçekleştirmek için wavelet, ridgelet ve curvelet transformlarını bilgisayarlı tomografi görüntülerine uygulamışlardır [69]. MTAT teknikleri ile GLCM matrisinin doku sınıflandırmadaki başarılarını karşılaştırdıklarında en başarılı yöntemin % 97- 98 oranında curvelet transformu ile sağlandığını göstermişlerdir. Curvelet

transformundan sonra sırayla yüksek başarı GLCM , ridgelet ve wavelet tabanlı doku analizinden elde edilmiştir. Yine benzer bir çalışma Reddy ve ark. tarafından gerçekleştirilmiştir [70]. Farklı olarak karşılaştırmaya contourlet transformunu ekleyerek domuz kemiğinin sınıflandırmasını bilgisayarlı tomografi görüntüleri ile gerçekleştirmişlerdir . Contourlet transformu tabanlı doku analizi % 97.69 başarı oranıyla wavelet, ridgelet ve curvelet transformu tabanlı doku analizinden daha başarılı bulunmuştur.

Wavelet ve wavelet uzantılı ridgelet, curvelet, contourlet ve shearlet tabanlı doku analizi tekniklerinin her birinin doku incelemesinde önemli kısıtları mevcuttur. Görüntü analizinde yaygın ve başarılı kullanım alanı bulunan Wavelet transformu görüntü üzerindeki noktaları iyi bir şekilde belirleyebilmesine rağmen görüntüdeki eğrileri ve konturları belirlemede yetersiz kalmaktadır [71]. Çünkü wavelet transformu çok çözünürlük (multiresolution) özelliğine sahip olmasına rağmen çok yönlü (multidirectional) özelliğine sahip değildir. Sonraki çalışmalarda affine transform kullanılarak wavelet transformunun analizinde öteleme döndürme ve ölçeklendirme özelliği eklenmesine rağmen kısıtlı sayıda yönlülük kazandırılabilmiştir. Bu çalışmalarda ise ridgelet transformu kadar istenilen başarı elde edilemediği gibi sistemin çalışma süresini de artırmışlardır. Wavelet transformunun çok yönlülük kısıtını aşmak için ridgelet transformu geliştirilmiştir. Ridgelet transformu wavelet transformuna göre daha yüksek çözünürlük ve yönlülük özelliğine sahip olmasına rağmen görüntüdeki yerel eğrileri saptayabilme başarısını global eğrileri için gösterememiştir. Ayrıca ridgelet transformu yumuşak geçişlerde olan eğrileri tanımlamakta yetersiz kalmıştır. Bu eksikliği gidermek için curvelet transformu kullanılmıştır [72]. Curvelet transformu wavelet ve wavelet tabanlı yöntemler arasında literatürde en yaygın kullanım alanı bulunan bir yöntemdir. Çok yönlülük ve çözünürlük özelliğine sahip olan curvelet transformu eş yönsüz özellikleri ve yumuşak eğrileri görüntüde tanımlamakta oldukça başarılıdır. Fakat curvelet transformunun ilk versiyonunun uygulanması oldukça zordur [73]. Sürekli (continous domain) alanda tanımlanan curvelet transformunun ayrık alana taşınması ilk versiyonunun birinci nesil curvelet transformunun (first generation curvelet) kullanım alanını daraltmıştır. Sonraki versiyonu ikinci nesil curvelet transformu (second generation curvelet) ile bu problem aşılmasına rağmen curvelet transformunda ekstra oryantasyon

(orientation search) araması yapmak gerekmektedir [74]. Çünkü hem curvelet hem de contourlet transformunun ortogonallik (orthogonality) özelliği bulunmamaktadır [75]. Contourlet transformu curvelet transformuna göre daha fazla çok yönlülük özelliğine sahiptir. Yumuşak eğrileri saptamakta bazı çalışmalarda curvelet transformunda daha başarılı sonuçlar verse de gereksiz özellik (redundancy) çıkarma oranı curvelet transformuna oranla daha yüksektir [76]. Contourlet transformu, shearlet transformu gibi farklı seviyelerde (level) değişebilen sayıda yönlülük sağlama özelliğine sahip olmasına rağmen özellikle Laplacian piramitten gelen gereksiz (redundancy) özellikler ve ortogonallik özelliğine sahip olmamasından dolayı doku analizinde curvelet transformu kadar başarı sağlayamamaktadır [77] [78].

Wavelet ve wavelet tabanlı yöntemlerin en büyük eksikliği ortogonallik özelliği ve görüntünün polar koordinat sisteminden taşınmasından dolayı ortaya çıkan oryantasyon arama problemidir. Hermite transformu Gaussian türevine dayalı başka bir MTAT tekniğidir.

Hermite transformunun en önemli özelliği wavelet tabanlı yöntemlerde bulunmayan ortogonallik özelliğidir. Gaussian türevine dayalı olan bu metodun gerçekleştirimi curvelet transformu kadar zor değildir. Çünkü Gaussian filtrelerin türevi ayrıştırılabilmektedir. Diğer önemli bir farklılığı ise Hermite transformunun yerel özelliğine sahip olmasıdır. Hermite transformu uygulanarak dekompozisyonu (decomposition) yapılan görüntülerde elde edilen katsayılar (coefficient) alınan bir noktanın karşılığı doğrudan orijinal görüntüyle aynı noktadır. Curvelet transformu gibi polar koordinat düzlemine rotasyonel (rotational) olarak aktarılmaya ihtiyaç duymadığından görüntünün önemli yapısal özellikleri korunmuş olur [75]. Bu sayede görüntünün doku özelliklerini daha verimli tanımlamayı sağlar.

Hermite Transformu görüntü işleme alanında özellikle kenar bulma [79], görüntü füzyonu (fusion) [76] ve görüntüde gürültü azaltımı (denoising) ile ilgili önemli çalışmalarda kullanılmış ve başarılı sonuçlar elde edilmiştir. Özellikle görüntüde gürültü giderimi ve görüntü füzyon çalışmalarında wavelet, curvelet ve contourlet transformu ile elde edilen sonuçlardan daha başarılı sonuçlar Hermite transformu ile elde edilmiştir [75]

[76]. Fakat doku tanımlama ve sınıflandırma ile ilgili çalışmalar Hermite transformu kullanılarak yapılmış çalışmaya literatür taraması süresince rastlanmamıştır.

Wavelet ve wavelet tabanlı yöntemler, medikal görüntüleme teknikleri olan MR, bilgisayarlı tomografi, ultrason vb. görüntülerde vücudun farklı bölgelerinde (beyin, akciğer, prostat, kalp vs.) oldukça yaygın yapılmış çalışmalar mevcuttur [70] [71] [72]. Bunların önemli bir kısmı yukarıda anlatılmıştır. Fakat PD ağırlıklı MR görüntüleri ve Hermite transformu kullanılarak doku analizi ve sınıflandırma çalışması literatürde mevcut değildir [80].

Çok yönlülük ve çok çözünürlük yöntemlerinden curvelet, contourlet ve Hermite transformlarından elde edilen katsayılar üzerinden yapılan istatistiksel doku analizlerinin sınıflandırma başarıları oldukça yüksek olmasına rağmen Hill- Sachs ve ödemli MR görüntülerini tanımlamakta yeterli değildir. İstatistiksel doku analizi sonuçları şekil özellikleri ile birleştirilerek bu başarının artırılması sağlanmıştır.

Hill- Sachs lezyonlu MR görüntülerinde lezyondan dolayı şekil bozuklukları görülmektedir. Histogram Oriented Gradients (HOG) yönteminin geliştirilmiş hali olan Pyramid of Histogram Orientation Gradients (PHOG) yöntemi kullanılarak şekil özellikleri çıkartılmaya çalışıldı [81]. HOG yöntemi ile görüntüdeki şekil özelliklerini çıkarmak için önce Canny edge dedector uygulanarak kenar bilgileri saptanır. Daha sonra Sobel maskesi ile kenar bilgilerinin gardyanı ve kuvveti (magnitude) hesaplanır. Hesaplanan kuvvet ile görüntü kenarlarının katkısı bir ağırlıkla ifade edilir. Belirli oryantasyon ve açıdaki ağırlıklar histogramın bir “bini” ile ifade edilir. PHOG yöntemi ile görüntü farklı altbantlara ayrılarak her bir alt bant için HOG yöntemi uygulanır. Elde edilen histogramlar peş peşe eklenerek görüntü özellikleri çıkarılır.

PHOG yönteminin başarısı birçok çalışmada HOG yöntemine göre daha yüksektir. Genellikle yüz tanıma [82], yüzdeki duyguyu tanıma [83], gülümsemeyi tanımlama [84] gibi çalışmalarda yaygın olarak kullanılan bu yöntem medikal alanda oldukça az uygulamada kullanılmıştır. Resailouyeh ve ark. shearlet katsayılarını ve shearlet katsayılarının histogram bilgisini kullanarak mikroskopik görüntülerin sınıflandırılmasını gerçekleştirmiştir [85]. Ou-Yang ve ark. meme kanserinin sınıflandırmasında PHOG

yönteminden faydalanmıştır [86]. Oktay ve ark. PHOG ve olasılıksal grafik (probabilistic graphical) model kullanarak omurga disklerinin sınıflandırılmasını sağlamıştır [87].

PHOG yöntemi genellikle diğer doku özellikleri olan local binary pattern ve Gabor özellikleri ile birleştirilerek sınıflandırma sisteminin başarısı artırılmıştır. Sheikh ve ark. deniz türlerinin sınıflandırılmasını local binary pattern ve PHOG metotları ile sağlamıştır [88]. Zhang ve ark. yürüyen insanları tanımlamak için local trinary pattern, local binary pattern ve PHOG yöntemleri ile elde edilen özelliklerden faydalanmıştır [89]. Bai ve ark. yüzdeki gülümsemeyi Gabor ve PHOG özellikleri ile tanımlamıştır [84].

Çalışmamızın bu bölümünde doku ve şekil özellikleri hem uzaysal alanda (spatial domain) hem de frekans alanında (frequency domain) tanımlanacaktır. (Şekil 4.1) ile önerilen sistemin akış şeması verilmiştir.




Şekil 4.1 Önerilen bilgisayar destekli tanı sistemin genel akış diagramı

4.2 Doku ve Şekil Özellikleri

Omuz MR görüntülerinden humerus başı ACWE ve SPF metodları ile başarıyla bölütlenmiştir. ACWE metodunun başarısı SPF metodundan daha yüksek olduğundan görüntü parçaları ACWE tarafından belirlenen humerus başı konturu kullanılarak oluşturulmuştur. (Şekil 4.2) de gösterilen otomatik bölütleme sonucu ve sınırlayıcı kutu (bounding box) yöntemi kullanılarak bölütlenen alanı en iyi ifade eden görüntü parçacıkları alındı. Alınan dikdörtgen bölgede humerus başını içermeyen alana sıfır

değeri atanarak (Şekil 4.12)'de görülen nihai görüntüler elde edilmiştir. Normal, ödemli ve Hill-Sachs lezyonlu görüntü parçaları üzerinden ikinci dereceden istatistiksel doku ve şekil özellikleri çıkarılmıştır.




Şekil 4.2 PD ağırlıklı sol omuz görüntülerinde a) ödemli humerus başı b) normal humerus başı c) uzman tarafından yapılan manuel bölütleme d) ACWE metodu ile gerçekleştirilen bölütleme e) otomatik olarak alınan ödemli ve f) normal görüntü parçaları (image patches).

4.2.1 Gray Level Co-occurrence Matrix (GLCM)

GLCM metodu yaygın olarak kullanılan ve gray tone spatial dependency matrix olarak da bilinen doku analizi yöntemidir. GLCM matrisi, görüntüde belirli açıda (orientation) ve uzaklıkta (distance) bulunan piksel çiftlerinin sayısının toplamını gösteren bir matristir. Belirli açı ve uzaklık parametreleri öteleme (offset) parametresi olarak ta adlandırılmaktadır. GLCM matrisi kullanılarak birinci ve ikinci dereceden istatistiksel analizler çıkartılabilmektedir.

(Şekil 4.3)'de gösterilen görüntüdeki gibi 0, 45, 90 ve 135 derece açılarla bir piksel uzaklıktaki (Şekil 4.3 b) de gösterilen görüntü için oluşturulan GLCM matrisi (Şekil 4.3 c)' de verilmiştir. Örneğin 0 ve 1 piksellerinin belirlenen ofset değerine göre

konumlandırılması görüntüde üç kez tekrarlanmıştır. Bu durumlar yeşil dikdörtgen ile gösterilmiştir. GLCM matrisinde bu değer yine yeşil dikdörtgen ile belirtilmiştir. Bu işlem bütün pikseller için gerçekleştirilerek GLCM matrisinin son durumu elde edilir.



Şekil 4.3 GLCM matrisinin oluşturulmasının görsel ifadesi.

Alınan farklı ofset değeri için farklı GLCM matrisleri oluşmaktadır. Oryantasyon simetrik ya da asimetrik olarak alınabilir. Ofset değerinin belirlenmesinde kesin bir kanı yoktur. Dolayısıyla biz çalışmamızda farklı açı ve uzaklıkta değerler olarak sınıflandırma başarısını analiz ettik [90].

GLCM matrisinden doku özelliği çıkarmada yaygın olarak kullanılan parametreler kontrast, enerji, homojenlik, korelasyon ve entropidir. Biz bu parametrelere ek olarak angular second moment (ASM), varyans, varyans farkı, entropi farkı, moment farkı, benzersizlik (dissimilarity), cluster shade, cluster prominence, inertia, yüksek olasılık (maximum probability), otokorelasyon, inverse difference moment ve iki korelasyon ölçütünü (two measurements of correlation features) inceledik.

$$\text{Entropi} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_{i,j} (-\ln P_{i,j}) \quad (4.1)$$

$P_{i,j}$ parametresi görüntüden elde edilen GLCM matrisini, N ise gri tonlamadaki farklı gri seviyeleri belirtmektedir.

$$\text{Kontrastlık} = \sum_{i=1}^{N-1} \sum_{j=1}^{N-1} P_{i,j} (i,j)^2 \quad (4.2)$$

Entropi parametresi görüntüdeki düzensizliği ve karmaşıklığı gösterirken kontrastlık görüntüdeki yerel değişiklikleri belirtir.

$$\text{Homojenlik} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{P_{i,j}}{1 + (i, j)^2} \quad (4.3)$$

Homojenlik parametresi ile görüntünün ne kadar homojen olduğu ve korelasyon ile gri tonlamada doğrusal bağıllık ölçülebilmektedir.

$$\text{Korelasyon} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_{i,j} \left(\frac{(i - \mu_i)(j - \mu_j)}{\sigma_i \sigma_j} \right) \quad (4.4)$$

μ_i , σ_i parametreleri $P_{i,j}$ matrisi için ortalama ve varyans değerlerini tanımlamaktadır.

$$\text{ASM} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_{i,j}^2 \quad (4.5)$$

ASM ve enerji parametreleri ile görüntünün homojenliği ve tekdüzeliği (uniform) ölçülmeye çalışılmıştır.

$$\text{Enerji} = \sqrt{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_{i,j}^2} \quad (4.6)$$

GLCM tabanlı istatistiksel analizde iki parametrenin belirlenmesi sınıflandırma başarısında çok etkilidir. Birincisi ofset değeri, ikincisi ise elde edilen GLCM matrisinden hesaplanacak olan birinci ya da ikinci dereceden istatistiksel parametrelerin seçimi. Hangi parametrelerin hangi doku türünde daha etkili olduğunun çalışılan şeklin incelenmesi ile belirlenmesi zordur. Dolayısıyla etkili olabileceğini düşündüğümüz bütün parametreleri hesaplayıp correlation feature selection (CFS) metodu ile en başarılı olan parametreleri ayırt edici doku özellikleri olarak belirledik. Yukarıda belirtilen bütün parametreleri kullandığımızda ödemli ve normal görüntülerin sınıflandırılmasının başarısı SVM

metodu ile % 94.11 olarak gerçekleştirdik. Sadece literatürde medikal dokuların analizinde kullanılan kontrast, enerji, homojenlik, korelasyon ve entropi özellikleri ile sistemimizin sınıflandırma başarısı % 91.17 olarak hesaplanmıştır. GLCM matrislerinden özellik çıkarma için hem asimetrik hem de simetrik yapı kullanılmıştır. Simetrik olarak özellik çıkarmanın sonucunun daha iyi olduğu gözlemlenmiştir (Çizelge 4.1) ve (Çizelge 4.2) .

Çizelge 4.1 GLCM özelliklerinin simetrik olmayan yapıda farklı uzaklık ve açısıl parametreleri ile hesaplama ($\theta_1 = 0^\circ, 45^\circ, 90^\circ$ and 135°).

Uzaklık Değeri (d)	MLP	SVM	KNN 1	KNN 3	KNN 5	Ortalama
d = 1	90.58	91.76	89.41	89.41	85.29	89.29
d = 2	90.58	91.76	88.23	89.41	87.64	89.52
d = 4	90.58	93.52	89.41	88.82	89.41	90.34
d = 8	92.35	94.11	91.17	92.94	92.94	92.70
d = 12	91.76	93.52	92.94	91.17	91.76	92.23
d = 16	90	92.94	90.58	92.35	94.11	91.99
Ortalama	90.98	92.94	90.29	90.68	90.19	

Çizelge 4.2 GLCM özelliklerinin simetrik yapıda farklı uzaklık ve açısıl parametreleri ile hesaplama ($\theta_1 = 0^\circ$ ve 180°).

Uzaklık Değeri (d)	MLP	SVM	KNN 1	KNN 3	KNN 5	Ortalama
d = 4	90.58	92.35	88.82	88.23	88.23	89.64
d = 8	92.35	94.11	88.82	91.17	92.35	91.76
d = 12	93.52	94.70	92.94	94.11	93.52	93.75
d = 16	90.00	92.94	90.58	92.35	94.11	91.99
Ortalama	91.6125	93.525	90.29	91.46	92.05	

Görüntüdeki asimetriyi en iyi belirleyen parametreler cluster shade ve cluster prominence olmuştur. Ödemli görüntülerde asimetri değeri oldukça yüksek olduğundan bu özellikler normal humerus başının lezyonlu olan görüntülerden ayırt edilmesini sağlamıştır. Maximum probability özelliği ise görüntüdeki dominant olan örüntüyü tanımlamayı sağlamıştır. Enerji ve ASM ise görüntüde en çok tekrar eden pikselleri belirleyerek sınıflandırmada olumlu katkı sağlamıştır.

4.2.2 Pyramid of Histogram Orientation Gradients (PHOG)

Bölütlemesi sağlanan humerus başlarının normal, ödemli ve Hill-Sachs lezyonlu olarak sınıflandırılmasında doku özelliklerini destekleyecek bir yöntem ihtiyacı duyulmuştur.

Hill-Sachs lezyonlu görüntüler deformasyondan dolayı şekil olarak ödemli ve normal omuz MR görüntülerinden farklıdır. Bu durumu şekil özelliklerinden HOG yönteminin uzantısı olan PHOG metodu ile ele almaya çalıştık [81]. PHOG metodu yüz ve yüz ifadelerini tanımda yaygın kullanım alanı bulmasına rağmen medikal görüntüleme teknikleri ile elde edilen görüntülerde uygulaması oldukça azdır [85] [86].

Humerus başlarını en iyi ifade eden bölge ACWE metodunun belirlediği kontur ile elde edilmiştir. Bu konturu sınırlayabilecek ilgili alan sınırlayıcı kutu (bounding box) yöntemi ile belirlendikten sonra görüntü parçaları (patches) elde edilmiştir.

Çizelge 4.3 PHOG özellikleri ile humerus başının sınıflandırma başarılarının farklı parametrelerle incelenmesi (K= histogram aralığı (bin), R = oryantasyon aralığı ve L = piramit seviyesi)


		Özellik seçiminden önce sınıflandırma başarıları		Özellik seçiminden sonra sınıflandırma başarıları	
K/R/L	Özellik sayısı	Doğruluk Değeri	Özellik sayısı	Doğruluk Değeri	
8/180/2	168	83.52	40	83.52	
8/180/3	680	90.58	67	90.58	
8/360/2	168	89.41	31	92.94	
8/360/3	680	93.52	69	97.05	
20/180/2	420	82.94	59	88.82	
20/180/3	1700	84.70	94	91.76	
20/360/2	420	90.05	64	94.05	
20/360/3	1700	92.35	84	95.88	

Her bir görüntü parçasına canny edge detector uygulanarak kenar bilgileri çıkarıldı. Görüntü üç piramit seviyesi (level) ile ifade edilerek görüntü hücrelere (cells) ayrıldı. Her bir L level 2L adet hücre barındırmaktadır. Herhangi bir yumuşatma işlemi uygulanmadan, 3x3sobel maskesi kullanılarak kenar bilgileri için gradyan ve kuvvet (magnitude) değeri hesaplandı. Bu değerler kullanılarak her bir piksel için bir ağırlık değeri atandı. Belirli bir oryantasyon ve açı aralığı (bin) histogramın bir aralığı ile ifade edilerek her bir hücre için histogram bilgisi çıkarıldı. Piramidin her seviyesinden elde edilen histogramlar birleştirilerek PHOG özellikleri (Şekil 4.4) elde edildi.

Elde edilen özellik sayısı aşağıdaki şekilde hesaplanabilmektedir [81].

$$\text{Özellik Sayısı} = K \sum_{l \in L} 4^l \quad (4.7)$$

L=3 , histogram aralığı (bin) K =8 ve oryantasyon aralığı [0-360] iken toplam 680 özellik, L=3 , histogram aralığı (bin) K =20 ve oryantasyon aralığı [0-360] iken toplam 1700 özellik çıkarıldı. Farklı aralık (K), oryantasyon değeri (R) ve piramit seviyeleri (L) için elde edilen özellik sayısı, özellik seçiminden önce ve sonrası elde edilen sınıflandırma başarısı (Çizelge 4.3) ile verilmiştir.



Şekil 4.4 a) Ödemli omuz MR görüntü parçası a) PHOG metodunun sıfırıncı piramit seviyesi b) PHOG metodunun birinci piramit seviyesi c) PHOG metodunun ikinci piramit seviyesi için elde edilen histogramın gösterimi.

Çalışmamızda oryantasyon parametresi 8 ve 20 olarak alındı. Açık değeri ise [0-180] ve [0-360] aralığında belirlendi. En iyi sonuçlar piramit seviyesi L=3 , histogram aralığı (bin) K =8 ve oryantasyon aralığı [0-360] aralığı için elde edildi. Bu parametreler ile normal ve ödemli sınıfların sınıflandırma başarısı %93.52 olarak elde edildi. CSF yöntemi ile özellik sayısı 680' den 69' a indirildiğinde SVM metodu ile sınıflandırma başarısı % 97.05 olarak hesaplandı.

4. 3 Transform Tabanlı Doku Özelliklerinin Çıkarılması

MR görüntülerinden GLCM tabanlı istatistiksel doku özellikleri çıkarıldıktan sonra bilgisayarlı tanı ve teşhis sisteminin performansının artırılması için görüntülere wavelet tabanlı curvelet, contourlet ve farklı olarak Hermite transformu uygulanarak elde edilen katsayılar (coefficients) üzerinden GLCM matrisleri oluşturularak ikinci dereceden istatistiksel analizlerle önerilen sistemin sınıflandırma başarıları karşılaştırılmalı olarak ölçüldü.

Görüntü üzerinden GLCM metodu kullanılarak yapılan istatistiksel doku analizinde sadece uzaysal özellikler değerlendirilebilirken görüntünün transformu gerçekleştirilerek elde edilen katsayılar üzerinden yapılan doku analizinde hem uzaysal hem de frekans alanında örüntü özellikleri çıkarılabilmektedir. Yapılan görüntü işleme ve nesne tanıma çalışmalarında yaygın olarak kullanılan yöntemler wavelet, ridgelet, curvelet, contourlet ve shearlet transformlarıdır. Curvelet ve contourlet transformunun başarısı, wavelet ridgelet ve gabor metotlarından daha yüksek olduğu yönünde birçok karşılaştırılmalı çalışmalar mevcuttur. Son dönemlerde ise shearlet transformu görüntüde gürültü giderimi, görüntü füzyonu ve doku analizinde kullanılmıştır. Bazı çalışmalarda shearlet transformu tabanlı doku analizi çalışmaları curvelet ve contourlet transformundan daha iyi sonuç verdiği gözlenmiştir. Fakat wavelet tabanlı bu yöntemlerin genel olarak yetersiz kaldığı iki önemli durum mevcuttur. Birincisi yerel olarak sinyalin herhangi bir polar rotasyon yapmadan decompozisyonu yapılan alandan doğrudan elde edilebilmesi (local correspondence property) [75], ikincisi ise ortogonalliktir [80]. Bu özelliklerin Hermite transformu tarafından sağlanabildiğini ve uygulanmasının wavelet tabanlı transformlara göre daha kolay olduğunu analiz ettikten sonra Hermite transform tabanlı doku analizini gerçekleştirmeye karar verdik. GLCM tabanlı, curvelet, contourlet transform tabanlı ikinci dereceden istatistiksel yöntemlerle doku analizlerini Hermite transform tabanlı doku analizleri ile karşılaştırdık.

4.3.1 Curvelet Transform Tabanlı İkinci Dereceden İstatistiksel Doku Analizi

Curvelet transformu çok çözünürlüklü yöntemlerden (multiresolution) olan wavelet ve ridgelet transformlarının eksikliklerini gidermek amacıyla geliştirilmiş ve literatürde en çok kullanılan ve kabul görmüş bir yöntemdir. Wavelet transformu görüntü üzerindeki

noktaları yakalamakta oldukça başarılı bir yöntemdir. Görüntü işlemede birçok alanda kullanılsa da görüntülerde doğruları özellikle yumuşak eğrileri çok yönlülük özelliğine sahip olmadığından (multidirectional) saptamakta yetersiz kalmıştır. Wavelet transformunun bu eksikliğini gidermek için yapılan çalışmalar ise hem yetersiz hem de çalışma zamanı bakımından yüksek maliyetli olmuştur. Önerilen yöntemler arasında en başarılı olan ise Ridgelet transformudur. Çok yönlü (multidirectional) ve çok çözünürlüklü (multiresolution) özelliklerini barındırmasına rağmen görüntüdeki yerel doğruları başarıyla saptayabilirken global doğruları bulmakta yetersiz kalmıştır [75]. Ridgelet transformunun performansını artırmak için görüntü bloklara ayrılmıştır ve her bir blok için ridgelet transformu uygulanmıştır. Bu yöntem ise birinci nesil curvelet transformu (first generation curvelet) olarak bilinmektedir. Curvelet transformu görüntüdeki doğruları hatta yumuşak eğrileri saptamakta çok yönlülük özelliğinden dolayı oldukça başarılıdır. Fakat birinci nesil curvelet transformu sürekli (continous) alanda tanımlanıp ayrık (discrete) ortama taşındığından dolayı yaygın bir kullanım alanı bulamamıştır. Fakat ikinci nesil curvelet (second generation curvelet) transformu bu sorunu “unequipped fast Fourier transform” ve “wrapping of specially selected Fourier samples” formlarında direk olarak ayrık ortamda tanımlandığından çözmüştür [73] [74]. Yaygın kullanım alanı bulan ikinci nesil curvelet transformlarının birbirinden en büyük farkı curveletleri dönüştürürken kullandıkları uzaysal gridlerden kaynaklanmaktadır.

Curvelet transformu görüntüdeki doğrularda ya da eğrilerde olan sürekliliği (discontinuities) negatif olmayan, yumuşak (smooth) radyal pencere fonksiyonu $W(r)$ (radial windows) ve periyodik açısall pencere $V(t)$ (angular window) fonksiyonu ile sağlamaktadır.

W parametresi pozitif reel argümanlarla $r \in (1/2, 2)$ için sağlanırken V parametresi $\in [-1, 1]$ aralığında desteklenmektedir. Her iki fonksiyonda geçişlilik (admissibility conditions) koşullarını sağladığı gösterilmiştir.

$$\sum_{j=-\infty}^{\infty} W^2(2^j r) = 1, \quad r \in \left(\frac{3}{4}, \frac{3}{2}\right) \quad (4.8)$$

$$\sum_{\ell=-\infty}^{\infty} V^2(t - \ell) = 1, \quad t \in \left(-\frac{1}{2}, \frac{1}{2}\right) \quad (4.9)$$

U_j frekans penceresi Fourier alanında radyal pencere ve periyodik açısal pencere fonksiyonlarına dayalı olarak aşağıdaki gibi tanımlanır.

$$U_j(r, \theta) = 2^{-\frac{3j}{4}} W(2^{-j}r) V\left(\frac{2^{\lfloor j/2 \rfloor} \theta}{2\pi}\right) \quad (4.10)$$

Curvelet transformu $x = (x_1, x_2)$ fonksiyonu ile 2^{-j} ölçeğinde (scale), θ_ℓ oryantasyon açısında (orientation angle) ve $x_k^{(j,\ell)} = R_\ell^{-1}(k_1 \cdot 2^{-j}, k_2 \cdot 2^{-j/2})$ pozisyonunda (4.11) eşitliği ile tanımlanır.

$$\varphi_{j,\ell,k}(x) = \varphi_j(R_{\theta_\ell}(x - x_k^{(j,\ell)})) \quad (4.11)$$

Burada R_θ parametresi radyan cinsinden θ açısı kadar döndürmeyi (rotation) ve R_θ^{-1} parametresi de bunun tersini aynı zamanda transpozunu ifade etmektedir.

Çalışmamızda ikinci nesil curvelet transformlarından “wrapping “ algoritmasına dayalı olanı kullanarak farklı yönlerde ve farklı çözünürlüklerde (resolution) görüntü analizini gerçekleştirdik. Bölütlenmesi tamamlanan humerus başlarından oluşturulan görüntü parçacıklarının boyutu maksimum çözünürlük seviyesini belirlemektedir.

Çizelge 4.4 Curvelet tabanlı ikinci dereceden istatistiksel doku özelliklerinin farklı sınıflandırıcılar ile sınıflandırma başarıları oranları.

	Curvelet tabanlı özniteliklerin sınıflandırma başarıları oranları (accuracy rate) [%]					
Uzaklık Değeri (d)	MLP	SVM	KNN 1	KNN 3	KNN 5	Ortalama
d = 8	95.29	97.05	92.94	94.11	92.35	94.34
d = 12	96.47	94.11	90.00	92.35	90.58	92.70
Ortalama	95.88	95.58	91.47	93.23	91.46	

Uygulamamızda görüntü parçaları için dekompozisyon seviye parametreleri iki ve üç, aç (wedge) parametreleri ise 12, 16 ve 32 olarak belirlendi. En iyi doku özellikleri dekompozisyon seviyesi iki aç parametresi de 16 olarak alındığında elde edildi. Birinci seviye (finest level) için bir tane ikinci seviye (second coarsest level) için 16 tane alt bant elde edildi. Toplamda 17 alt bant için farklı oryantasyon ve uzaklık parametreleri ile GLCM matrisleri oluşturuldu. GLCM matrisleri üzerinden ikinci derece istatistiksel özellikler çıkarıldı. Uzaklık ($d = 1, 2, 4, 8, 12, 16$) ve oryantasyon ($\theta = 0^\circ, 180^\circ$)


parametreleri ile her bir alt bant için 44 farklı GLCM tabanlı doku özellikleri çıkarılarak toplamda 748 özellik elde edildi. CFS metodu ile ayırt edici en iyi 17 özellik seçildi. En iyi sınıflandırma başarısı SVM metodu ile uzaklık değeri $d=8$ ve oryantasyon ($\theta = 0^\circ, 180^\circ$) alındığında elde edildi (Çizelge 4.4).

4.3.2 Contourlet Transform Tabanlı İkinci Dereceden İstatistiksel Doku Analizi

Curvelet transformu ile yumuşak ve eş yönsüz (anisotropic) doğrular iki boyutlu görüntülerde az sayıda katsayı kullanılarak başarıyla sürekli alanda (continuous) tanımlanabilmesine rağmen ayrık alanda (discrete domain) tanımlanabilmesi için birtakım rotasyon işlemine tabi tutulması gerekmektedir. Bu da görüntülerdeki yapısal alanların tanımlanmasında bozulmalara neden olmaktadır. Contourlet transformu curvelet transformunun bu eksikliğini gidermek için geliştirilmiş bir yöntemdir.

Contourlet transformu, curvelet transformu gibi çok yönlü ve çok çözünürlüklü olarak görüntü dekompozisyonu sağlamaktadır. Farklı olarak contourlet transformu farklı ölçeklerin her biri (scale) için daha fazla yönlülük (directional) değişikliği imkanı sunmaktadır [91].

Contourlet transformu iki farklı Laplacian ve yönlü (directional) filtrelerin ardı ardına uygulanması ile gerçekleştirilir [92]. Laplacian piramit (LP) görüntünün çok yönlü alçak (low pass) ve yüksek (high pass) geçirgenli olarak dekompozisyonunu sağlar. Bu alt bantların her biri yönlü filtre (directional filter bank DFB) yardımı ile analiz edilerek yüksek frekans değerlerindeki yumuşak eğrilerin saptanmasını sağlar. Laplacian piramit yardımıyla görüntüdeki noktalar tespit edilir. Bulunan noktaların sürekliliği ise DFB ile birleştirilerek eş yönsüz doğrular saptanır. Laplacian piramit ve DFB nin uygulanmasından sonra contourlet katsayıları elde edilir. Görüntüde istenilen seviye kadar bu işlemler tekrarlanarak her bir katman için (Şekil 4.5)' deki gibi farklı contourlet katsayıları elde edilir.



Şekil 4.5 Çok çözünürlüklü (multiscale) ve çok yönlü (multidirectional) olarak MR görüntülerinin contourlet transformu ile dekompozisyonu.

Çizelge 4.5 Contourlet tabanlı ikinci dereceden istatistiksel doku özelliklerinin farklı sınıflandırıcılar ile sınıflandırma başarıları oranları.

	Contourlet tabanlı öznitelikleri sınıflandırma başarıları oranları (accuracy rate) [%]					
Uzaklık Değeri (d)	MLP	SVM	KNN 1	KNN 3	KNN 5	ORTALAMA
d=8	94.70	96.47	91.76	93.52	94.11	94.11
d=12	92.35	95.88	92.35	93.52	92.94	93.41
Ortalama	93.52	96.17	92.05	93.52	93.52	

Çalışmamızda PD ağırlıklı MR görüntüleri üç piramit seviyesinde (pyramidal levels), 4 ve 8 yönlü alt bantlarla (subbands) dekompozisyonu sağlandı. Birinci seviyede 1, ikinci seviyede 4 ve son seviyede 8 olmak üzere toplamda 13 alt bant elde edildi. Her bir alt bant için farklı oryantasyon ve uzaklık parametreleri ile GLCM matrisleri oluşturuldu. GLCM matrisleri üzerinden ikinci derece istatistiksel özellikler çıkarıldı. Uzaklık ($d = 1, 2, 4, 8, 12, 16$) ve oryantasyon ($\theta = 0^\circ, 180^\circ$) parametreleri ile her bir alt bant için 44 farklı GLCM tabanlı doku özellikleri çıkarılarak toplamda 572 özellik elde edildi. CFS metodu ile ayırt edici en iyi 23 özellik seçildi. En iyi sınıflandırma başarıları SVM metodu

ile uzaklık değeri $d=12$ ve oryantasyon ($\theta = 0^\circ, 180^\circ$) alındığında % 96.47 olarak saptandı (Çizelge 4.5).

4.3.3 Hermite Transform Tabanlı İkinci Dereceden İstatistiksel Doku Analizi

Curvelet ve contourlet transformları çok yönlü ve çok çözünürlük özellikleriyle orijinal sinyalin alternatif sinyal olarak ifade edilmesini sağlayarak sinyalin farklı karakteristik özelliklerini ortaya çıkarır. Böylece eşyönsüz ve yumuşak eğriler bile bu yöntemlerle başarıyla saptanabilir. Fakat orthogonal curvelet ve orthogonal contourlet transformu henüz sağlanamamaktadır [75],[92]. Ayrıca analizi yapılan sinyalin yeniden sentezlenmesi yerel konum bilgileri kullanılarak gerçekleştirilememektedir.

Hermite transformu, curvelet ve contourlet transformlarından farklı olarak sinyalin yerel olarak analiz ve sentezini Gaussian türevine dayalı Hermite polinomları ile gerçekleştirir. Gaussian türevi ise Hermite polinomlarına orthogonaldır [76]. Gaussian filtreleri ayrılabilir filtreler olduğundan Hermite transformunun uygulanabilirliği de wavelet transform tabanlı yöntemlere göre daha kolaydır. Hermite transformunun diğer önemli özelliği ise Gaussian filtrelerin sonuçları görsel olarak memelilerin algılama sistemine daha uygundur. Bu özelliklerinden dolayı Hermite transformu görüntü işleme alanında, görüntü de kenar bulma, indeksleme ve görüntü füzyonu gibi alanlarda başarılı bir şekilde uygulanmıştır [80].

Hermite transformu ilk olarak orijinal görüntüyü $L(x,y)$ pencerelere $w(x - x_0, y - y_0)$ böler ve herbir yerel penceredeki pikselleri analiz ederek iki boyutlu sinyali (x_0, y_0) ayrıştırır.

$$w(x,y) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{x^2 + y^2}{2\sigma^2}\right] \quad (4.12)$$

İkinci aşamada pencerelere ayrılan sinyal orthonormal basis fonksiyonların toplamı şeklinde ifade edilerek görüntünün yerel olarak tanımlanması sağlanır. Eğer sinyal iki boyutlu Gaussian fonksiyonu kullanılarak dekompozisyonu sağlanmışsa (4.12) eşitliğindeki gibi buna karşılık gelen orthonormal polinomlar $G_{n-m,m}(x,y)$ n. dereceden Hermite polinomları H_n olarak adlandırılır [75].

$$G_{n-m,m}(x,y) = \frac{1}{\sqrt{2^n(n-m)!m!}} H_{n-m}\left(\frac{x}{\sigma}\right) H_m\left(\frac{y}{\sigma}\right) \quad (4.13)$$


Gaussian fonksiyonları ile n. dereceden Hermite polinomları $H_n(x)$ aşağıdaki gibi ifade edilebilir.

$$H_n\left(\frac{x}{\sigma}\right) = (-1)^n \exp\left(\frac{x^2}{\sigma^2}\right) \frac{d^n}{dx^n} \exp\left(-\frac{x^2}{\sigma^2}\right) \quad (4.14)$$


Giriş sinyalinin $L(x,y)$ Gaussian filtre fonksiyonu $D_{m,n-m}(x,y) = G_{m,n-m}(-x,-y)w^2(-x,-y)$ ile konvolüsyonu polinomial katsayılarının $L_{m,n-m}(x_0,y_0)$, $n = 0,1, \dots, \infty$ ve $m = 0,1, \dots, n$ için oluşturulmasını sağlar.

$$L_{m,n-m}(x_0,y_0) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} L(x,y) D_{m,n-m}(x-x_0,y-y_0) dx dy \quad (4.15)$$

Sentez filtrelerinin (synthesis filters) transform katsayıları ile interpolasyonu yani transform polinomlarının tersi (inverse) ise orijinal sinyalin oluşturulmasını sağlar.



Şekil 4.6 Hermite transformunu PD ağırlıklı MR görüntülerine uygulamamız sonucunda elde edilen alt bant (band-pass subimages) görüntülerinin gösterimi (Hermite katsayıları $D_{m,n-m}$ için $m = 0,1, \dots, n$, ve $n=3$, ile m parametresi ile x, n-m parametresi ile y yönünde değişim.)



Şekil 4.7 Farklı doku analiz yöntemlerinin (Hermite, curvelet, contourlet tabanlı GLCM ve GLCM yönteminin doku analizi) farklı sınıflandırıcılarla (SVM, MLP ve KNN) elde edilen doğruluk ve hassasiyet değerlerinin karşılaştırmalı olarak grafik yardımıyla gösterimi.

Çizelge 4.6 Hermite tabanlı ikinci dereceden istatistiksel doku özelliklerinin farklı sınıflandırıcılar ile sınıflandırma başarıları oranları.

	Hermite tabanlı öznelitliklerin sınıflandırma başarıları oranları (accuracy rate) [%]					
Uzaklık Değeri (d)	MLP	SVM	KNN 1	KNN 3	KNN5	Ortalama
d=8	98.23	97.05	94.11	95.29	95.29	95.99
d=12	98.23	97.64	93.52	95.88	94.70	95.99
Ortalama	98.23	97.34	93.81	95.58	94.99	

Doku analizi amacıyla PD ağırlıklı görüntülere Hermite transformu uygulayarak (Şekil 4.6)'daki gibi alt görüntü bantları (band-pass subimages) $N=3$ seviye (order) analiz ölçeği $S=8$ (scale of analyses) için elde edilerek görüntü dekompoze edildi. Her bir alt bant için GLCM matrisleri oluşturularak ikinci dereceden istatistiksel özellikler çıkarıldı. Uzaklık ($d = 1, 2, 4, 8, 12, 16$) ve oryantasyon ($\theta = 0^\circ, 180^\circ$) parametreleri ile her bir alt bantdan özellikler çıkarılarak peş peşe eklendi. CFS metodu ile ayırt edici en iyi 132 özellik seçildi. En iyi sınıflandırma başarıları MLP metodu ile uzaklık değeri $d=12$ ve oryantasyon ($\theta = 0^\circ, 180^\circ$) alındığında % 98.23 ve aynı parametreler için SVM metodu ile % 97.64 olarak saptandı. Hermite transform tabanlı doku analizi diğer önerilen yöntemlerden hassasiyet ve doğruluk ve parametrelerine göre kullanılan sınıflandırma yöntemleri SVM, MLP ve KNN ile daha başarılı olduğu tespit edilmiştir (Şekil 4.7).

4.4 Shearlet Transform Tabanlı PHOG Yöntemi ile Şekil Analizi

Bölütlenmesi tamamlanan humerus başlarının doku analizinde curvelet, contourlet ve Hermite transformlarından faydalanılarak ikinci dereceden istatistiksel olarak gerçekleştirilen doku analizlerinin başarısı artırılmıştı. Humerus başlarından özellikle Hill-Sachs lezyonlu olan görüntülerde objenin şeklinde lezyondan dolayı meydana gelen deformasyonu PHOG tabanlı şekil analizi yöntemi ile saptanabileceğini yapılan uygulamalar sonucunda elde ettik. PHOG yönteminin performansını artırmak için görüntülere önce Shearlet transformu uygulayıp elde edilen katsayılar üzerinden PHOG yöntemi ile şekil özellikleri çıkararak önerilen sistemin başarısını nasıl etkileyeceğini analiz ettik.

Shearlet transformu curvelet ve contourlet transformları gibi çok yönlü ve çok çözünürlük özelliğine sahiptir [93]. Fakat shearlet transformu curvelet transformu gibi şekilde yapısal bozulmalara neden olacak çevirme (rotation operation) işlemlerine ihtiyaç duymamaktadır [94]. Shearlet transformu affine sisteme dayalı olarak eşyönsüz eğrileri açısıl kırpma (shear) parametreleri ile tanımlamaktadır. Shearlet transformunun üç önemli parametresi mevcuttur. Açısıl kırpma (shear), ölçeklendirme (scale) ve çevirme (translation). Sürekli olarak tanımlanan shearlet transformu ise bu üç parametrenin değerlendirilmesiyle (sampling) ayrık alanda (discrete domain) tanımlanabilir. Sürekli shearlet (continous shearlets) $\psi_{a,s,t}(x)$ aşağıdaki gibi tanımlanabilir [78][95].

$$\psi_{a,s,t}(x) = a^{-3/4} \psi \left(\begin{pmatrix} a & 0 \\ 0 & \sqrt{a} \end{pmatrix}^{-1} \begin{pmatrix} 1 & s \\ 0 & \sqrt{1} \end{pmatrix}^{-1} (x - t) \right) \quad (4.16)$$

ψ parametresi “mother shearlet” ile Fourier alanında (domain) (4.17) denklemi ile tanımlanır.

$$\hat{\psi}(\omega) = \hat{\psi}_1(\omega_1) \hat{\psi}_2(\omega_2/\omega_1) \quad (4.17)$$

ψ_1 parametresi wavelet ve ψ_2 parametresi ise bump fonksiyonudur.

Ayrık shearlet transformu (discrete) $\mathcal{SH}(f)(\kappa, j, k, m)$ açısıl kırpma (shear), ölçeklendirme (scale) ve çevirme (translation) parametrelerinin aşağıdaki gibi ayrık hale getirilmesi ile elde edilir.

$$\mathcal{SH}(f)(\kappa, j, k, m) := \left\{ \begin{array}{ll} \langle f, \phi_m \rangle & \text{for } \kappa = 0 \\ \langle f, \psi_{j,k,m}^\kappa \rangle & \text{for } \kappa \in \{h, v\} \\ \langle f, \psi_{j,k,m}^{h_{xv}} \rangle & \text{for } \kappa = x, k = 2^j \end{array} \right\} \quad (4.18)$$

$0, \dots, j_0 - 1, -2^j + 1 \leq k \leq 2^j - 1$, ve $m \in I$ [5]

Çalışmamızda omuz MR görüntülerinin herbirine shearlet transformu uygulayarak 2 seviyede (two level) dekompozisyonunu sağlayarak toplam 13 (1 + 4 + 8) alt bant elde ettik. Her bir alt bant için elde edilen katsayılar üzerine histogram aralığı (bin) $K=8$ ve oryantasyon aralığı $[0-360]$, $[0-180]$ belirlenerek PHOG yöntemi ile özellik çıkarıldı.

En iyi sonuç histogram aralığı (bin) $K=8$ ve oryantasyon aralığı $[0-360]$ iken toplam 8840 özellik ile 97.64 olarak özellik sayısı CSF yöntemi ile azaltıldığında 98.23 olarak hesaplandı (Çizelge 4.7).

Çizelge 4.7 Shearlet Transform katsayıları ile PHOG tabanlı şekil özelliklerinin sınıflandırma başarısı ($K=8$, $R=[0,360]$ ve $L=3$).

	Özellik seçiminden önce sınıflandırma başarısı		Özellik seçiminden sonra sınıflandırma başarısı	
	Özellik sayısı	Sınıflandırma başarısı	Özellik sayısı	Sınıflandırma başarısı
PHOG	680	93.52	69	97.05
FDST	8840	97.64	52	98.23

4.5 Şekil ve Doku Özelliklerinin Bir Arada Kullanılmasıyla MR Görüntülerinin Sınıflandırılması

Doku özelliklerini analiz ettiğimizde en iyi sınıflandırma başarısı Hermite transformu ile elde edilen katsayılar üzerinden GLCM tabanlı istatistiksel doku analiz yöntemleri olduğunu saptadık. Bölütlenmesi tamamlanan omuz MR görüntülerinden PHOG metodu ile çıkarılan özellikler doku özellikleri ile bir araya getirilerek önerilen tanı sisteminin başarısı artırılmaya çalışıldı.

PHOG yöntemi ile üç grubun sınıflandırma başarısı histogram aralığı (bin) $K=8$ ve oryantasyon aralığı $[0-360]$ iken % 92.35 iken CSF yöntemi ile özellik sayısı azaltıldığında bu oran % 97.05 olarak değişti. PHOG ve GLCM yöntemlerinden elde edilen sınıflandırma başarısı ise % 94.97 iken özellik sayısı azaltıldığında % 96.80 olarak

hesaplandı. Fakat bu oran PHOG yönteminin tek başına gerçekleştirdiği başarıdan daha da düşüktür. PHOG yönteminin oluşturduğu öznelilik vektörü Hermite tabanlı istatistiksel doku analizi yöntemleri ile birleştirdiğimizde ise sınıflandırma başarısı % 95.43 olarak hesaplandı. CSF yöntemi ile özellik azalttığımızda ise bu başarı oranı % 99.54 olarak SVM yöntemi ile hesaplandı (Çizelge 4.8).

Çizelge 4.8 Hermite tabanlı ikinci dereceden istatistiksel doku, ikinci dereceden istatistiksel doku ve şekil PHOG özelliklerinin farklı sınıflandırıcılar ile sınıflandırma başarısı oranları.

Yöntemler	<u>Özellik seçiminden önce</u> <u>sınıflandırma başarısı %</u>		<u>Özellik seçiminden sonra</u> <u>sınıflandırma başarısı %</u>	
	SVM	Özellik sayısı	SVM	Özellik sayısı
PHOG (K=8, R=[0,180] ve L=3)	91.78	680	96.80	94
PHOG (K=8, R=[0,360] ve L=3)	92.35	680	97.05	69
GLCM + PHOG	94.97	724	96.80	85
Hermite GLCM + PHOG	95.43	812	99.54	82

4.6 Bağımsız Eğitim ve Test Kümelerinin Sınıflandırma Başarıları

Omuz MR görüntüleri ikinci dereceden istatistiksel yöntemler kullanılarak elde edilen doku analizleri ve PHOG yöntemine dayalı şekil özellikleri kullanılarak sınıflandırılmıştır. Sınıflandırma yöntemi olarak SVM, MLP ve KNN algoritmaları uygulanmıştır. Elimizdeki sınırlı sayıdaki veri kullanılarak sistemin hem eğitilmesi hem de başarısının tarafsız olarak ölçülebilmesi gerekmektedir. Bu amaçla 10 kere çapraz doğrulama (cross validation) yöntemi kullanılarak omuz MR görüntüleri Hill-Sachs lezyonlu, ödemli ve normal olarak etiketlendirildi. 10 kez çapraz doğrulama yönteminde veriseti 10 eşit parçaya ayrılır. Her bir iterasyonda veri kümesinin 9/10'luk kısmı eğitim 1/10'luk kısmı test için kullanılır. Her iterasyonda verisetinin farklı bir bölümü eğitim ve test için kullanıldığından bütün verinin eğitim ve test için kullanımı sağlanmış oldu. Sistemin hata oranı ise 10 kez çapraz doğrulama sonucunda elde edilen hata miktarlarının ortalaması alınarak hesaplandı. Çapraz doğrulamanın en önemli avantajı verisetinin bütün örneklerinin eğitim ve test aşamasında kullanılmasıdır.

Omuz MR görüntülerinden elde edilen doku ve şekil özelliklerinin sınıflandırma başarısını ayrıca bağımsız eğitim ve test kümeleri kullanarak analiz ettik. Amacımız çapraz doğrulama yönteminde her bir örneğin eğitim ve test aşamasında kullanılarak ağız ezberlemesine yol açıp açmadığını saptamaktır. Bu amaçla verisetinin %80'ni eğitim %20'si test için ayrıldı. Omuz MR görüntülerinin sınıflandırılması 10 kez rastgele seçilen eğitim ve test örnekleri ile gerçekleştirildi. Önerilen sistemin başarısı ise her bir veri kümesinin sınıflandırma başarılarının ortalaması alınarak hesaplandı (Çizelge 4.9).

Çapraz doğrulama yöntemi ile en başarılı sonuç Hermite transformu tabanlı ikinci dereceden istatistiksel yöntemlerle elde edilen doku analizlerinin PHOG yöntemine dayalı şekil özellikleri ile birleştirilmesi ile %99.54 olarak SVM yöntemi ile hesaplandı. Bağımsız eğitim ve test kümesi kullanıldığında bu başarı oranı % 95.69 olarak hesaplandı. CSF yöntemi ile özellik seçiminden sonra başarı oranı %94.11'e düştü. Sadece PHOG tabanlı şekil özellikleri kullanılarak sistemin sınıflandırma başarısı % 91.02 iken CSF yöntemi ile özellik indirgemediği sonra %95.34 olarak hesaplandı. GLCM tabanlı doku ve PHOG tabanlı şekil özellikleri kullanılarak gerçekleştirilen sınıflandırma başarısı ise % 94.78 olarak hesaplandı.

Çizelge 4.9 Rastgele seçilen bağımsız 10 farklı veri seti üzerinde SVM metodu ile farklı doku ve şekil özelliklerin sınıflandırma başarılarının analiz sonuçları.

VERİSETİ	<u>Özellik seçiminden önce</u> <u>sınıflandırma başarısı %</u>			<u>Özellik seçiminden sonra</u> <u>sınıflandırma başarısı %</u>		
	PHOG	GLCM+ PHOG	Hermite GLCM + PHOG	PHOG	GLCM+ PHOG	Hermite GLCM + PHOG
1	88.24	93.18	95.45	94.12	95.45	90.91
2	88.57	93.33	95.56	94.29	91.11	93.33
3	97.06	93.02	95.35	97.06	95.35	95.35
4	97.14	95.45	97.73	100	95.45	90.91
5	91.18	93.18	90.91	94.12	93.18	90.91
6	85.71	95.56	95.56	97.14	91.11	91.11
7	91.18	95.45	97.73	91.18	95.45	95.45
8	91.43	95.45	95.45	94.29	97.73	97.73
9	88.24	97.67	97.67	94.12	97.67	97.67
10	91.43	95.45	95.45	94.14	93.18	97.73
Ortalama	91.02	94.78	95.69	95.34	94.57	94.11

BÖLÜM 5

SONUÇ VE ÖNERİLER

Klinik çalışmalar sonucu humerus başı lezyonlarının incelenmesinde PD ağırlıklı iki boyutlu aksiyal kesitlerin uygun olduğuna karar verilmiştir. PD ağırlıklı görüntüler ağrıya neden olan ödem bulgusunu açıklayabilir ve Hill-Sachs lezyonu hakkında bilgi verebilmektedir. Diğer görüntüleme modalitelerine (BT, T1 ağırlıklı MR) göre PD ağırlıklı MR görüntüleri yumuşak dokuyu gösterebilme kabiliyetine sahiptir. Fakat PD ağırlıklı MR görüntüleri ile bölütleme çalışmasını yapmak diğer modalitelere göre dört önemli nedenden dolayı daha güçtür. Birincisi, T1 ağırlıklı MR ve BT görüntülerine göre PD ağırlıklı görüntüler daha fazla gürültü içerirler. İkincisi, PD ağırlıklı MR görüntüleri yumuşak dokuları detaylı olarak gösterir ve bu dokular arasında geçişler oldukça yumuşaktır. Üçüncüsü, humerus başında ödem yoğunluk değerinde artış olarak görülür. Ödemin yeri ve büyüklüğü hastaya göre değişmektedir. Son olarak, Hill-Sachs lezyonu omuzda meydana gelen çökme kırığıdır, dolayısıyla humerus başının anatomik yapısı da değişmektedir. PD ağırlıklı omuz görüntülerinde bu kısıtlar hem bilgisayarla hem de gözle bölütlemeyi zorlaştırmaktadır. Ancak ağrıya neden olan ödem bulgusunu açıklayabilme ve Hill-Sachs lezyonu hakkında bilgi verebilme özelliğinden dolayı PD ağırlıklı MR görüntüleme bu alanda özellikle tercih edilmektedir.

Yapılan uygulamalar sonucu, görüntüye ön işlem uygulanmadığı durumda ACWE ve SPF metotları T1 ağırlıklı MR görüntülerinden humerus başını oldukça iyi şekilde

bölütleyebilirken PD ağırlıklı görüntülerden humerus başını bölütleyememektedir. Gürültünün standart sapma değerini omuz bölgesinden otomatik olarak hesaplanarak görüntüdeki gürültü giderilmiş ve SRAD yönteminin kullanım alanına MR görüntüleri de eklenerek genişletilmiştir. SRAD ve homomorfik filtre ile görüntüde homojenlik sağlandıktan sonra humerus başı PD ağırlıklı MR görüntülerinden ACWE yöntemi ile başarıyla bölütlenebilmiştir. Bu yöntemin başarısını literatürde yaygın olarak kullanılan SPF metot, GMM ,Fuzzy C-Means metotları ve uzman kişinin elle gerçekleştirdiği bölütleme sonuçları ile karşılaştırılmıştır.

ACWE yönteminin en büyük kısıtlarından olan başlangıç konturunun yerinin belirlenmesi çalışmamızda otomatik olarak dairesel Hough transformuyla gerçekleştirilmiştir. Çalışmada kullanılan omuz MR görüntüleri hasta kişilerden alınmıştır, bu durum kullandığımız veri setindeki görüntü kalitesini düşürmüştür. Çalışmanın bir diğer kısıtı ise manuel segmentasyonun fare yardımıyla yapılmasıdır. Humerus başının kenar kıvrımlarının fare yardımıyla çizilebilmesi mümkün olmamıştır. Bu durum hem kontrol veri setinin kalitesini hemde segmentasyon başarısını negatif olarak etkilemiştir. Fakat belirlenen kısıtlara rağmen ACWE yöntemi ile yapılan segmentasyon başarısı PD ağırlıklı görüntüler için oldukça yüksektir.

Çalışmamızda humerus başı bölütleme işlemini tamamladıktan sonra şekil ve doku özellikleri çıkarılmıştır. Humerus başında meydana gelen lezyonları saptamakta tek başına şekil ya da doku özelliklerinin kullanılmasının yeterli olmadığı görülmüştür. Humerus başında bulunan ödem aynı zamanda Hill-Sachs lezyonlu humerus başlarında genelde görülmektedir. Doku analiz yöntemlerinden ikinci dereceden istatistiksel yöntemlerle GLCM matrisi üzerinden doku özellikleri farklı öteleme (offset) değerleri ile simetrik ve asimetrik olarak çıkarıldı. Simetrik yöntemin başarısının yüksek olduğu saptandıktan sonra wavelet tabanlı transformlar ve Hermite transformu kullanılarak doku özellikleri hem uzaysal hem de frekans alanından çıkarılarak GLCM tabanlı doku analizinin performansı artırıldı. Çizelge (5.1) de gösterildiği gibi Hermit transformuna dayalı GLCM tabanlı doku analizi yöntemi diğer önerilen curvelet, contourlet tabanlı doku analiz yöntemlerinden daha başarılı bulunmuştur. Curvelet transformu tabanlı doku analizi, GLCM tabanlı yöntemle göre hassasiyet (sensitivity), belirginlik (specificity) ve doğruluk (accuracy) parametrelerine göre % 1-2 ,% 4-5ve % 0-2 oranında SVM ve MLP

sınıflandırıcılarıyla daha başarılı olduğu saptanmıştır. Curvelet tabanlı doku analizi, contourlet tabanlı doku analiz yöntemini hassasiyet, belirginlik ve doğruluk ve parametrelerine göre % 1, % 0-1 ve % 1-3 oranında humerus başını sınıflandırma başarısı MLP ve SVM metodları kullanıldığında geçmiştir. Bunun nedeni ise contourlet transformunda özellikle Laplacian piramitten gelen fazlalıktır (redundancy). Çok yönlülük ve çok çözünürlük gibi önemli özellikleri olmasına rağmen eş yönsüz ve yumuşak eğrileri gereğinden fazla parametrelerle tanımlamaktadır.

Çizelge 5.1 Önerilen doku analiz yöntemlerinin farklı sınıflandırıcılarla hassasiyet, belirginlik ve doğruluk parametreleri ile karşılaştırılması olarak analizi.

	Farklı doku analizleri için sınıflandırma başarıları					
	Doku Özellikleri	MLP	SVM	KNN 1	KNN 3	KNN 5
Hassasiyet	GLCM (d=12)	91.46	90.69	91.35	90.58	89.53
	Curvelet (d=8)	96.25	96.38	89.41	90.58	86.51
	Contourlet (d=8)	94.87	96.20	90.12	93.58	93.67
	Hermite (d=8)	97.50	96.25	93.67	93.82	93.82
Belirginlik	GLCM (d=12)	95.45	98.80	94.38	97.64	97.61
	Curvelet (d=8)	97.77	97.77	96.47	97.64	97.56
	Contourlet (d=8)	94.56	96.70	93.25	93.47	94.50
	Hermite (d=8)	98.88	97.77	94.50	96.62	96.62
Doğruluk	GLCM (d=12)	93.52	94.70	92.94	94.11	93.52
	Curvelet (d=8)	95.29	97.05	92.94	94.11	92.35
	Contourlet (d=8)	94.70	96.47	91.76	93.52	94.11
	Hermite (d=8)	98.23	97.05	94.11	95.29	95.29

Hermite transformu, curvelet ve contourlet transformu gibi yumuşak eğrileri tanımlamakta oldukça başarılı bir yöntemdir. Hermite transformu, wavelet tabanlı (curvelet, contourlet, shearlet) dönüşümlerinin sağlayamadığı orthogonallik ve yerel lokasyon özelliği ile eşyönsüz özellikleri görüntünün ana yapısını bozmadan sağlayabilmektedir. Diğer bir avantajı ise Gaussian filtreler ayrılabilir özellikte olduğu için uygulanabilirliği (implementation) özellikle curvelet transformına göre çok daha kolaydır.

Hermite transformu görüntüde gürültü giderimi, görüntü füzyonu ve görüntüde kenar bulma gibi alanlarda kullanılmasına rağmen Hermite katsayıları üzerinden doku analizi çalışmalarına literatürde rastlanılmamıştır. Hermite transformu yöntemiyle ikinci

dereceden istatistiksel yöntemlerle doku analizini PD görüntüleri üzerinde uygulama bakımından çalışmamız özgündür.

Şekil özelliklerini analiz etmek için görüntü şekillerini yerel ve düzenini uzaysal olarak tanımlayan PHOG yönteminden yararlanıldı. PHOG yöntemi görüntü analizinde yaygın kullanım alanı olmasına rağmen medikal görüntülerde oldukça az sayıda çalışmada kullanılmıştır. PHOG yöntemi ile veri setimizden çıkarılan özneliklerle normal ödemli ve Hill-Sachs lezyonlu humerus başları olarak sınıflandırdığımızda % 92.35 oranında SVM metodu ile başarı elde edildi. Özellik seçiminden sonra sınıflandırma başarısı % 97.05 olarak hesaplandı. PHOG ve GLCM özellikleri bir arada kullanıldığında sınıflandırma başarısı % 96.80 olarak belirlendi. Bu başarı oranı PHOG yönteminin sınıflandırma başarısından düşüktür. Fakat Hermite transform tabanlı GLCM yöntemi ile doku özelliklerini PHOG yöntemi ile elde edilen şekil özellikleri ile birleştirdiğimizde başarı oranı % 99.54 olarak SVM metodu ile hesaplandı.

Veri setimizde yer alan 219 PD ağırlıklı görüntülerden sadece bir tanesinde yanlış sınıflandırma olmuştur. Normal humerus başı görüntüsü ödemli olarak sınıflandırılmıştır. Önerilen bilgisayar destekli omuz lezyonlarını tanıma sistemimiz kullanılan veri seti bakımından orijinaldir ve sistemin başarısı ümit vericidir.

KAYNAKLAR

-
- [1] Chaui J. , Hamitouche C., Stindel E. ve Roux C., (2011). “Recognition Based Segmentation and Registration Method For Image Guided Shoulder Surgery”, 33rd Annual International Conference of the IEEE EMBS
 - [2] Perez G., Garamendi J.F. , R. ve Montes Diez E., (2008).“MRI Shoulder Complex Segmentation and Classification”, International Joint Conference.
 - [3] Tremblay M., Albu A. ve Hebert L., (2004). “Integraing Region and Edge Information for the automatic Segmentation of Interventional Magnetic Resonance Images of the Shoulder Complex”, Proceedings of the Canadian Conference on Computer and Robot Vision.
 - [4] Köse C., Gençalioğlu O. ve Şefik U. (2009). “An automatic diagnosis method for the knee meniscus tears in MR images”, Expert Systems with Applications.
 - [5] Swanson M.S., Prescott J.W. ve Best T.M. Best, (2010). “Semi automated to asses the lateral meniscus in normal and osteoarthritic knees”, Osteoarthritis and Cartilage,
 - [6] Ramakrishna B. ve Liu, W. Ganesh Saiprasad, (2009). ” An automatic computer-aided detection system for meniscal tears on magnetic resonance images” IEEE transaction on medical imaging 28 (8)
 - [7] Waterton J., Solloway S., Foster J., Keen M., Gandy S., Middleton B., Maciewicz R., Watt I., Dieppe P., ve Taylor C., (2000).“Diurnal variation in the femoral articular cartilage of the knee in young adult humans,” Magn. Reson. Med., 43:126–132.
 - [8] Fripp J., Bourgeat P., Crozier S., ve Ourselin S., (2007). “Segmentation of the bones in MRIs of the knee using phase, magnitude, and shape information,” Acad. Radiol., 14(10):1201–1208, Oct.
 - [9] Tang J., Millington S., S. Acton T., Crandall J. ve Hurwitz S., (2006). “Surface extraction and thickness measurement of the articular cartilage from MR images using directional gradient vector flow snakes,” IEEE Trans. Biomed. Eng., vol. 53(5):896–907.
 - [10] T.Stammberger, F. Eckstein, K. Englmeier ve M. Reiser, (1999). “Determination of 3D cartilage thickness data fromMRimaging: Computational method and reproducibility in the living,” Magn. Reson. Med., 41:529–536.

- [11] Folkesson J., Dam E., Olsen O. ve Pettersen P., (2005). "Automatic Segmentation of the Articular Cartilage in Knee MRI using a Hierarchical Multi class Classification Scheme", MICCAI Springer Verlag Berlin Heidelberg, 327-334.
- [12] Folkesson J., Dam E., Olsen O. ve Pettersen P., (2005). "Combining Binary Classifiers for Automatic Cartilage Segmentation in knee MRI", LNCS 3765: 230-239.
- [13] Ho J. H., Sheah K. ve Tjoen D. T., (2010). "Anterior Cruciate Ligament Segmentation using Morphological Operations with Active Contour", Bioinformatics and Biomedical Engineering (iCBBE), 2010 4th International Conference on IEEE,
- [14] Ghosh S., Beuf L. O., Ries M., Lane N. E. ve Steinbach L. S., (2000). "Watershed segmentation of high resolution magnetic resonance images of articular cartilage of the knee", Proc. of the 22nd Int. Conf. Annual EMBS, 3174-3176.
- [15] Grau V., Mewes A. U. J., Alcañiz M., Kikinis R., ve Warfield S. K., (2004) "Improved watershed transform for medical image segmentation using prior information", IEEE Trans. on Medical Imaging, 23(4):447-458.
- [16] Folkesson J., Dam E., Olsen O., Pettersen P., ve Christiansen C., (2007) "Segmenting articular cartilage automatically using a voxel classification approach", IEEE Trans. on Medical Imaging, 26(1):106-115, 2007.
- [17] Tejos C., Laurance D. Hall, ve Cárdenas-Blanco A., (2004). "Segmentation of articular cartilage using active contours and prior knowledge", Proc. of the 26th Annual Int. Conf. of the IEEE EMBS, San Francisco, CA, USA 1648-1651.
- [18] Tang J., Millington S., Scott T. Acton, Crandal J. I., ve Hurwitz S., (2006). "Surface extraction and thickness measurement of the articular cartilage from MR images using directional gradient vector flow snakes", IEEE Trans. on Biomedical Engineering, 53(5):896-907.
- [19] Hussain Z. Tameem, Luis E. Selva, ve Usha S. Sinha, (2007). "Morphological atlases of knee cartilage: shape indices to analyze cartilage degradation in osteoarthritic and non-osteoarthritic population", Proc. of 29th Annual Int. Conf. of the IEEE EMBS, Cité Internationale, Lyon, France, 1310-1313.
- [20] Sofia K. Michopoulou, Elias Panagiotopoulos ve Speller R., (2009). "Atlas based segmentation of degenerated Lumbar intervertebral discs from images of the spine", IEEE Trans. on Biomedical Engineering, 56(9)
- [21] Lippitt S ve Matsen F.A., (1993) "Mechanisms of glenohumeral joint instability". Clin Orthop ;291: 20-28,
- [22] Kazar B. ve Relovszky E., (1969). "Prognosis of primary dislocation of the shoulder". Acta Orthop Scand; 40(2):216-24
- [23] Cooper DE., Arnoczky SP., O'Brien SJ., Warren RF., DiCarlo E. ve Allen AA.: (1992). "Anatomy, histology and vascularity of the glenoid labrum". J Bone Joint Surg, 74 :46-52

- [24] Eve FS., (1880). "A case of subcoracoid dislocation of the humerus with the formation of an indentation on the posterior surface of the head". *Medico-Chirurg Trans Soc Lond* , 63:317-321
- [25] Warner JJ., Deng XH., Warren RF. ve Torzilli PA., (1992)"Static capsuloligamentous restraints to superior-inferior translation of the glenohumeral joint".*Am J Sports Med*, 20: 675-85.
- [26] Krissian K. ve Fenandez S.A. (2009). Noise driven anisotropic diffusion filtering of MRI. *IEEE Transactions on Image Processing*. 18(10):.2265 – 2274
- [27] Perona P. ve Malik J., (1990). "Scale –space and edge detection using anisotropic diffusion." *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 12(7):629-639.
- [28] Yongjian Y.ve Acton S.T., (2002). "Speckle reducing anisotropic diffusion". *IEEE Transactions on Image Processing*, 11(11):1260-1270.
- [29] Yoo B.C., Ryu J.G., Park H.K. ve Nishimura T.H. (2008). " Multi-scale based adaptive SRAD for ultrasound images enhancement". *World Congress on Engineering and Computer Science*. 2008, 258-266
- [30] Liu G., Zeng X., Tian F., Li Z. ve Chaibou K., (2009), "Speckle reduction by adaptive window anisotropic diffusion". *Signal Processing*, 89(11):2233-2243.
- [31] Li C., Xu C., Gui C. ve M. Fox, (2005). "Level set evolution without re-initialization: a new variational formulation", in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, San Diego, 430–436
- [32] N. Paragios ve R. Deriche. (2000). "Geodesic active contours and level sets for detection and tracking of moving objects. *IEEE Transaction on Pattern Analysis and Machine Intelligence*", 22, 2000, 1–15.
- [33] Chan T.F. ve Vese. L.A. (2001) "Active contours without edges". *IEEE Transactions on Image Processing Issue 2*: 266-277
- [34] Tsai A., Yezzi A. ve Willsky A. (2001)"Curve evolution implementation of the Mumford –Shah functional for image segmentation, denoising, interpolation and magnification. " *IEEE Transaction on Image Processing* 10 (8):1169-1186
- [35] Mumford D., ve Shah J., (1989)."Optimal approximation by piecewise smooth function and associated variational problems" *Communication on Pure and Applied Mathemetics* 42 577-685.
- [36] Vese L. ve Chan T. (2002) Multiphase level set framework for image segmentation using the Mumford Shah model. *International Journal of Computer vision* 50 (3): 271-293
- [37] Cremers ve Daniel, (2002). "Diffusion snakes: Introducing statistical shape knowledge into the Mumford-Shah functional. *International journal of computer vision*", 50: 295-313.
- [38] Li C., Kao C., Gore J.ve Ding Z., (2008). " Minimization of region-scalable fitting energy for image segmentation", *IEEE Transactions on Image Processing*. 17 (10): 1940–1949.

- [39] Ni K., Bresson X. ve Chan T. ve Esedoglu S.. (2009). “ Local histogram based segmentation using the Wasserstein distance”. International Journal of Computer Vision. 97–111.
- [40] Kim J., Fisher III J.W. ve Yezzi A., (2005). “A nonparametric statistical method for image segmentation using information theory and curve evolution”, IEEE Transactions on Image Processing 14 (10) :1486–1502
- [41] Ge Q., Xiao L., Zhang J. ve Wei Z.H.. (2012). “ An improved region based model with local statistical features for image segmentation”. Pattern Recognition. 45: 1578-1590.
- [42] Wang L., Li C., Sun Q., Xia D. ve Kao C. Y., (2009). “Active contours driven by local and global intensity fitting energy with application to brain MR image segmentation”, Computerized Medical Imaging and Graphics 33, 2009, 520–531
- [43] Liu T., Xu H., Jin W., Liu Z., Zhao Y., ve Tian W. (2014). “Medical Image Segmentation Based on a Hybrid Region-Based Active Contour Model,” Computational and Mathematical Methods in Medicine. 2014, Article ID 890725
- [44] Akram F., Kim J. H., Lim H. U., ve Choi K. N., (2014), “Segmentation of Intensity Inhomogeneous Brain MR Images Using Active Contours”, Computational and Mathematical Methods in Medicine 2014 , Article ID 194614, 14
- [45] Zhang K., Zhang L., Song H. ve Zhou W. (2010). ” Active contours with selective local or global segmentation: A new formulation and level set method”. Image and Vision Computing. 28: 668-676
- [46] Xu H., Liu T., ve Wang G., (2014). “ Hybrid geodesic region-based active contours for image segmentation”, Computers and Electrical Engineering, vol. 40, 2014(3): 858–869
- [47] Liu S. ve Peng Y.(2012). ” A local region based Chan-Vese model for image segmentation. Pattern Recognition”. 45, pp 2769-2779.
- [48] Huang, Y., Englehart, K. B., Hudgins, B., ve Chan, A. D. (2005). A Gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses. Biomedical Engineering, IEEE Transactions on, 52(11): 1801-1811.
- [49] Nguyen N.T., Laurendeau D. ve A.B. Albu, (2007). “A new segmentation method for MRI images of the shoulder joint” Computer and Robot Vision, Fourth Canadian Conference., 329-338.
- [50] Morar A. ve Moldoveanu F., (2012). ”Image segmentation based on active contours without edges”, In IEEE International Conference on Intelligent Computer Communication and Processing, 213-220.
- [51] Chaoui J., Hamitouche C. ve Stindel E., (2011). ”Recognition based segmentation and registration method for image guided surgery”, In IEEE, Engineering in Medicine and Biology Society, 6212-6215.

- [52] Vovk U., Pernus F. ve Likar B. (2007). "A review of methods for correction of intensity inhomogeneity in MRI". *IEEE Transactions on Medical Imaging*. 26(3): 405-421.
- [53] Gonzalez R.C., ve Woods R.E. (2002). "Digital image processing". Prentice Hall.
- [54] Farnoosh R. ve Zarpak B. (2008). "Image segmentation using Gaussian mixture model". *International Journal of Engineering Science*. 19, (1-2): 29-32
- [55] Chuang K.S., Tzeng H.L., Chen S., Wu J. ve Chen T. (2006). "Fuzzy c-means clustering with spatial information for image segmentation". *Computerized Imaging and Graphics*. 30:9-15
- [56] Srinivasan, E. M., Ramar, K., ve Suruliandi, A. (2011). "Texture analysis using local texture patterns: a fuzzy logic approach". *International Journal of Pattern Recognition and Artificial Intelligence*, 25(05):741-762.
- [57] Thibault, G., Fertil, B., Navarro, C., Pereira, S., Cau, P., Levy, N., ve Mari, J. L. (2013). Shape and texture indexes application to cell nuclei classification. *International Journal of Pattern Recognition and Artificial Intelligence*, 27(01): 1357002
- [58] Bharati M.H., Liu J.J ve MacGregor J.F, (2004). "Image texture analysis: methods and comparisons". *Chemometrics and Intelligent Laboratory Systems* 72:57–71.
- [59] Honeycutt C. E.ve Plotnick, R. (2008). "Image analysis techniques and gray-level co- occurrence matrices (GLCM) for calculating bioturbation indices and characterizing biogenic sedimentary structures." *Computers & Geosciences*, 34:1461–1472.
- [60] Doyle S., Hwang M., Shah K., Madabhushi A., Feldman M., ve Tomaszewski J., . (2007). "Automated grading of prostate cancer using architectural and textural image features," in *ISBI*, 1284–1287.
- [61] Xian G.. (2010). "An identification method of malignant and benign liver tumors from ultrasonography based on GLCM texture features and fuzzy SVM." *Expert Systems with Application*, .37:6737–6741.
- [62] Yu H., Caldwell C., Mah K. ve Mozeg D., (2009). "Coregistered FDG PET/CT-based textural characterization of head and neck cancer for radiation treatment planning", *IEEE Transactions on Medical Imaging* 28 : 374–383.
- [63] Liu, B., Cheng, H. D., Huang, J., Tian, J., Tang, X., ve Liu, J. (2010). "Fully automatic and segmentation-robust classification of breast tumors based on local texture analysis of ultrasound images". *Pattern Recognition*, 43(1): 280-298.
- [64] Sertel O., Kong J., Shimada H., Catalyurek U., Saltz J., ve Gurcan M. N., (2009) "Computer-aided prognosis of neuroblastoma on whole-slide images: Classification of stromal development," *Pattern Recognition*., 42: 1093–1103.
- [65] Korchiyne, R., Farssi, S. M., Sbihi, A., Touahni, R., ve Alaoui, M. T. (2014). "A Combined Method Of Fractal And GLCM Features For MRI And CT Scan Images Classification". *arXiv preprint arXiv:1409.4559*.

- [66] Zhang, J., Tong, L., Wang, L., ve Li, N. (2008). "Texture analysis of multiple sclerosis: a comparative study". *Magnetic resonance imaging*, 26(8):1160-1166.
- [67] Zhou, S., Shi, J., Zhu, J., Cai, Y., ve Wang, R. (2013). "Shearlet-based texture feature extraction for classification of breast tumor in ultrasound image. *Biomedical Signal Processing and Control*", 8(6):688-696.
- [68] González-Castro, V., Alegre, E., García-Olalla, O., García-Ordás, D., García-Ordás, M. T., ve Fernández-Robles, L. (2012). "Curvelet-based texture description to classify intact and damaged boar spermatozoa". In *Image Analysis and Recognition* 448-455. Springer Berlin Heidelberg.
- [69] Dettori, L., ve Semler, L. (2007). "A comparison of wavelet, ridgelet, and curvelet-based texture classification algorithms in computed tomography". *Computers in Biology and Medicine*, 37(4): 486-498.
- [70] Reddy, T. Kalpalatha, ve N. Kumaravel. (2011). "A comparison of wavelet, curvelet and contourlet based texture classification algorithms for characterization of bone quality in dental CT". *Proceedings of International Conference on Environmental, Biomedical and Biotechnology, IPCBEE*. 16.
- [71] Eltoukhy, M. M., Faye, I., ve Samir, B. B. (2010). "A comparison of wavelet and curvelet for breast cancer diagnosis in digital mammogram". *Computers in Biology and Medicine*, 40(4):384-391.
- [72] Eltoukhy, M. M., Faye, I., ve Samir, B. B. (2010). "Breast cancer diagnosis in digital mammogram using multiscale curvelet transform". *Computerized Medical Imaging and Graphics*, 34(4): 269-276.
- [73] Candes, E. J., ve Donoho, D. L. (2000). "Curvelets, multiresolution representation, and scaling laws". In *Proc. SPIE* 4119 (1):1-2
- [74] Candes, E., Demanet, L., Donoho, D., ve Ying, L. (2006). "Fast discrete curvelet transforms". *Multiscale Modeling & Simulation*, 5(3):861-899.
- [75] Martens, J. B. (2006). "The Hermite transform: a survey. *EURASIP journal on applied signal processing*", 2006, 97-97.
- [76] Cruz-Techica, S., ve Escalante-Ramirez, B. (2011). "Image fusion algorithm using the multiresolution directional-oriented hermite transform". In *Pattern Recognition* (202-210). Springer Berlin Heidelberg.
- [77] Ma, J., ve Plonka, G. (2010). "The curvelet transform". *Signal Processing Magazine, IEEE*, 27(2):118-133.
- [78] Häuser, S., ve Steidl, G. (2013). "Convex multiclass segmentation with shearlet regularization". *International Journal of Computer Mathematics*, 90(1): 62-81.
- [79] Olveres, J., Nava, R., Moya-Albor, E., Escalante-Ramírez, B., Brieva, J., Cristóbal, G., ve Vallejo, E. (2014). "Texture descriptor approaches to level set segmentation in medical images". In *SPIE Photonics Europe* 91380J-91380J. International Society for Optics and Photonics.
- [80] Estudillo-Romero, A., ve Escalante-Ramirez, B. (2011). "Classification of low level visual texture features based on the hermite transform". In *Signal-Image*

Technology and Internet-Based Systems (SITIS), 2011 Seventh International Conference on 461-467 IEEE.

- [81] Bosch, A., Zisserman, A., ve Munoz, X. (2007). "Representing shape with a spatial pyramid kernel". In Proceedings of the 6th ACM international conference on Image and video retrieval 401-408. ACM.
- [82] Dhall, A., Asthana, A., Goecke, R., ve Gedeon, T. (2011). "Emotion recognition using PHOG and LPQ features". In Automatic Face & Gesture Recognition and Workshops , 2011 IEEE International Conference on 878-883. IEEE.
- [83] Zhao, C., Zhang, X., Zhang, B., Dang, Q., ve Lian, J. (2013). "Driver's fatigue expressions recognition by combined features from pyramid histogram of oriented gradient and contourlet transform with random subspace ensembles". IET Intelligent Transport Systems, 7(1): 36-45.
- [84] Bai, Y., Guo, L., Jin, L., ve Huang, Q. (2009). "A novel feature extraction method using pyramid histogram of orientation gradients for smile recognition". In Image Processing (ICIP), 2009 16th IEEE International Conference on 3305-3308. IEEE.
- [85] Rezaeilouyeh, H., Mahoor, M. H., Mavadati, S. M., ve Zhang, J. J. (2013). "A Microscopic Image Classification Method Using Shearlet Transform". In Healthcare Informatics (ICHI), 2013 IEEE International Conference on 382-386. IEEE.
- [86] Ou-Yanga, J., Huangb, P. J., Huangc, T. K., ve Leea, H. J. (2013). "Breast Lesions Analysis Using Kinetic and Pyramid Spatial Features in Dynamic Contrast Enhanced MRI". 1st IEEE/IIAE International Conference on Intelligent Systems and Image Processing
- [87] Oktay, A. B., ve Akgul, Y. S. (2011). "Localization of the lumbar discs using machine learning and exact probabilistic inference". In Medical Image Computing and Computer-Assisted Intervention–MICCAI 2011 158-165. Springer Berlin Heidelberg.
- [88] Sheikh, A. R., Lye, M. H., Mansor, S., Fauzi, M. F. A., ve Anuar, F. M. (2011). "A content based image retrieval system for marine life images". In Consumer Electronics (ISCE), 2011 IEEE 15th International Symposium on 29-33 IEEE.
- [89] Zheng, Y., Shen, C., Hartley, R., ve Huang, X. (2011). "Pyramid center-symmetric local binary/trinary patterns for effective pedestrian detection". In Computer Vision–ACCV 2010 281-292. Springer Berlin Heidelberg.
- [90] Sezer, A., Sezer, H. B., ve Albayrak, S. (2015). "An Identification Method of Normal and Edematous Humeral Head from PD Weighted MR Images Based on GLCM Texture Features". International Conference on Medical, Biological and Pharmaceutical Sciences (ICMBPS)
- [91] Do, M. N., ve Vetterli, M. (2005). "The contourlet transform: an efficient directional multiresolution image representation". Image Processing, IEEE Transactions on, 14(12): 2091-2106.

- [92] Da Cunha, A. L., Zhou, J., ve Do, M. N. (2006). "The nonsubsamped contourlet transform: theory, design, and applications". Image Processing, IEEE Transactions on, 15(10):3089-3101.
- [93] Emrich, T., Graf, F., Kriegel, H. P., Schubert, M., Thoma, M., ve Cavallaro, A. (2010). "CT slice localization via instance-based regression". In SPIE Medical Imaging (762320-762320). International Society for Optics and Photonics.
- [94] He, J., Ji, H., ve Yang, X. (2013)." Rotation invariant texture descriptor using local shearlet-based energy histograms". Signal Processing Letters, IEEE, 20(9): 905-908.
- [95] Schwartz, W. R., da Silva, R. D., Davis, L. S., ve Pedrini, H. (2011). "A novel feature descriptor based on the shearlet transform". In Image Processing (ICIP), 2011 18th IEEE International Conference on 1033-1036 IEEE.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Aysun SEZER

Doğum Tarihi ve Yeri : 10.03.78 MUT

Yabancı Dili : İngilizce

E-posta : sezeraysun@gmail.com

ÖĞRENİM DURUMU

Derece	Üniversite	Alan	Mezuniyet Yılı
Yüksek Lisans	Galatasaray Üniversitesi	Endüstri Mühendisliği	2007-2009
Yüksek Lisans	Haliç Üniversitesi	Bilgisayar Mühendisliği	2006-2008
Lisans	İstanbul Kültür Üniversitesi	Endüstri Mühendisliği	2000-2006
Lisans	İstanbul Kültür Üniversitesi	Bilgisayar Mühendisliği	2000-2005

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2009-2015	Yıldız Teknik Üniversitesi Bilgisayar Mühendisliği	Araştırma Görevlisi
2006-2009	Haliç Üniversitesi Bilgisayar Mühendisliği	Araştırma Görevlisi

YAYINLARI

Makale

1. Sezer, Aysun, Hasan Basri Sezer, and Songul Albayrak. (2015). Segmentation of Bone with Region Based Active Contour Model in PD Weighted MR Images of Shoulder. Computational and Mathematical Methods in Medicine, 2015.

Bildiri

1. Sezer, Aysun, Hasan Basri Sezer, and Songul Albayrak (2015). Classification of bone pathologies with finite discrete shearlet transform based shape descriptors. The fifth International Conference on Image Processing Theory, Tools and Applications IPTA'15
2. Sezer, Aysun, Hasan Basri Sezer, and Songul Albayrak. (2015). Segmentation of humeral head from axial proton density weighted shoulder MR images. Tenth International Symposium on Medical Information Processing and Analysis. International Society for Optics and Photonics.
3. Sezer, Aysun, Hasan Basri Sezer, and Songul Albayrak. (2015). An Identification Method of Normal and Edematous Humeral Head from PD Weighted MR Images Based on GLCM Texture Features. International journal of advance computational engineering and networking volume3 issue 6
4. Sezer, Aysun, Hasan Basri Sezer, and Songul Albayrak. (2014). Segmentation of humeral head from MR slices. Signal Processing and Communications Applications Conference (SIU), 2014 22nd. IEEE.