

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

**MR GÖRÜNTÜLERİNDE MENİSKÜSLERİN SEGMENTASYONU VE
MENİSKÜS YIRTIKLARININ TESPİTİ**

AHMET SAYGILI

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

**DANIŞMAN
DOÇ. DR. SONGÜL ALBAYRAK**

İSTANBUL, 2017

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MR GÖRÜNTÜLERİNDE MENİSKÜSLERİN SEGMENTASYONU VE
MENİSKÜS YIRTIKLARININ TESPİTİ**

AHMET SAYGILI tarafından hazırlanan tez çalışması 24.11.2017 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. Çiğdem EROĞLU ERDEM
Marmara Üniversitesi




Prof. Dr. Nizamettin AYDIN
Yıldız Teknik Üniversitesi



Doç. Dr. Mine Elif KARSLIGİL
Yıldız Teknik Üniversitesi



Doç. Dr. Mustafa Ersel KAMAŞAK
İstanbul Teknik Üniversitesi



Doç. Dr. Songül ALBAYRAK
Yıldız Teknik Üniversitesi



Bu çalışma 116E151 proje numarası ile Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından desteklenmiştir.

ÖNSÖZ

Bu tez çalışmasında, MR görüntüleri üzerinde menisküs dokularının otomatik olarak bölütlenmesi ve menisküs yırtıklarının tespit edilmesi amaçlanmıştır.

Tez sürecim boyunca kıymetli bilgileri ve yapıcı eleştirileri ile beni yönlendiren Doç. Dr. Mine Elif KARSLIGİL'e ve Doç. Dr. Mustafa Ersel KAMAŞAK'a, her konuda beni aydınlatan ve bana yol gösteren, güler yüzünü hiç esirgemeyen danışman hocam Doç. Dr. Songül ALBAYRAK'a, çalışmalarım süresince desteklerini esirgememiş olan çalışma arkadaşlarım Yrd. Doç. Dr. Heysem KAYA, Arş. Gör. İlhan KEKLİK ve Arş. Gör. Dr. Selçuk POYRAZ'a sonsuz teşekkürlerimi ve şükranlarımı sunarım.

Yaşamım boyunca desteklerini, sevgilerini ve dualarını esirgemeyen çok kıymetli anneme ve babama ayrı ayrı sonsuz teşekkürler ediyorum. Doktoranın zorlu ve stresli sürecinde her zaman bana destek olan sevgili eşime teşekkürlerimi sunuyorum. Son olarak moral ve motivasyonumun en üst seviyede olmasını sağlayan biricik oğluma teşekkür ediyorum.

Kasım, 2017

Ahmet SAYGILI

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ.....	viii
KISALTMA LİSTESİ.....	ix
ŞEKİL LİSTESİ.....	xi
ÇİZELGE LİSTESİ	xiii
ÖZET	xv
ABSTRACT.....	xvii
BÖLÜM 1	
GİRİŞ.....	19
1.1 Literatür Özeti.....	21
1.2 Tezin Amacı.....	29
1.3 Hipotez.....	31
BÖLÜM 2	
DİZ EKLEMİ VE DİZİN ANATOMİK YAPISI.....	32
2.1 Diz Eklemine Oluşturan Yapılar	32
2.1.1 Kemikler	34
2.1.2 Bağlar (Ligamentler)	34
2.1.3 Tendonlar	35
2.1.4 Kıkırdaklar.....	35
2.1.5 Kaslar	36
2.1.6 Eklem Kapsülü	36
2.1.7 Bursalar	36
2.2 Diz Eklemi Rahatsızlıkları	36
2.2.1 Osteoartrit	37
2.2.2 Menisküs Yırtıkları	39
BÖLÜM 3	

MANYETİK REZONANS GÖRÜNTÜLEME (MRG)	45
3.1 MRG'nin Temelleri	45
3.1.1 Sinyal Üretimi	46
3.1.2 MRG'de Uyarım Dizileri	47
3.2 Diz Eklemine Manyetik Rezonans Görüntüleme	49
3.3 Diz MR Görüntülerinde Sagittal, Koronal ve Aksiyal Düzlemler	51

BÖLÜM 4

MANYETİK REZONANS GÖRÜNTÜLERİNDEN DİZ MENİSKÜSLERİNİN OTOMATİK BÖLÜTLENMESİ İÇİN BİLGİSAYAR TEMELLİ YENİ BİR YAKLAŞIM	54
4.1 Materyal ve Yöntem	55
4.2 Bütünsel Sınırlayıcı Kutunun (Global Bounding Box) Bulunması	57
4.2.1 Bütünsel sınırlayıcı kutu içerisinde alansal örtüşme hesabı	59
4.3 Özellik çıkarımı ve indirgenmesi (Feature extraction and reduction)	60
4.3.1 Yönelimli Gradyan Histogramları	61
4.3.2 Yerel İkili Örüntü	67
4.3.3 Rastgele Alt Örnekleme (Random Subsampling)	73
4.3.4 Temel Bileşen Analizi	74
4.4 Model Eğitimi	76
4.4.1 Model Eğitici: Aşırı Öğrenme Makinesi	77
4.4.2 Model Eğitici: Rastgele Ormanlar	80
4.5 Regresyon Sonuçlarının Analizi	81
4.6 Kesit Eleme	82
4.7 Menisküs Sınırlarının Çıkartılması	83
4.8 DeneySEL Sonuçlar	85
4.9 Hesapsal Karmaşıklık ve Çalışma Süreleri	87
4.10 Tartışma	90

BÖLÜM 5

MANYETİK REZONANS GÖRÜNTÜLERİNDE YER ALAN MENİSKÜS YIRTIKLARININ BİLGİSAYAR DESTEKLİ OTOMATİK TEŞHİSİ İÇİN YENİ BİR YÖNTEM	95
5.1 Materyal ve Yöntem	96
5.2 Bütünsel Sınırlayıcı Kutular Üzerinden Özellik Çıkarımı ve İndirgemesi	100
5.3 Bölütleme İşlemleri	103
5.3.1 Geçerlilik İndeksleri	106
5.4 Sınıflandırma	107
5.4.1 En Yakın k-Komşuluğu (k-Nearest Neighboring (kNN)),	108
5.4.2 Destek Vektör Makineleri (Support Vector Machines (SVM))	108
5.5 DeneySEL Sonuçlar	109
5.6 Hesaplama Zamanları	113
5.7 Tartışma	114
5.8 Önerilen Yaklaşımların Karşılaştırılması	118

BÖLÜM 6

SONUÇ VE ÖNERİLER	120
KAYNAKLAR.....	123
EK-A	
OSTEOARTRİT GİRİŞİMİ	136
A-1 Görüntü Değerlendirmeleri	136
ÖZGEÇMİŞ	139

SİMGE LİSTESİ

B_0	Harici manyetik alan
C	Düzenleştirme sabiti
G_z	Doğrusal gradyan alanı
h_{ij}	Mekansal işlev
$H^\dagger$	Moore-Penrose genelleştirilmiş çıkış matrisi tersi
$h(x)$	Gizli katman çıkış vektörü
$G(a,b,x)$	Lineer olmayan parçalı sürekli fonksiyon
J	Amaç fonksiyonu
M	Hacimsel manyetik alan
$NB(x_j)$	Merkezi x_j pikseli olan kare pencere
P	İşlem gören komşu sayısı
R	Merkez pikselin komşularına olan uzaklığı
r	İlinti
T	Etiket matrisi
T_E	Dinleme zamanı (Echo time)
T_R	Yineleme zamanı (Repetition time)
u_{ij}	Üyelik değeri
v_i	Küme merkezi değeri
V_{PC}	Bölümlendirme indeksi
V_{CE}	Sınıflandırma entropisi
w_0	Uyarıcı taşıyıcı frekans
x_c	Merkez piksel
x_p	Merkez pikselin komşuları
β	Çıkış ağırlıkları vektörü
$\emptyset$	Başlangıç fazı
γ	Döngüsel oran sabitesi

KISALTMA LİSTESİ

ACL	Ön Çapraz Bağ (Anterior Cruciate Ligament)
AH	Ön Boynuz (Anterior Horn)
BCO	Bulanık c-Ortalamalar
BODY	Menisküs Gövdesi
CAD	Bilgisayar Destekli Teşhis (Computer Aided Diagnosis)
CT	Bilgisayarlı Tomografi (Computer Tomography)
DESS	Denge durumunda çift yankılı (Double Echo in the Steady State)
DSC	Dice Benzerlik Katsayısı (Dice Similarity Coefficient)
ELM	Aşırı Öğrenme Makinesi (Extreme Learning Machine)
FCM	Bulanık c-Ortalamalar (Fuzzy c-Means)
GMBCO	Güçlendirilmiş Mekansal Bulanık c-Ortalamalar
HOG	Yönlendirilmiş Gradyan Histogramları (Histogram of Oriented Gradients)
K-L	Kellgren Lawrence
kNN	En Yakın k-Komşuluğu (k-Nearest Neighbor)
LBP	Yerel İkili Histogramlar (Local Binary Pattern)
MBCO	Mekansal Bulanık c-Ortalamalar
MR	Manyetik Rezonans
MRG	Manyetik Rezonans Görüntüleme
MSE	Ortalama Karesel Hata (Mean Squared Error)
OA	Osteoartrit
OAI	Osteoartrit Girişimi (Osteoarthritis Initiative)
PCA	Temel Bileşen Analizi (Principal Component Analysis)
PFCM	Olasılıksal Bulanık c-Ortalamalar (Probabilistic Fuzzy c-Means)
PH	Arka Boynuz (Posterior Horn)
RF	Radyo Frekans
RF	Rastgele Ormanlar (Random Forests)
ROI	İlgi Bölgeleri (Region of Interests)
SIFT	Büyük Ölçekli Değişmez Özellik Dönüşümü (Scale Invariant Feature Transform)
SLFN	Tek Gizli Katmanlı İleri Beslemeli Yapay Sinir Ağı (Single Layer Feedforward Network)
SVM	Destek Vektör Makineleri (Support Vector Machines)
VKİ	Vücut Kitle İndeksi

weDESS Denge durumunda su uyarımlı çift yankılı (Water Excitation Double Echo in the Steady State)

ŞEKİL LİSTESİ

	Sayfa
Şekil 2. 1 Sağ dizin önden ve yukarıdan görünümü [86]	33
Şekil 2. 2 Diz eklemının detaylı gösterimi [88]	33
Şekil 2. 3 Sağlıklı diz görüntüsü [96]	38
Şekil 2. 4 Osteoartrite olmuş diz görüntüsü [96]	38
Şekil 2. 5 Seviye 1 (Grade 1) menisküs bozuklukları. (a) T2 uyarım dizili koronal düzlem MRG; (b) T2 uyarım dizili sagittal düzlem MRG; (c) Proton ağırlıklı uyarım dizili koronal düzlem MRG; Proton ağırlıklı uyarım dizili sagittal düzlem MRG; (e) seviye 1 bozukluk için üç boyutlu görüntü [100]	40
Şekil 2. 6 Seviye 2 (Grade 2) menisküs bozuklukları. (a) T2 uyarım dizili koronal düzlem MRG; (b) Proton ağırlıklı uyarım dizili koronal düzlem MRG; (c) T2 uyarım dizili sagittal düzlem MRG; (d) Proton ağırlıklı uyarım dizili sagittal düzlem MRG; (e) seviye 2 bozukluk için üç boyutlu görüntü [100]	41
Şekil 2. 7 Seviye 3 (Grade 3) menisküs bozuklukları. (a) T2 uyarım dizili koronal düzlem MRG; (b) Proton ağırlıklı uyarım dizili koronal düzlem MRG; (c) T2 uyarım dizili sagittal düzlem MRG; (d) Proton ağırlıklı uyarım dizili sagittal düzlem MRG; (e) seviye 3 bozukluk için üç boyutlu görüntü [100]	42
Şekil 2. 8 En yaygın menisküs yırtık tipleri [104]	43
Şekil 3. 1 MR görüntülerde elde edilebilecek farklı düzlemler [106]	46
Şekil 3. 2 Proton ağırlıklı yağ bastırılmış uyarım dizisi için sagittal düzlemde örnek görüntü [119]	52
Şekil 3. 3 Koronal düzlemde proton ağırlıklı yağ bastırılmış uyarım dizisi için örnek görüntü [119]	52
Şekil 3. 4 Veri seti içerisinde MR kesit görüntülerinde elde edilebilecek 3 farklı düzlem için örnekler	53
Şekil 4. 1 Menisküs sınırlarının belirlenmesi için akış şeması	57
Şekil 4. 2 Bütünsel sınırlayıcı kutu içerisinde elle bölütlenmiş örnek MR kesit görüntüsü	58
Şekil 4. 3 Görüntüsün tamamında ve bütünsel sınırlayıcı kutuda gerçekleştirme zamanları	59
Şekil 4. 4 MR kesit görüntülerinde farklı menisküs büyüklükleri	59
Şekil 4. 5 Alansal örtüşme hesabı	60
Şekil 4. 6 İşaretsiz 0-180 derecenin 9 kanala ayrılması	63
Şekil 4. 7 Gradyan (Yön Vektörü) Histogramlarının oluşturulması	64

Şekil 4. 8	Tanımlayıcı bloklarının oluşturulması	64
Şekil 4. 9	Örnek bir blok üzerinde yönelimli gradyan histogramlarının görselleştirilmesi	65
Şekil 4. 10	Menisküs dokusuna ait yönelimli gradyan histogramlarının görselleştirilmesi (Hücre büyüklüğü=10).....	66
Şekil 4. 11	Menisküs dokusuna ait yönelimli gradyan histogramlarının görselleştirilmesi (Hücre büyüklüğü=3).....	67
Şekil 4. 12	LBP tanımlayıcı kodu oluşturmak için bir örnek	69
Şekil 4. 13	Dairesel (8, 1), (16, 2) ve (8, 2) komşulukları [149]	69
Şekil 4. 14	(8, R) komşuluğu için 58 farklı düzgün örüntü [149]	70
Şekil 4. 15	(8, R) komşuluğu için 58 farklı düzgün örüntü [149]	71
Şekil 4. 16	Örnek bir menisküs penceresinde LBP özelliklerinin görselleştirilmesi	72
Şekil 4. 17	Başka bir örnek menisküs penceresinde LBP özelliklerinin görselleştirilmesi	72
Şekil 4. 18	Örnek bir MR kesit görüntüsü üzerinde bütünsel sınırlayıcı kutu	73
Şekil 4. 19	Tek bir MR görüntüsü için örtüşme oranlarına göre elde edilen örnek sayılarının histogramı	74
Şekil 4. 20	Örtüşen alanlar için örnek görüntüler	77
Şekil 4. 21	ELM ağ yapısı	78
Şekil 4. 22	ELM gizli katman sayılarının belirlenmesi.....	79
Şekil 4. 23	ELM düzenleme parametresinin belirlenmesi.....	80
Şekil 4. 24	Elenen kesitler için bir örnek	83
Şekil 4. 25	Menisküs çıkarım aşaması için akış şeması	84
Şekil 4. 26	Ortanca filtresi ile gürültülerin azaltılması	84
Şekil 4. 27	Menisküs sınırlarını belirleme aşamaları	85
Şekil 4. 28	a) gerçek ve tahmin edilen menisküs sınırları, b) gerçek menisküs bölgesi, c) tahmin edilen menisküs bölgesi.....	86
Şekil 4. 29	HOG ve LBP ile özellik çıkarımı için süre değerleri.....	89
Şekil 4. 30	Hatalı bölütlemelerin olduğu 5 farklı örnek	93
Şekil 5. 1	Örnek bir MR kesit görüntüsü ve menisküs yapılarının konumları	99
Şekil 5. 2	Sistem genel akış diyagramı.....	100
Şekil 5. 3	Bütünsel sınırlayıcı kutu ve elle bölütlenmiş örnek MR görüntüsü	101
Şekil 5. 4	Dikdörtgensel pencerelerin elde edilmesi	102
Şekil 5. 5	Menisküs yırtıklarının sınıflandırılması için akış şeması.....	102
Şekil 5. 6	Bulanık kümeleme yöntemleri ile bölütleme işlem adımları.....	105
Şekil 5. 7	Menisküs dokularının bölgelere göre ayrılması.....	106
Şekil 5. 8	Küme sayılarına göre GMBCO geçerlilik değerleri.....	107
Şekil 5. 9	Örnek bir MR kesiti üzerinde işlem adımları	110
Şekil 5. 10	Farklı performans değerlendiricileri için kutu grafiği (box plot).....	112

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 1. 1 Literatürdeki çalışmaların karşılaştırılması	28
Çizelge 3. 1 Literatürdeki incelediğimiz çalışmalarda kullanılan MR cihazlarının manyetikleme yetenekleri, uyarım dizileri, görüntü düzlemi, çözünürlüğü ve kesit kalınlığı	49
Çizelge 3. 2 Düşük alanlı tarayıcılarla yüksek alanlı tarayıcıların karşılaştırılması.	50
Çizelge 4. 1 Sol ve sağ diz için K-L dereceleri	56
Çizelge 4. 2 Aynı kesit üzerinde farklı pencere boyutlarının en iyi regresyon sonuçlarının karşılaştırılması	81
Çizelge 4. 3 Gerçek ve tahmin edilen pencereler arasındaki ilinti	82
Çizelge 4. 4 Dice ve Duyarlılık için Ortalama (Ort.) ve Standart Sapma (Ss) Değerleri .	87
Çizelge 4. 5 Gerçekleme Süreleri (s: saniye)	88
Çizelge 4. 6 Bütünsel kutu içerisinde HOG ile özellik çıkarımında kullanılan parametreler	89
Çizelge 4. 7 Literatürde yer alan ve menisküs bölütlemesi yapan çalışmaların elde ettiği başarı oranları (İM: iç menisküs, DM: dış menisküs)	90
Çizelge 4. 8 Literatürde yer alan ve menisküs bölütlemesi yapan çalışmaların kullanmış oldukları veri setlerinin boyutları ve katılımcıların sağlık durumları	91
Çizelge 5. 1 Veri setindeki katılımcıların demografik bilgileri	97
Çizelge 5. 2 İç Menisküste Yırtıkların Bölgelere Göre Dağılımı	98
Çizelge 5. 3 Dış Menisküste Yırtıkların Bölgelere Göre Dağılımı	99
Çizelge 5. 4 İç ve dış menisküsler için yırtık ve sağlıklı menisküs sayıları.....	99
Çizelge 5. 5 Kümeleme yöntemlerinin geçerlilik indeks sonuçları.....	107
Çizelge 5. 6 İç ve dış menisküsler için ikili ve çoklu sınıflandırma sonuçları	111
Çizelge 5. 7 Çoklu sınıflandırma için karışıklık matrisi.....	113
Çizelge 5. 8 İkili sınıflandırma için karışıklık matrisi	113
Çizelge 5. 9 Farklı sınıflayıcılara göre sistemin gerçekleme zamanı.....	114
Çizelge 5. 10 Literatürde yer alan ve menisküs yırtık tespiti yapan çalışmaların kullanmış oldukları veri setlerinin boyutları ve katılımcıların sağlık durumları	115
Çizelge 5. 11 Literatürde yer alan ve menisküs yırtık tespiti yapan çalışmaların kullanmış oldukları veri setlerinin boyutları ve katılımcıların sağlık durumları	115
Çizelge 5. 12 Literatürde yer alan ve menisküs yırtık tespiti yapan çalışmaların elde ettiği başarı oranları (İM: iç menisküs, DM: dış menisküs)	116

Çizelge 5. 13 İç menisküslerin gövde bölümü için farklı bölütleme yaklaşımları ile
bölütlenmiş görüntülerin menisküs yırtık tipleri sınıflandırma sonuçları 119

MR GÖRÜNTÜLERİNDE MENİSKÜSLERİN SEGMENTASYONU VE MENİSKÜS YIRTIKLARININ TESPİTİ

Ahmet SAYGILI

Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

Tez Danışmanı: Doç. Dr. Songül ALBAYRAK

Medikal veriler hastalıkların tanı ve teşhisinde kullanmaya uygun çok değerli bilgiler içermektedir. Ancak veri setlerinin büyüklüğü ve karmaşıklığı verilerin sınıflandırılmasını zorlaştırmaktadır. Bu durum tıbbi veriler üzerinde otomatik tespit sistemlerinin yaygın hale gelmesini sağlamıştır. Bu verilerden birisi de bu tez çalışmasının konusu olan diz eklemi menisküs yapılarıdır. Menisküs yırtıkları, özellikle sporcularda ve ileri yaşlarda yaygın olarak görülen diz rahatsızlıklarından biridir. Bu yüzden doğru teşhisin doğru zamanda konulması osteoartrite gibi dizde oluşabilecek farklı rahatsızlıkların önüne geçilmesini sağlamaktadır. Bu çalışma, radyologları desteklemek için (i) menisküslerin bölütlenmesi ve yırtıkların tespit edilmesi, (ii) erken teşhis ve tedavinin sağlanması ve (iii) manyetik rezonans (MR) görüntülerini değerlendirenlerin farklılıklarından kaynaklanan hataların azaltılması için bilgisayara dayalı ve otomatikleştirilmiş yeni yaklaşımlar önermektedir. Gerçekleştirdiğimiz çalışmalarda bu amaçlar doğrultusunda Osteoartrite Girişimi (OAI) tarafından sağlanmış sagittal düzlemde elde edilmiş, denge durumunda su-uyarımli çift yankılı standardında MR görüntüleri kullanılmıştır. Tez kapsamında iki farklı ve kapsamlı çalışma gerçekleştirilmiştir. İlk çalışmada yönlendirilmiş gradyan histogramları (HOG) ve yerel ikili örüntüler (LBP) MR görüntülerinden özellik çıkarımı için, aşırı öğrenme makinesi (ELM) ve rastgele ormanlar (RF) yöntemleri de model öğrenmede (regresyon) kullanılmıştır. Öncelikle menisküsleri sınırlayan en ufak dikdörtgen pencereler bulunmaktadır. Bundan sonra, menisküs sınırları morfolojik

süreçlerle açığa çıkarılmaktadır. Ardından, bu sınırlar ile gerçek sınırlar arasındaki benzerlikler ölçülmekte ve birbirleriyle karşılaştırılmaktadır. Dice benzerlik ölçütüne göre en yüksek menisküs bölütleme başarısı % 82.73'tür. İkinci çalışmada menisküslerin bölütlenmesi ve menisküs yırtıklarının otomatik olarak sınıflandırılması için önceki yöntemden farklı ve yeni bir yaklaşım önerilmiştir. Bu çalışma ise önışleme, bölütleme ve sınıflandırma olmak üzere üç temel aşamadan oluşmaktadır. Önışlem aşamasında MR kesit görüntülerinden menisküslerin yer aldığı pencerelerin elde edilmesi işlemi gerçekleştirilmiştir. Bölütleme aşamasında bulanık c-ortalamalar (BCO), mekansal bulanık c-ortalamalar (MBCO) ve güçlendirilmiş mekansal bulanık c-ortalamalar (GMBCO) kümeleme yöntemleri ile menisküs yapıları bölütlenmiştir. Bölütlenmiş görüntüleri sınıflandırarak menisküs yırtıklarını tespit etmek için ise en yakın k komşuluğu (kNN), aşırı öğrenme makinesi (ELM) ve destek vektör makineleri (SVM) sınıflayıcıları kullanılmıştır. Yöntem menisküslerde yırtıkların olup olmadığını, eğer varsa yırtıkların menisküsün hangi bölgesinde (Ön boynuz, menisküs gövdesi, arka boynuz) olduğunu ve yırtık tiplerinin (yatay, dikey vb.) ne olduğunu 3-4 dakikalık bir süre zarfında ortaya koymaktadır. Önerdiğimiz sistem literatürde daha önce gerçekleştirilmemiş olan, menisküsleri yırtık tiplerine göre sınıflandırma işlemini %84.97'lik bir başarı oranı ile gerçekleştirmektedir. Bu yönleri sayesinde çalışma kapsamında önerilen bilgisayar destekli teşhis sistemleri (CAD) radyoloji uzmanları tarafından menisküs bölütlenmesinde ve menisküs yırtıklarının teşhisinde bir karar destek sistemi olarak kullanılabilir.

Anahtar Kelimeler: Bölütleme, Diz eklemi, Menisküs, Medikal görüntüler, Bilgisayar destekli teşhis, Menisküs yırtıkları, Manyetik rezonans görüntüleme.

MENISCUS SEGMENTATION AND DETECTION OF MENISCUS TEARS IN MR IMAGES

Ahmet SAYGILI

Department of Computer Engineering

Ph.D. Thesis

Adviser: Assoc. Prof. Dr. Songül ALBAYRAK

Medical data contains valuable information suitable for diagnosis of diseases. However, the size and complexity of data sets make it difficult to classify data. This provides that automatic detection systems become common on medical data. One of these data is the meniscus structures of the knee joint which is the subject of this thesis study. Meniscus tears are one of the common knee disorders, especially in sports and elderly people. Therefore, the right time to put the right diagnosis ensures that the various disorders that may occur in the knee can be avoided, such as osteoarthritis. This study suggests new computer-based and fully automated approaches to support radiologists (i) to segment menisci and to detect tears, (ii) to provide early diagnosis and treatment, and (iii) to reduce errors caused by MR reader differences. In our studies, we used MR images in the water-selective excitation) double echo in the steady state (weDess) standard obtained in the sagittal plane provided by the Osteoarthritis Initiative (OAI) for these purposes. Two different and comprehensive studies were carried out within the scope of the thesis. In the first study, extreme learning machine (ELM) and random forest (RF) methods were used for model learning (regression) and histogram of oriented gradients (HOG) and local binary patterns (LBP) for feature extraction. First of all, there are the most compact rectangular windows that limit meniscus. After that, the meniscus boundaries are obtained by morphological processes. Then, similarities between predicted boundaries and ground truth boundaries are measured and

compared with each other. The highest meniscus segmentation success achieved with the Dice similarity metric was 82.73%. In the second study, a new and different approach to the previous method was proposed for the segmentation of menisci and the automatic classification of meniscal tears. This study consists of three basic stages: preprocessing, segmentation and classification. In the preprocessing step, the acquisition of the windows where the menisci are located was performed from the MR slices. The meniscus structures were segmented by fuzzy c-means (FCM), spatial fuzzy c-means (sFCM) and improved spatial fuzzy c-means (isFCM) clustering methods at the segmentation step. The k-nearest neighbor (kNN), extreme learning machine (ELM) and support vector machines (SVM) classifiers were used to classify segmented images and to detect meniscus tears. The method first decides whether there are tears on menisci; if this is the case then, determines the place (anterior horn, meniscus body, posterior horn) and the type of tears (horizontal, vertical, etc.) with high success rates within 3-4 minutes. The proposed system realizes classification of meniscus tear types by a success rate of 84.97%, which has not been done before in the literature. The computer aided diagnostic systems (CAD) proposed in the study can be used by radiologists as a decision support system in meniscus segmentation and diagnosis of meniscus tears with these aspects.

Keywords: Segmentation, Knee joint, Meniscus, Medical Images, Computer aided diagnosis, Meniscus tears, magnetic resonance imaging.

BÖLÜM 1

GİRİŞ

Görüntü işleme teknikleri özellikle medikal görüntülemelerde sıklıkla kullanılmaktadır. Medikal görüntülemedeki teknolojik gelişim farklı dokulara ait yüksek çözünürlükte görüntüler elde edilebilmesine olanak sağlamaktadır. Medikal uygulamaların gerçekleştirildiği sektörlerde görüntü işleme yöntemleri ile elde edilen bilgiler karar almada etkin rol oynayan bir konumdadır. Ultrasonografi, bilgisayarlı tomografi ve manyetik rezonans görüntüleme (MRG) en sık kullanılan medikal görüntüleme biçimlerindendir.

Bu tez çalışması kapsamında MRG kullanılarak diz ekleminde yer alan menisküs dokularının analiz edilmesine çalışılmıştır. MR görüntüleme herhangi bir cerrahi müdahale gerektirmeyen yani invaziv olmayan bir yöntem olması, yüksek çözünürlüğe sahip görüntüler oluşturabilmesi ve iyonlaştırıcı olmayan radyo frekans (RF) sinyallerine bağlı olarak çalışması sebebiyle en sık tercih edilen görüntüleme biçimlerinden biridir. Bu çalışmada diz MR görüntülerinden menisküs bölgelerinin otomatik bir şekilde bölütlenmesi ve menisküs yırtıklarının tespit edilmesi amaçlanmaktadır. Menisküsler dizdeki hareket kabiliyetini doğrudan etkileyen yapılardır. Menisküslerin zarar görmesi hareketin kısıtlanmasına sebep olabilmektedir. Ayrıca menisküslerin dize uygulanan yükün yumuşatılması, kaval (tibia) ve uyluk (femur) kemiklerinin arasındaki uyumun sağlanarak sürtünmenin önlenmesi gibi görevleri vardır. Aynı zamanda menisküslerin zarar görmesi osteoartrite rahatsızlığının da tetiklenmesine sebep olabilmektedir. Bu sebeple menisküs bölgelerinde oluşan normal olmayan durumların erken tanı ve tedavisi önem arz etmektedir.

İnsan vücudunda her diz eklemine biri dizin iç kısmında (medial) diğeri dış kısmında (lateral) olmak üzere iki çeşit menisküs bulunmaktadır. Dış menisküs iç menisküse göre daha hareketlidir. Bu sebeple yırtık oluşma ihtimali iç menisküste daha fazladır. Menisküs yırtıkları özellikle genç yaşlardaki sporcularda ve ilerlemiş yaşlardaki kişilerde (65 yaş üstü) ortaya çıkan bir rahatsızlıktır. Menisküs yırtıklarının teşhisi radyoloji uzmanları tarafından konulmaktadır. Menisküs yırtıklarının erken teşhis edilmesi, osteoartrit gibi rahatsızlıkların oluşmasını engeller ve ilerlemeden tedavi edilmesine olanak sağlar. Otomatik bölütleme işlemlerinin olmadığı durumlarda radyoloji uzmanları bu bölgelerin tespitini elle gerçekleştirmektedir. Bu durum tanı konulma süresini uzatabilmektedir. Bunun yanı sıra bölütleme işlemlerinin elle gerçekleştiriliyor olması hem zaman açısından maliyetli olmaktadır hem de MR görüntülerini değerlendirenlerin farklılıklarından kaynaklanan hatalı bölütlemelere sebep olabilmektedir. Bu sebeple bu çalışmaya konu olan otomatik bölütleme işlemleri uygulanmaya başlanmıştır. 2000’li yıllara doğru çalışılmaya başlanılan bu konu son yıllarda daha da ivme kazanmıştır.

Bu tez çalışması kapsamında yapılan değerlendirmeler için kullanılan veri seti Osteoartrit Girişimi (OAI) tarafından halka erişimi açık olan diz MR görüntülerinden oluşmaktadır [1]. Toplamda 4796 katılımcının yer aldığı veri setinde radyoloji uzmanları tarafından elle bölütlenmiş 88 MR görüntüsü yer almaktadır. Gerçekleştirilen deneysel çalışmalarda doğrulama işlemini gerçekleştirebilmek adına bu elle bölütlenmiş görüntülerden faydalanılmaktadır. Gerçekleştirilen sistem otomatik olan ve ön bilgiye ihtiyaç duymayan bir bölütleme ve teşhis sistemidir. Bu sistem için görüntü işlemede kullanılan tekniklerden faydalanılmaktadır. Yönelimli gradyan histogramları (histogram of oriented gradients (HOG)) ve yerel ikili örüntü (local binary pattern (LBP)) gibi farklı özellik çıkarımı yöntemleri ve en yakın k-komşuluğu (k-nearest neighborhood (kNN)), rastgele ormanlar (random forest (RF)), destek vektör makinaları (support vector machines (SVM)) ve aşırı öğrenme makinaları (extreme learning machines (ELM)) gibi farklı sınıflayıcılar ile sınıflama ve regresyon işlemleri gerçekleştirilmektedir.

Bu tez kitabının birinci bölümünde geçmişten günümüze bu alanda yapılan çalışmaların yer aldığı literatür özetine, tezin amacına ve literatüre ve bilime sağladığı katkılara yer verilmiştir. Özellikle literatürdeki çalışmaların artı ve eksi yönleri üzerinde durularak yapılan bu çalışmanın önemi vurgulanmaya çalışılmıştır. Çalışmanın ikinci bölümünde diz

ekleminde yer alan menisküs dokuları üzerinde işlemler gerçekleştirdiğimiz için diz ekleminde yer alan yapılar incelenmiştir. Bu sayede yapılan işlemlerin daha anlaşılır olacağı düşünülmektedir. Üçüncü bölümde kullanılan görüntüleme biçimi olan MRG anlatılmıştır. Neden bu görüntüleme biçiminin seçildiğinin vurgulanması açısından bu başlık önemli görülmektedir. Tez çalışması kapsamında iki farklı ve kapsamlı çalışma yapılmıştır. İlk çalışma dördüncü bölümde anlatılan menisküs dokularının otomatik bir şekilde bölütlenmesini sağlayan çalışmadır. Diğer çalışma ise beşinci bölümde verilmiş olan hem menisküs dokularının bölütlenmesini sağlayan hem de menisküs yırtıklarının teşhisini sağlayan çalışmadır. Bu çalışma ile bilgisayar destekli bir teşhis sistemi ortaya konmuştur. Dördüncü ve beşinci bölümde çalışmalarda kullanılan veri setlerine, materyal ve yöntemlere ve elde edilen sonuçlara alt başlıklarda ayrıntılı olarak yer verilmiştir. Tez çalışmamızın altıncı ve son bölümünde ise sonuçlar ve önerilere yer verilmiştir.

1.1 Literatür Özeti

Görüntü bölütleme ile ilgili literatürde yapılmış çok sayıda çalışma bulunmaktadır. Bunun yanı sıra bilgisayar destekli görüntü işleme tekniklerindeki gelişmeler ve görüntüleme cihazlarının sağladığı faydalı bilgiler sayesinde insan vücudunda yer alan yapılardaki anormalliklerin tespitinde büyük bir aşama kaydedilmiştir. Geçmişten günümüze özellikle beyin tümörlerinin tespit edilmesi [2], [3], [4], [5], [6], [7], [8], [9] ve mamogram görüntülerinden göğüs kanseri teşhisi [10], [11], [12], [13], [14], [15] üzerine birçok çalışma gerçekleştirilmiştir. Daha sonra bu çalışmaların motivasyonunda insan vücudunun farklı bölgeleri için medikal görüntü işleme teknikleri uygulanmaya başlanmıştır.

Medikal görüntü işleme de en sık kullanılan yöntemler eşikleme [16], [17], [18], [19], [20], bölge büyütme algoritmaları [21], [22], [23], [24], sınıflayıcılar [25], [26], [27], kümeleme yaklaşımları [28], [29], [30], Markov modelleri [31], [32], [33], [34], [35], yapay sinir ağları [36], [37], [38], bozulabilir modeller [39], [40], [41], [42], [43] ve atlas temelli [42], [44], [45], [46] yaklaşımlardır. Bu yöntemlerin yanı sıra son yıllarda özellikle bilgisayarla görme ve görüntü işleme alanlarında büyük bir yer edinen derin öğrenme yöntemi için ayrıca bir parantez açmak gerekmektedir. Derin öğrenme ifadesi 2012

yılında Hinton tarafından çok katmanlı yapay sinir ağlarının verimli bir şekilde eğitilebileceği ortaya koyulduktan sonra literatürde kullanılmaya başlanmıştır [47]. Derin öğrenme yöntemi çok büyük boyutlardaki etiketlenmiş eğitim verilerinden özellik çıkarımı yapabilen sistemler oluşturabilmektedir. Bilgisayarla görme alanında dünyanın en prestijli yarışması olan ImageNet sınıflandırma yarışmasında gerçekleştirilen çalışmalardan bir tanesi [48] konvolüsyonel sinir ağını kullanarak birinci olmuştur. Ve birinci olan bu çalışmanın sınıflandırma hatası %11 iken en yakın rakibinin yani ikinci olan yarışmacının sınıflandırma hatası %26 olmuştur. Bu durum sonucunda 2013 yılında MIT teknoloji değerlendirme dergisi (MIT Technology Review) derin öğrenmeyi en iyi atılım gösteren 10 yöntemden biri olarak belirlemiştir [49] . Bundan sonra derin öğrenme araştırmacılar tarafından birçok alanda tercih edilen bir yöntem haline gelmiştir.

Literatürde bilgisayarla görme ve görüntü işlemede sıklıkla tercih edilen derin öğrenme yöntemini kullanan ve diz bölgesindeki yapıların bölütlenmesini gerçekleştiren az sayıda çalışma bulunmaktadır. Bu çalışmalardan ilkinde 2013 yılında Prasoon vd. [50] üç-düzlemli evrimsel sinir ağlarını (triplanar convolutional neural network) kullanarak diz ekleminde kıkırdak dokularının bölütlenmesini gerçekleştirmişlerdir. Çalışma düşük alan tarayıcılarla elde edilmiş MR görüntülerinde kaval kemiği kıkırdaklarına (tibial cartilage) uygulanmış ve 114 görüntü üzerinde test edilmiştir. Yöntemde tek bir ölçekte yalnızca iki boyutlu özellikler kullanılsa da, çok boyutlu özellikler kullanan en gelişmiş yöntemlerden daha iyi performans ortaya koymuştur. Çalışma öznel olarak görüntülerden özellikleri öğrenen derin bir öğrenme mimarisi ile daha iyi sonuçlar elde edilebildiğini ortaya koymuştur [50]. 2017 yılında Liu vd. tarafından gerçekleştirilen başka bir çalışmada evrimsel sinir ağları ile bozulabilir model (deformable model) yaklaşımı ile diz eklemi MR görüntülerinde kıkırdak ve kemik bölütlemesi (segmentasyonu) gerçekleştirilmiştir [51]. Çalışma 2010 yılı diz görüntüleri bölütleme yarışmasında [52] diz görüntülerinde birçok yaklaşımdan daha iyi bölütleme performansı ortaya koymuştur. 2017 yılında Aldrin tarafından gerçekleştirilen tez çalışmasında ise menisküs bölütlemeleri için 2D UNet evrimsel derin öğrenme ağları (2D UNet fully convolutional network) ve rastgele ormanlar yöntemleri karşılaştırılmalı olarak uygulanmıştır [53]. 18 farklı MR görüntüsü üzerinde yapılan testlere göre Dice [54] metriği ile elde edilen sonuçlar derin öğrenme için %75.3, rastgele ormanlar için %54.4

olarak belirlenmiştir. Kemik ve kıkırdak bölütlemesi de gerçekleştiren çalışmada uyluk kemiğinin bölütlemesi için %95.3, kıkırdak dokuları için ise %71.7 bölütleme başarıları elde etmişlerdir. Anlatılmış olan bu yöntemler insan vücudundaki birçok bölgede başarıyla uygulanmış yöntemlerdir. Bu tez çalışmasının da konusu olan insan vücudunun diz eklemi bölgesine de bu yöntemler başarılı bir şekilde uygulanmaktadır.

Diz eklemi kaval ve uyluk kemiği, eklem kıkırdakları ve menisküslerden oluşmaktadır. Bütün bu yapılar hareket kabiliyetini doğrudan etkilemektedir. Diz üzerindeki hareketi doğrudan etkileyen bu yapıların otomatik olarak bölütlenmesini sağlayan birçok çalışma bulunmaktadır. Kıkırdak ve menisküs bölgelerinin bölütlemesine de imkan sağlayan kaval ve uyluk kemiklerinin bölütlenmesi önemli bir konumda bulunmaktadır. Kemik bölütlemesinde istatistiksel yüzey modeli yaklaşımı [55], [56], aktif çevre (active contour) metodu [57], bozulabilir model yaklaşımları [58] gibi birçok yöntem başarılı bir şekilde uygulanmıştır. Diz MR görüntüleri üzerine gerçekleştirilen çalışmalardan bir bölümü ise eklem kıkırdaklarının bölütlenmesi üzerinedir. Eklem kıkırdaklarının aşınması ile ortaya çıkan osteoartrit (OA), en sık görülen eklem hastalığıdır. Bu hastalığın henüz kesin tedavisi olmamakla birlikte yapılan çalışmalarda hastalığın erken teşhisi amaçlanmaktadır. Erken teşhis sayesinde de hastaların hareket kaybı ve duyacakları acı minimuma inmektedir.

Kıkırdak bölütleme üzerine gerçekleştirilen çalışmaların bir kısmı yarı otomatik bölütleme ile kıkırdakları tespit ederken [59], [60], bir diğer kısmı otomatik bölütleme ile kıkırdak tespiti yapmaktadır [61], [62], [63], [64], [65]. Kıkırdak bölütlemesi ile OA rahatsızlığının tespit edilmesi çalışmalarının yanı sıra, menisküslerin tespiti ve teşhisi üzerine de çalışmalar bulunmaktadır. Menisküsler ile ilgili gerçekleştirilen çalışmalar menisküs bölütlemesi ve menisküs yırtıklarının otomatik olarak belirlenmesi üzerine iki başlık altında toplanmıştır. Bazı çalışmalar ise her iki işlemi de gerçekleştirmektedir. Menisküs yırtıklarını tespit etmeyip sadece bölütleme işlemi yapan çalışmalarda temel amaç radyoloji uzmanlarının elle bölütlediği menisküs dokularını otomatik ya da yarı otomatik olarak bölütlemektir [66], [67], [68], [69], [70], [53], [71]. Menisküs yırtıkları ile ilgili olan çalışmalarda ise amaç öncelikle menisküsün bölütlenmesi ve yerinin tespit edilmesi ardından da yırtıkların tespit edilmesidir.

Bilgisayar destekli menisküs çıkarımı üzerine 20. yy'ın sonlarında çalışmalar yapılmaya başlanmıştır. Gerçekleştirilen çalışmalarda morfolojik işlemler, histogram eşitleme, eşikleme, kenar belirleme filtreleri ve bölge büyütme yöntemleri gibi görüntü işlemede sıklıkla kullanılan teknikler kullanılmaktadır. Yapılan çalışmalardan ilki Saki vd.'nin bulanık kural temelli yaklaşımı kullanarak gerçekleştirdikleri otomatik menisküs bölütlemesi yapan çalışmadır [72]. Çalışmada öncelikle yoğunluk (intensity) değerlerine göre eşikleme yapılarak kıkırdak dokuları bölütlenmektedir. Ardından bulunan bu kıkırdak dokularına göre menisküs vokselleri bulanık eğerse (fuzzy if then) kuralına göre tespit edilmektedir. Çalışmada yalnızca 5 MR (3 sağlıklı, 2 hasta) görüntüsünden oluşan küçük bir veri seti kullanılmıştır.

Normal ve osteoartrite rahatsızlığına yakalanmış dizlerde dış menisküslerin incelenmesi ve değerlendirilmesini yarı otomatik bir yöntemle gerçekleştiren Swanson vd. yaptığı çalışmada amaçlarının bölütleme zamanını azaltmak ve MR değerlendirci farklılıklarından (intra reader variability) oluşan hataları minimuma indirmek olduğunu belirtmişlerdir [69]. Çalışmada 10 tanesi normal (sağlıklı) olmak üzere toplam 24 katılımcının MR görüntüleri kullanılmıştır. Bölütleme işlemi için tohum bölge büyütme algoritmasını kullanan çalışmada, bölütleme başarısını arttırmak için görüntüler üzerine morfolojik işlemler (eşikleme, genişletme vb.) uygulanmıştır. Sistemin bölütleme başarısını ölçmek için Zijdenbos benzerlik ölçütü kullanılmış ve sağlıklı olmayan görüntüler için hastalığın düzeyine göre 0.75 (0. düzey), 0.67 (1. düzey) ve 0.64'lük (2. düzey) bir ortalama başarı elde edilmiştir. Hastalıklı görüntüler için elde edilen başarının düşük olması çalışmanın geliştirilmesi gereken yönüdür.

Menisküs bölütleme işlemini voksel seviyesinde gerçekleştiren çalışmalar da son yıllarda ivme kazanmıştır. Bu çalışmalardan ilki Fripp vd.'nin sagittal düzlemde 14 farklı sağlıklı insana ait MR görüntüsünde yaptıkları otomatik menisküs bölütleme çalışmasıdır [67]. Çalışmada daha önce yaptıkları kemik ve kıkırdak bölütleme sonuçlarını ön bilgi olarak kullanmışlar ve bu ön bilgiye göre menisküs voksellerinin etiketlemesini gerçekleştirmişlerdir. Dice benzerlik ölçütünü kullanarak dış menisküsler için % 75, iç menisküsler için %77'lik başarı oranı elde etmişlerdir. Çalışmanın sadece sağlıklı insanlar üzerinde gerçekleştirilmesi ve küçük bir veri setinde uygulanması zayıf yönleridir. Kim vd. istatistiksel yüzey modelleri ile bütünleştirilmiş aktif yüzey modellerini (active shape

model) kullanarak 3 boyutta menisküs bölütleme işlemi gerçekleştirmişlerdir [71]. Yapılan işlemler sonucunda iç menisküs için %54, dış menisküs için %73'lük bir başarı elde edilmiştir. Yin ve diğerleri daha önce yapmış oldukları kemik ve kıkırdak bölütlemesi çalışmalarının sonuçları ile rastgele ormanlar sınıflayıcılarını kullanarak 3-D menisküs bölütleme işlemi gerçekleştirmişlerdir [73]. Yaptıkları çalışmanın başarısını Dice benzerlik metriğini kullanarak ölçmüşler ve %80'lik bir başarı oranı elde etmişlerdir. Nedmark'ın çalışmasında düşük alan tarayıcılarla elde edilmiş MR görüntüleri kullanılarak otomatik menisküs bölütleme işlemi yapılmıştır [74]. Çalışmada öncelikle kemik bölütlemesi yapılmış ardından elde edilen bilgiler ile menisküs lokalizasyonu yapılmış ve son adımda da menisküs bölütlemesi yapılmıştır.

Paproki vd.'nin yapmış oldukları çalışmada [68] normal ve osteoartrit olmuş diz MR görüntülerinde iç ve dış menisküslerin bozulabilir model (deformable model) yaklaşımı ile otomatik olarak bölütlenmesi ve ölçülmesi gerçekleştirilmiştir. Bozulabilir model yaklaşımı içerisinde 3-B aktif yüzey modeli (active shape model), istatistiksel yüzey modeli (statistical shape model) ve şablon eşleştirme (template matching) yordamlarına yer vermişlerdir. Çalışmada Dice benzerlik ölçütü ile elde edilmiş başarı oranları iç menisküs için %77.1 iken, dış menisküs için %83.5 olmuştur. Zhang vd.'nin 2013 yılında gerçekleştirdiği çalışmada diğer çalışmalara ilave olarak farklı ağırlıklandırma yöntemleri uygulanmıştır [70]. Yapılan bu çalışmada aşırı öğrenme makinasını ve ayırmsayıcı rastgele alanlar yöntemlerini bir arada kullanarak kıkırdak ve menisküs dokuları için otomatik bir bölütleme işlemi ortaya koymuşlardır. Aşırı öğrenme makinası ve ayrık rastgele alanlar yöntemleri için Dice benzerlik ölçütüne göre elde edilmiş olan başarı, kıkırdak bölütleme için %82, menisküs bölütleme için ise %81'dir. Çalışmada katılımcıların sağlık durumlarının bilinmiyor olması eksik yönleridir.

3 boyutta gerçekleştirilmiş ve ağırlıklı olarak kıkırdak dokuları üzerinde çalışmalar yapmış Dam vd.'nin yaptığı çalışmada [66] diz MR görüntüleri üzerinde kemik, kıkırdak ve menisküs bölütleme işlemini otomatik gerçekleştiren bir sistem geliştirilmiştir. Çalışmada hem yüksek alan hem de düşük alan tarayıcılarla elde edilmiş MR görüntüleri kullanılmıştır. Toplamda 1907 diz MR görüntüsünün kullanıldığı çalışmada voksel sınıflandırma ile kombine edilmiş çoklu atlas temelli bir çalışma yapılmıştır. Dice benzerlik ölçütü ile elde edilmiş sonuçlara göre iç menisküs için %76 ve dış menisküs için

%83'lük bir bölütleme başarı oranı elde edilmiştir. Çalışmanın kıkırdak dokular üzerinde yoğunlaşması ve menisküsler üzerinde çok detaylı analiz yapmaması menisküs tarafından baktığımızda zayıf yönü olarak gösterilebilir. Bu alanda yapılmış bir başka çalışmada ise Kohut vd. MR görüntülerinden diz eklemi iç menisküs dokularındaki rahatsızlıkların tespit edilmesini amaçlamaktadır. Amaçlarını gerçekleştirmek için havza (watershed) yöntemi ile bölütleme gerçekleştirmişler ve bu yöntemi görüntü işlemede sıklıkla kullanılan bölge büyütme ve eşikleme yöntemleri ile karşılaştırmışlardır. Çalışmalarında dış menisküsler üzerine değerlendirme yapmamış olmalarını eksik yönü olarak söyleyebiliriz [75].

Menisküs bölütlemesi üzerine yoğunlaşmış bu çalışmaların yanı sıra hem bölütleme hem de yırtık tespiti yapan çalışmalar son yıllarda artmaktadır. Menisküs yırtıkları üzerine yapılan ilk çalışmalar 2000'li yılların başlarında gerçekleştirilmiştir. Hata vd.'nin 2001 yılında yapmış oldukları, metot olarak bulanık eğerse (fuzzy if-then rules) kurallarını kullandıkları çalışma menisküs yırtıkları ile ilgili yapılmış ilk çalışmadır [76]. Bu çalışmada menisküs yırtıklarının teşhisi için, sagittal düzlemde, proton ağırlıklı MR diz görüntüleri üzerinde otomatik olarak iç veya dış menisküsün tespiti ve yırtıkların teşhisini gerçekleştiren bir sistem sunulmuştur. Yırtık olup olmadığının bir uzman tarafından elle belirlenmesi çalışmanın eksik yönü olarak söylenebilir. Sağlıklı ve zarar görmüş menisküsler arasındaki farkları araştıran bir diğer çalışmada sagittal düzlemde elde edilmiş 55 farklı MR görüntüsü ile gerçekleştirilmiştir [77]. Çalışmada yırtıkların seviyelendirilmesi için iki farklı radyoloji uzmanından destek alınmış ve görüntülerin 15'i seviye 0 (normal menisküs), 20'si seviye 1 (az sevide bozulmuş menisküs) ve 20'si seviye 2 (daha fazla bozulmuş menisküs) olarak sınıflandırılmıştır. Menisküslerin yerlerinin tespit edilmesi için bölge büyütme (region growing) yaklaşımı kullanılmıştır. Tespit edilmiş menisküslerden ilgi yapılarına göre bir dizi dokusal özellik (ilinti, entropi vb.) çıkartılmıştır. Çalışmanın sonunda Bayes sınıflayıcı kullanılarak menisküsler normal ve bozulmuş olmak üzere 89%'luk doğruluk oranı ile sınıflandırılmıştır. Çalışmanın yırtık menisküs (seviye 3) tespiti yapmaması ve sadece iç menisküslerin arka boynuzlarını tespit etmesi eksik yönleridir. Histogram temelli yaklaşımla bölütleme yapan ve şablon eşleştirme yöntemiyle yırtıkları tespit etmeye çalışan bir diğer çalışmada sagittal diz MR görüntüleri kullanılmıştır [78]. Ayrıca sistem başarısını artırmak için Sobel, Prewitt gibi

kenar belirleme filtreleri kullanılmış ve bu filtrelerin başarıyı artırdığı görülmüştür. Gerçekleştirilen bu çalışmanın menisküs yerini tespit ederken bölgeye özgü varsayımlar kullanması bir eksiklik olarak görülebilir. Ramakrishna vd. MR görüntülerinden menisküs yırtıklarını tespit etmek ve yırtıkları seviyelendirmek için bilgisayar destekli otomatik bir sistem gerçekleştirmiştir. Çalışma önileme, menisküs çıkarımı ve menisküs karakterine göre skrolama sistemi olmak üzere üç bölümden oluşmaktadır [79]. Bu alanda yapılmış kapsamlı bir çalışma olmasına rağmen, çalışmada elde edilen özgüllük (specificity) değerinin düşük olması, kesitlerin belirlenmesinde bir ön bilgiye ihtiyaç duyması eksik yönleri arasındadır. Swamy vd. yaptıkları çalışmada önileme aşamasında kontrast artırma ve eşikleme işlemlerini uygulamış ve ardından Canny kenar belirleme yöntemi ile kaval ve uyluk kemiklerini bölütlemiştir [80]. Bu bölütleme işleminin ardından kaval ve uyluk kemikleri arasında kalan menisküs bölgesi ROI temelli maskeleme sayesinde tespit edilmiş ve görüntülenmiştir. Elde edilen menisküs bölgeleri renklendirilerek menisküs yırtıklarının görselleştirilmesi sağlanmıştır [80]. Fu ve arkadaşları MR görüntülerinden menisküs yırtıklarının tespitini bilgisayar destekli bir sistemle gerçekleştirmişlerdir [81]. Bu çalışmada menisküsün yerini belirlemek için düzey kümeleri ile aktif çevre (Active Contour with Level Sets) modelini kullanmışlardır. Ardından uzaysal (spatial) ve spektral düzlemden her bir şüpheli menisküs için 180 farklı özellik çıkarmışlardır. Elde edilen özelliklere SVM sınıflandırıcı ile sınıflandırma işlemi yaparak menisküs yırtıklarını tespit etmişlerdir [81].

Osteoartrite olmuş diz MR görüntülerinde kırık kalınlığının ölçümü ve menisküs yırtıklarının tespiti üzerine yapılmış olan başka bir çalışma da histogram eşitleme, eşikleme, Canny kenar belirleme yöntemi ve ilgi alanlarının tespiti ve maskelenmesi gibi yöntemler kullanılmıştır [82]. Yapılan çalışmada sistemin başarısını ölçmek için doğrulama işleminin yapılmamış olması zayıf yönüdür. Zarandi ve ark. 2016 yılında proton ağırlıklı MR görüntüleri üzerinde menisküs yırtıklarının teşhisini yapan bir çalışma ortaya koymuşlardır [83]. Çalışmada öncelikle FCM ve PFCM kümeleme yöntemleri ile MR görüntülerini bölütlemişler ve ardından algılayıcı sinir ağı (perceptron neural network) ile sınıflandırma işlemi yaparak MR görüntülerinin yırtık olup olmadığına karar vermişlerdir. Çalışmanın sonucunda iç menisküs ön boynuz yırtıklarını %84.24'lük bir başarı oranıyla sınıflandırmışlardır.

Çizelge 1. 1 Literatürdeki çalışmaların karşılaştırılması

Menisküs Bölütlemesi ve Menisküs Yırtık Tespiti ile İlgili Geçmiş Yıllarda Yapılan Çalışmalar					
Yazar ve Yılı	Yapılan İş	Veri seti, Boyutu	Yöntem	Eksik Yönü	Başarısı
Boniatis vd. 2008	Menisküslerin normal ve bozulmuş olarak sınıflandırılması	Farklı, 55 MR	Bayes sınıflayıcı	Yırtık olup olmadığının elle belirlenmesi	89%
Fripp vd. 2009	Yarı otomatik menisküs bölütlemesi	Farklı, 14 MR	Aktif yüzey modeli	Sadece sağlıklı insanlar üzerinde küçük bir veri setinde uygulanması	77%
Köse vd. 2009	Menisküs yırtıkları için otomatik teşhis sistemi	Farklı, 30 hastaya ait 500 görüntü	Histogram temelli yaklaşım, istatistiksel bölütleme yaklaşımı	MR görüntüleri yerine MR görüntülerinden elle belirlenmiş kesitler üzerine değerlendirme yapması	Hastalıklı görüntü için doğruluk: 88 Sağlıklı görüntü için doğruluk: 95
Ramakrishna vd. 2009	Menisküs yırtıkları için bilgisayar destekli otomatik teşhis sistemi	Farklı, 40 MR	İlgi bölgelerinin seçimi, eşikleme, alan ve yüzey kısıtlamaları, görünüş maskelerinin uygulanması	Kesit seçiminde uzman bilgileri neticesinde belli kesit aralıklarının elle belirlenmesi	Duyarlılık: 83 Özgüllük: 75
Swanson vd. 2010	Yarı otomatik menisküs bölütlemesi	OAI, 24 MR	Tohum bölge büyütme (Seeded Region Growing)	Hastalıklı görüntüler için elde edilen başarının düşük olması	75% (0. düzey), 67% (1. düzey) 64% (2. düzey)
Kim vd. 2010	Otomatik menisküs bölütlemesi	-	Aktif yüzey modeli, istatistiksel yüzey modelleri	Başarısının Düşük olması	54%
Yin vd. 2011	Otomatik menisküs bölütlemesi	OAI, 60 MR	Rastgele ormanlar sınıflaması	Ön bilgiye ihtiyaç duyması	80%
Zhang vd. 2013	Otomatik menisküs ve kırıldak bölütlemesi	Farklı, 11 MR	Aşırı öğrenme makinası ve ayırık rastgele alanlar	Katılımcıların sağlık durumlarının bilinmiyor olması	81%
Fu vd. 2013	Menisküs yırtıklarının tespiti	Farklı, 166 MR	Düzyük kümeleri ile aktif çevre SVM sınıflayıcı	Menisküsün sadece yırtık olup olmadığının tespit edilmesi	72%
Paproki vd. 2014	Otomatik menisküs bölütlemesi	OAI, 88 MR	Bozulabilir model yaklaşımı, şablon eşleştirme	Bölütleme işleminin uzun sürmesi	77%
Dam vd. 2015	Otomatik menisküs, kırıldak ve kemik bölütlemesi	OAI ve CCBP, 1907 MR	Atlas temelli yaklaşım	Menisküsler üzerinde çok detaylı analiz yapmaması	76%
Patel vd. 2016	Menisküs yırtıklarının tespiti	Farklı, 10	Histogram eşitleme, eşikleme, Canny kenar belirleme yöntemi	Doğrulama işleminin yapılmamış olması	-
Zarandi vd. 2016	Menisküs yırtıklarının tespiti	Farklı, 50	FCM ve PFCM algılayıcı sinir ağı	Menisküs yırtık tiplerinin belirlenmemiş olması	90%
Kohut vd. 2017	Otomatik menisküs bölütlemesi	Farklı, 7 MR	Havza (Watershed) yöntemi, bölge büyütme ve eşikleme	Örneklem sayısının az olması	78%

Çizelge 1.1’de son on yılda bu alanda yapılan çalışmalardan ön plana çıkanlar gösterilmektedir. Çizelgeden çalışmaların kimler tarafından, hangi tarihlerde ve hangi işlemler ile yapıldığını görmek mümkündür. Bunun yanı sıra çalışmalarda kullanılan veri setleri bizim çalışmamızda kullanılan OAI veri seti değilse ilgili sütuna farklı yazılmıştır. Eksik yönü sütununda bizim çalışmamızda yapmış olduğumuz işlemlerle kıyaslanarak eksik yönler tespit edilmiştir. Genel olarak çizelge değerlendirildiğinde sağlıklı katılımcılar üzerinde gerçekleştirilen sistemlerin elde ettiği başarıların daha yüksek olduğu görülmektedir. Ancak sadece sağlıklı insanlar üzerinden bir sistem kurmakta çok yerinde bir yaklaşım olmamaktadır. Kimi çalışmalarda ise örneklem sayılarının az olması elde edilen başarıların genelleme performanslarının sorgulanmasına neden olabilmektedir. Yarı otomatik bölütleme gerçekleştiren çalışmalarda ise ön bilgiye ya da uzman bilgisine ihtiyaç duyulması bu çalışmaların eksik yönleri olarak belirlenmiştir. Menisküs yırtıkları ile ilgili gerçekleştirilen çalışmalarda ise bizim yaptığımız ve beşinci bölümde yer verdiğimiz yöntemle karşılaştırıldığında sadece yırtık olup olmadığının belirlenmesini bir eksiklik olarak değerlendirebiliriz.

1.2 Tezin Amacı

Günümüzde manyetik rezonans (MR) görüntüleri birçok hastalığın teşhisinde, klinik tanı ve tedavide, cerrahi karar almada kullanılmaktadır. Bu görüntüler diz ekleminin elle veya otomatik şekilde bölütlenerek morfolojik olarak değerlendirilmesine de imkan sağlamaktadır. Bu tez çalışmasında diz eklem MR görüntülerindeki menisküs yapılarına ait bölgelerin otomatik olarak bölütlenmesi ve menisküs yırtıklarının tespit edilmesi amaçlanmaktadır. Geliştirilecek sistem hem menisküs yırtığı olan katılımcılara hem de sağlıklı katılımcılara ait diz MR görüntülerinden oluşmaktadır.

Osteoartrite genellikle diz eklemlerini etkileyen ve eklemlerde kıkırdak zedelenmesine bağlı olarak hareket kabiliyetinin azalmasına neden olan bir hastalıktır. Hastalığın gelişmiş ülkelerde 60 yaş ve üstü insanların yaklaşık %12’sinde görülmesi bu hastalığın erken tanı ve tedavisinin ne denli önemli olduğunu göstermektedir. Bu tez çalışmasının konusu olan menisküs dokularında görülen yırtılmalar da osteoartrite rahatsızlığını tetiklemektedir. Bu sebeple menisküs yırtıklarının da olabildiğince erken teşhis edilmesi ve tedavisine başlanması gerekmektedir. Diz MR görüntüleri uzman radyologlar

tarafından, uzmanının tecrübesi ile doğru orantılı olarak gözlemlenmekte ve gerek görüldüğü takdirde elle bölütlenerek analiz edilmektedir. Bu elle bölütleme işlemi her bir MR için yaklaşık 35 dk. sürmektedir [84]. Aynı zamanda elle bölütleme işlemi radyologların tecrübesi ile orantılı olarak, hataya açık bir işlemdir. Bütün bu durumlar otomatik bir bölütleme ve tanı koyma sistemine olan ihtiyacı göstermektedir. Bu tezde önerilen otomatik bölütleme sistemi bahsedilen bu eksiklikleri gidererek menisküslerin bölütlenmesinde ve menisküs yırtıkları için erken tanı ve tedavinin gerçekleştirilmesinde yardımcı olmaktadır.

Gerçekleştirilen sistem bölütleme ve yırtık tespiti işlemini literatürdeki çalışmaların büyük bölümünden farklı olarak herhangi bir ön bilgiye ihtiyaç olmadan otomatik bir şekilde yapmaktadır. Kimi çalışmalarda menisküslerin bölütlenmesi için öncesinde kemik dokularının bölütlenmesi gerekmektedir. Ancak ilgilenilen yapıların dışındaki yapı veya yüzeylerin de tespit edilmesi sistemi hesapsal açıdan daha karmaşık hale getirmektedir. Bu sebeple, bu çalışmada sadece menisküse özgü yaklaşımlar bulunmaktadır. Diz MR görüntülerinin bölütlenmesi ile ilgili olarak literatürde farklı çalışmalar mevcuttur. Fakat bu tezde gerçekleştirilen sistem, menisküsleri bölütleyen, bölütlenmiş menisküsler üzerinde yırtık tespiti yapan, yırtık tespitini yaparken de yırtığın hangi bölgede ve hangi tipte olduğunu ortaya koymaktadır. Literatürde şu ana kadar yapılan çalışmalarda menisküsleri yırtık tiplerine göre (yatay yırtık, dikey yırtık vb.) sınıflandıran bir çalışma bulunmamaktadır.

Bu tez çalışması sonunda gerçekleştirilen sistemin diz menisküs dokularında oluşan normal olmayan durumların tespitinde radyoloji ve ortopedi doktorları için bir karar destek sistemi olarak kullanılmasının mümkün olduğu düşünülmektedir. Bu kapsamda gerçekleştirilen sistemlerin yakın gelecekte MR iş istasyonu yazılımlarında modüller halinde bulunması öngörülmektedir. Bu sebeple önerdiğimiz sisteme benzer sistemlere olan ihtiyaç daha belirgin hale gelmektedir. Bu çalışma sayesinde insan vücudunda yer alan benzer şekilde bozulabilir dokuların bölütlenmesi ve analizi üzerine gelecekte yapılacak çalışmalara da ışık tutmaktadır.

1.3 Hipotez

MR görüntüleme, diz eklemlerinde kullanılan, invaziv olmayan (vücuda cerrahi bir girişim yapılmayan) değerlendirmeleri sayesinde son yıllarda altın standart haline gelmiştir. Başarılı yumuşak doku kontrastı, yüksek mekansal çözünürlük ve çok düzlemli görüntüler sayesinde MR, diz eklemi anatomisini ve ilişkili patolojileri doğru bir şekilde gösterir. Diz eklemi MR görüntülerinde anatomik yapıların değerlendirilmesi oldukça zordur. Çünkü diz eklemiindeki menisküs ve kıkırdak gibi yapılar belirgin şekilleri olmayan bozulabilir yapılardır. Bu bozulmalar belli sınıflandırmalara tabi olsalar da kişiden kişiye farklılık gösterebilir. Öte yandan bu anatomik yapılar aynı MR cihazıyla elde edilse bile kesitten kesite anatomik yapıların şekillerinde ve konumlarında değişiklikler olabilmektedir. Bunun yanı sıra görüntüler elde edilirken hastaların hareket etmesi sebebiyle görüntülerde kaymalar oluşabilmektedir. Bu durum radyoloji uzmanının gözlemlediği MR görüntüsünde hatalar yapmasına sebep olabilmektedir. Aynı zamanda görüntüler üzerinde oluşabilen gürültüler de hatalı değerlendirmelere yol açabilmektedir.

Menisküs yırtıklarının tam ve doğru olarak değerlendirilmesi, radyoloji uzmanının doku bozukluklarının şekillerinden ve kıkırdak dokuların karmaşık yapılarından haberdar olması ile doğrudan ilgilidir. Yani menisküs yapılarının elle bölütlenmesi ve yırtıkların el ile değerlendirilmesi radyoloji uzmanlarının tecrübesi ile ilişkilidir. Aynı zamanda MR görüntülerinin değerlendirilmesi hataya açık olması ile birlikte zaman alıcı karmaşık bir işlemdir. Tek bir MR görüntüsünün değerlendirilmesi radyoloji uzmanlarının yaklaşık 30-35 dakikalarına mal olmaktadır [84].

Bu tez çalışması bahsedilen bu problemlerin çözümünün bilgisayar destekli otomatik bir bölütleme yaklaşımı ve yırtıkların teşhisini sağlayan bir bilgisayar destekli otomatik teşhis sistemi ile sağlanacağı hipotezi üzerine kurulmuştur. Ayrıca literatürde menisküs yırtıkları ile ilgili bu güne kadar yapılmış çalışmalarda sadece menisküslerin yırtık olup olmadığı üzerinde durulmuştur. Menisküs yırtıklarının hangi bölgede ve hangi tipte olduğu üzerine şu ana kadar yapılmış bir çalışma bulunmamaktadır. Gerçekleştirilen sistemin bu açığı kapatacağı öngörülmektedir.


DİZ EKLEMİ VE DİZİN ANATOMİK YAPISI

Tez çalışmamız diz eklemi üzerinde yer alan menisküs dokuları üzerine incelemeler gerçekleştirmektedir. Bu sebeple insan diz anatomisinin detaylarının verilmesi önemli görülmektedir. Çalışmamızın bu bölümünde diz ekleminin anatomik yapısı ve dizde oluşabilecek başlıca rahatsızlıklardan bahsedilecektir.

2.1 Diz Eklemine Oluşturan Yapılar


Diz eklemi insan vücudundaki en güçlü ve en önemli eklemlerden biridir. Vücut ağırlığını taşıırken aynı zamanda vücudun hareket kabiliyetini sağlar. Diz eklemindeki hareketler, yürüme, koşma ve oturma gibi birçok gündelik etkinlik için gereklidir.

Diz aynı zamanda tibiofemoral eklem olarak da bilinmektedir [85]. Bu tibiofemoral eklem Şekil 2.1'den de görüldüğü gibi dört farklı kemikten yapılmıştır. Bu kemikler diz ekleminin üst, kalçanın da alt kısmında bulunan uyluk, diz ekleminin alt kısmında bulunan kaval, kaval kemiğinin sol arka kısmında kamış (fibula) ile uyluk ve kaval kemiklerinin birleşme noktalarında dizi ön kısmından saran diz kapağından (patella) oluşmaktadır.



Şekil 2. 1 Sağ dizin önden ve yukarıdan görünümü [86]

Diz ekleminde bu kemiklerin dışında her birinin ayrı ayrı görevleri olan ligamentler, tendonlar, kıkırdaklar, bursalar, menisküsler ve eklem kapsülleri gibi yapılarda bulunmaktadır [87]. Diz ekleminde yer alan yapıların detaylı gösterimini Şekil 2.2'den görmek mümkündür.



Şekil 2. 2 Diz ekleminin detaylı gösterimi [88]

Devam eden bölümde bu yapıların diz eklemine ne gibi katkılar sağladığına dair bilgiler verilecektir.

2.1.1 Kemikler

Kemikler diz eklemine esnekliğini ve dengesini sağlayan yapılardır. Dizde kaval, uyluk, diz kapağı ve kamış olmak üzere dört farklı kemik bulunmaktadır. Genelde parlak kemik adı verilen kaval dizden ayak bileğine kadar uzanmaktadır. Kaval kemiğinin üstü, iki plato ve tibial tüberkül adı verilen bir mafsalları benzeri çıkıntıdan oluşur [87]. Kavalın iki yanında bulunan şok emici kartilajlar dizin dengesinin sağlanmasına yardımcı olurlar. Diz kapağı düz, üçgen görünümlü bir kemiktir. Diz kapağının görevi diz büküldüğünde ya da düzleştirildiğinde, diz eklemine korumak için kemiklerle kaslar arasındaki sürtünmeyi hafifletmektir. Diz kapağı, uyluğun alt ön yüzeyi boyunca, femoral kondiller adı verilen iki çıkıntı arasında süzülür. Bu kondiller patellofemoral oluk adı verilen bir oluk oluştururlar. Uyluk kemiği vücuttaki en büyük, en uzun ve en güçlü kemiktir. Kemik ucundaki yuvarlak düğmelere kondil denir. Kamış, dizin alt kısmında yan bacakta ince uzun kemiktir ve dizden ayak bileğine doğru kaval kemiği ile yan yana uzanmaktadır [87], [89].

2.1.2 Bağlar (Ligamentler)

Bağların fonksiyonu, kemikleri birbirine bağlayarak dizin dengesinin sağlanmasıdır. Bağlar, esnekliği çok iyi olmayan ancak sağlam ve güçlü yapılardır. Bağların hangi kemikleri birbirlerine bağladığına göre çeşitleri bulunmaktadır [86].

İç yan bağ (Medial Collateral Ligament), femur kemiğinin orta kısmını kaval kemiğinin iç kısmına bağlar ve dizin yanal hareketlerini sınırlar. Dış yan bağ (Lateral Collateral Ligament) ise uyluk kemiğinin dış tarafını kamış kemiğinin dış yanına bağlar ve dizin yanal hareketini sınırlar [90].

Ön çapraz bağ sayesinde kaval ve uyluk kemikleri diz eklemine ortasına bağlanır; dizin derinliğinde ve arka çapraz bağın ön kısmında yer alır. Kaval kemiğinin dönmesini ve ileriye doğru hareketini sınırlar. Arka çapraz bağ dizdeki en güçlü bağ yapılarıdır. Kaval ve uyluk kemiklerini birbirine bağlar. Dizde arkaya doğru olan itmelerde dengenin sağlanması arka çapraz bağın görevidir [85], [90]. Bağların diz eklemine yerleşimlerini Şekil 2.2'den görmek mümkündür.

2.1.3 Tendonlar

Tendonlar teknik olarak kasın bir parçası olan ve kasları kemiklerle birleştiren elastik dokulardır [87], [91]. Tendonların çoğu dizin dengesinin sağlanmasında görevlidir. Dizde kuadriseps ve patellar olmak üzere iki büyük tendon vardır. Kuadriseps tendonu uyluğun kuadriseps kaslarını diz kapağına bağlar ve dizin düzeltilmesi için güç sağlar. Ayrıca, uyluk kemiği içerisindeki patellofemoral olukta bulunan diz kapağının tutulmasına da yardımcı olur. Patellar tendon, diz kapağını kaval kemiğine bağlar [87], [89], [91].

2.1.4 Kıkırdaklar

Kaval ve uyluk kemiklerinin birbirlerine temas ettikleri yüzeyler eklem kıkırdağı ile korunmaktadır. Kemiklerin karşılıklı hareketlerinde eklem kıkırdağı, kemiklerin uçlarını örter ve kemiklerin ortak hareket etmelerine olanak sağlar. Dizin eklem kıkırdağı uyluğun uçlarını, kavalın üstünü ve diz kapağın arka kısmını kaplar. Diz ortasında şok emici olarak işlev gören menisküslü disk yastıkları bulunur [85], [89], [90].

Menisküs dokuları yarım ay biçiminde kaval ve uyluk kemikleri arasında yer alan dokulardır [92]. En önemli görevi, diz üzerine yapılan yükün yumuşatılması ve aşınmayı önlemesidir [93]. İnsan vücudunda her diz ekleminde biri dizin iç kısmında (medial) diğeri dış kısmında (lateral) olmak üzere iki çeşit menisküs bulunmaktadır. Dış menisküs iç menisküse göre daha hareketlidir. Bu sebeple yırtık oluşma ihtimali iç menisküste daha fazladır. Menisküs yırtıkları, diz ekleminde sıklıkla kıkırdak ve kemik bozulmasına neden olur. Menisküsün bir başka görevi ise eklem kıkırdağını korumaktır. Ana işlevi, tibiofemoral eklem içindeki temas alanını maksimize etmek ve temas stresini en aza indirmektir. Bu eklemin temas mekaniği, menisküs yırtıkları nedeniyle kolayca değişebilir. Dahası, artiküler kıkırdak metabolizmasının yapısı bozulabilir ve bu da dizi erken osteoartrite için risk altına sokar [94]. Menisküs yırtıkları özellikle genç yaşlardaki sporcularda ortaya çıkan bir rahatsızlıktır. Çoğunlukla ani dönme hareketi olarak bilinen hareket sonucunda menisküs yırtıkları oluşabilmektedir. Menisküs yırtıklarının teşhisi radyoloji uzmanları tarafından konulmaktadır.

Eklem kıkırdağı herhangi bir eklemdaki tüm kemiklerin uçlarında bulunur; diz ekleminde uyluk ve kaval kemiğinin uçları ile diz kapağının arka kısmı kaplıdır. Eklem kıkırdağı, sinovyal membran (ortak astar) tarafından yapılan sinovyal sıvı (yumurta beyazı gibi

görünür) tarafından kaygan halde tutulur. Kıkırdak pürüzsüz ve kaygan olduğundan, kemikler birbirlerine karşı kolayca ve ağrısız hareket eder [87], [90], [91].

Vücudumuzdaki ağırlık taşıyan kemikler genellikle eklem kıkırdağıyla korunur; bu kıkırdak, sinovyal sıvı ile yağlanan ince, sert, esnek, kaygan bir yüzeydir. Sinovyal sıvı, herhangi bir aşınma olmadan diz üzerine yapılan baskıların yumuşatılmasına da yardımcı olan sıvıdır [85], [89].

2.1.5 Kaslar

Bacaktaki kaslar dizin kararlı ve hareketli olmasına olanak sağlar. Dizdeki en bilinen kaslar kuadriseps ve hamstringlerdir. Kuadriseps, uyluğun ön tarafında bulunan dört farklı kas topluluğundan oluşur ve eğilmiş bir dizin düz bir konuma getirilerek dizin düzeltilmesinden sorumludur. Hamstrings kasları ise, uyluğun arkasındaki üç kas grubundan oluşmaktadır ve dizin düz bir konumdan bükülmüş bir konuma geçmesini sağlar [85], [89], [90], [91].

2.1.6 Eklem Kapsülü

Eklem Kapsülü, kemiklerin uç uca birleşmesiyle oluşur. Koruyucu özellikte sert bir bağ dokusundan oluşmaktadır. Kıkırdak dokuların üst kısımları ince bir zara benzeyen sinovyal membran hücre ile kaplıdır. Bu hücre içerisinde yer alan sinovyal sıvı diz için yağlama sağlar [85], [89], [90], [91].

2.1.7 Bursalar

Diz çevresinde ve etrafında çeşitli boyutlarda 13 bursa bulunur. Bu sıvı dolu kese tamponlar, kaslar, kemikler, tendonlar ve bağlar arasındaki sürtünmeyi azaltarak rahat bir şekilde çalışmalarını sağlar. Prepatellar bursa, en önemli bursalardan biridir ve dizin ön tarafında diz yüzeyinin hemen altında bulunur ve diz kapağını korur [85], [89], [90].

2.2 Diz Eklemi Rahatsızlıkları

Diz vücuttaki yükün taşınmasında birincil göreve sahip eklemdir. Diz eklemine sürekli hareket halinde olması sebebiyle rahatsızlık oluşma ihtimali de artmaktadır. Diz

ekleminde en sık ortaya çıkabilecek rahatsızlıklar menisküs dokularının zarar görmesi ve osteoartrite, yani diz eklem kıkırdığının kireçlenmesidir.

2.2.1 Osteoartrite

Dejeneratif eklem hastalığı veya dejeneratif artrit de denen osteoartrite (OA), eklemlerde en sık görülen rahatsızlıklardandır. OA her eklemi etkileyebilir, ancak çoğunlukla diz, kalça, bel ve boyun, parmakların küçük eklemlerinde sıklıkla görülür.

Sağlıklı eklemlerde, kıkırdak adı verilen sağlam, kauçuk bir materyale benzeyen bir yapı kemiklerin yüzeyini kaplar. Kıkırdak dokular, eklem hareketlerinin gerçekleşmesine fayda sağlar ve kemikler arasında bir yastık görevi görür. OA rahatsızlığında kıkırdak dokusu zarar görür ve ağrıya neden olur. Erken tanı yapılmazsa zamanla daha kötüye giderek kemik yapılarının aşınmasına sebep olur [95].


OA rahatsızlığı orta yaş grubunda ve genellikle 65 yaş üstü insanlarda görülür. Yaş ilerlemesi sebebi ile kıkırdak dokulardaki aşınmalar neticesinde rahatsızlık meydana gelir. Osteoartrite tedavisinin amacı, ağrıyı azaltmak ve eklem fonksiyonlarını geliştirmektir. Hastalık için herhangi bir tedavi yoktur, ancak bazı tedaviler hastalığın ilerlemesini yavaşlatmaya çalışmaktadır.

Osteoartrite en sık diz eklemlerinde görülür. Bu eklemlerde osteoartrite oluştuğunda, kemiklerin uçlarını kaplayan kıkırdakların giderek pürüzlendiği ve incelendiği görülür. Kıkırdakın altındaki kemik kalınlaşarak tepki verir ve daha da genişler. Sanki vücut hasarı onarmaya çalışıyormuş gibi eklem içindeki tüm dokular normalden daha aktif hale gelir. Eklem kenarındaki kemik dışı doğru büyür ve osteofit olarak adlandırılan kemik çıkıntıları oluşur. Bu, diz kapağına, uyluk ve kaval kemiğine etki edebilir. Genellikle görülen belirtiler [96];

- Sinovyum şişer ve daha sonra eklem şişmesine neden olan ekstra sıvı üretmeye başlar. Buna genellikle efüzyon veya dizin sulanması denir.
- Kapsül ve bağlar, yavaş yavaş kalınlaşır ve sanki eklemi dengelemeye çalışıyormuş gibi kasılmaya başlar.


Eklem içindeki ve etrafındaki bu değişiklikler kısmen iltihaplanma sürecinin ve vücudun hasarı onarmaya çalışması sonucunda ortaya çıkmaktadır. Birçok durumda, onarımlar

oldukça başarılıdır ve eklem içindeki değişiklikler çok ağrıya neden olmaz veya ağrı varsa hafif olur. Bununla birlikte, diğer durumlarda, onarım da işe yaramaz ve diz hasar görür. Bu durum eklem diğer kısımlarına daha fazla ağırlık verilmesine yol açarak, belirtilerin zamanla kademeli olarak daha kötü ve daha kalıcı hale gelmesine neden olabilir [96].



Şekil 2. 3 Sağlıklı diz görüntüsü [96]

Şekil 2.3 ve 2.4'te sağlıklı ve osteoartrite olmuş diz görüntüleri yer almaktadır. Bu görüntüler yardımıyla hangi dokularda ne tür bozulmalar olduğunu görmek mümkündür.




Şekil 2. 4 Osteoartrite olmuş diz görüntüsü [96]

2.2.2 Menisküs Yırtıkları


Menisküs yapılarında yer alan doku bozuklukları (lezyon) için Stoller ve Crues [97],[98] yaptıkları çalışmalarda 3 seviyeli bir sınıflandırma sistemi önermişlerdir. Bu sınıflandırma sisteminde menisküslerdeki bozulma miktarlarına göre seviyeler 1'den 3'e doğru artmaktadır. Yapılan çalışmalarda önerilen bu sınıflandırma sistemi için % 87-97 duyarlılık, %89-98 özgüllük ve % 88-95 güvenilirlik değeri ölçülerek 3 seviyeli sınıflandırma kullanımının güvenilir olduğunu göstermişlerdir [99]. Sadece seviye 3 bozulma için (eklem ile etkileşimde doğrusal yüksek yoğunluklu sinyal) patolojik demek doğru olacaktır. Meniskal bozulmanın konumuna ve ciddiyetine bağlı olarak değişen sinyal yoğunluğu bulunmaktadır.

1. seviye doku bozuklukları Şekil 2.5'te görüldüğü gibi eklem yapısının dışında dağınık bir bölgede meniskal bozulmanın erken safhalarında ortaya çıkan düşük sinyalli yapıdır.


2. seviye doku bozuklukları ise Şekil 2.6'te görüldüğü gibi menisküsün alt yüzeyine uzanmadan yüksek yoğunluklu bir sinyal üreterek düzgün yatay bir görüntüdedir. Bu bozulmada ortaya çıkan sinyaller 1. seviyeye göre daha kapsamlıdır, ancak menisküsün bölünmesi yada yırtılması durumu henüz oluşmamıştır. 1.seviye bozulmaların ilerlemiş çeşitleri olarak değerlendirmek mümkündür. 3. seviye bozulmaları yırtık olarak değerlendirmek mümkündür. Bu tip bozulmalar Şekil 2.7'de görüldüğü gibi menisküste yüksek seviyede sinyaller oluşturur ve menisküsün geniş bir bölümüne yayılarak eklem yüzeyine kadar uzanır.



Şekil 2. 5 Seviye 1 (Grade 1) menisküs bozuklukları. (a) T2 uyarım dizili koronal düzlem MRG; (b) T2 uyarım dizili sagittal düzlem MRG; (c) Proton ağırlıklı uyarım dizili koronal düzlem MRG; Proton ağırlıklı uyarım dizili sagittal düzlem MRG; (e) seviye 1 bozukluk için üç boyutlu görüntü [100]



Şekil 2. 6 Seviye 2 (Grade 2) menisküs bozuklukları. (a) T2 uyarım dizili koronal düzlem MRG; (b) Proton ağırlıklı uyarım dizili koronal düzlem MRG; (c) T2 uyarım dizili sagittal düzlem MRG;(d) Proton ağırlıklı uyarım dizili sagittal düzlem MRG; (e) seviye 2 bozukluk için üç boyutlu görüntü [100]




Şekil 2. 7 Seviye 3 (Grade 3) menisküs bozuklukları. (a) T2 uyarım dizili koronal düzlem MRG; (b) Proton ağırlıklı uyarım dizili koronal düzlem MRG; (c) T2 uyarım dizili sagittal düzlem MRG;(d) Proton ağırlıklı uyarım dizili sagittal düzlem MRG; (e) seviye 3 bozukluk için üç boyutlu görüntü [100]

Menisküs yırtıkları genellikle diz bükülürken veya ani dönme hareketi denilen hareketle oluşur. Menisküs yırtıkları ağır kaldırıldığında veya spor yaparken ortaya çıkabilir.

Yaşlandıkça menisküs aşınır. Bu, daha kolay menisküs yırtığı oluşmasına neden olur [101], [102] . Menisküs yırtığı oluşan bir diz ekleminde ortaya çıkan belirtiler şu şekildedir;

- Dizde ağrı meydana gelmesi
- Hareket kabiliyetinde sınırlamalar oluşması
- Dizde boşalma hissi
- Diz ekleminde şişlik oluşması
- Diz ekleminde kilitlenmelerin olması

Menisküs yırtıklarında, yırtığın tipi belirtilerin oluşmasında etkilidir [103]. Menisküs yırtık tipleri yırtığın şekline, konumuna ve boyutuna göre çeşitlenmektedir. Literatürde yer alan çalışmalarda şekillerine göre menisküs yırtıkları için en sık kullanılan yırtık tipleri Şekil 2.8’de görülmektedir.



Şekil 2. 8 En yaygın menisküs yırtık tipleri [104]

Boylamasına (Longitudinal, Vertical) yırtıklar, menisküsün çevresel dokularına ve menisküsün dış kenarına paralel doğrultuda dikey veya uzunlamasına gerçekleşen yırtıklardır. Boylamasına yırtıkların büyük bölümü iç menisküsün ortasında ve arka

boynuzunda meydana gelir. Dış menisküste ise ACL yırtıldığında arka boynuzda yaygın olarak görülür. Yırtığın yapısındaki duruma göre “kova sapı” yırtık olarak da adlandırılabilir. Bu yırtık tipi genellikle eklem bölgesinde kayma ya da kilitlenme olan genç atletlerde görülür. İç menisküste dış menisküsten üç kat fazla görülür. Çevresel yırtıklar, menisküsün üçte birlik çevre bölgesinde bulunan dikey veya uzunlamasına yırtıklardır. Kendi kendilerine iyileşme özelliği gösterebilen yırtıklardır. Radyal yırtıklar, genellikle arka boynuzlarda ve orta kısımlarda yer alan enine yırtıklardır. Yanal menisküste daha sık görülürler ve genellikle ACL yırtıkları ile ilişkilendirilirler. Menisküsün üçte birlik bölümü olan avasküler kısımda meydana gelen radyal yırtıkların iyileşme potansiyeli azdır. Genellikle travmatiktirler ve daha genç, fiziksel olarak aktif hastalarda görülürler. Yatay (Horizontal) yırtıklar yaşlı insanlarda sık görülür. Bu yırtıklar menisküsü üst ve alt katmanlara böler. Bu tip yırtıkların iyileşme kapasitesi azdır veya hiç yoktur. Karmaşık yırtıkların çoğunlukla bu yırtık tipinden türediği düşünülmektedir. Oblik yırtıklar; flep veya papağan gagası yırtıkları olarak da bilinir; bunlar eğik ve dikey ayrılma yırtıklarıdır ve genellikle menisküsün arka boynuz ile orta kısmın birleşme bölgelerinde görülürler. Karmaşık yırtıklar, yaşlılarda yaygındır. Yırtıklar birden fazla düzlemde oluşur ve yukarıdaki yırtıkların bir araya gelmesi ile ortaya çıkar. Kök (Root) yırtıklar, arka veya ön boynuzların merkez bölgelerinde görülen menisküs yırtıklarıdır. Travmatik yırtıklar, belirli bir travmatik yaralanma olayının sonucu olarak ortaya çıkan yırtıkları tanımlamak için kullanılan ve dikey, kova sapı ve radyal yırtıkları içeren bir karma yırtıktır. Travmatik yırtıklar normalde daha genç yaştaki aktif spor yapan kişilerde görülür. Menisküs tipik olarak uzunlamasına bir doğrultuda bölünür. Menisküsün orta kısmı merkezi olarak yerinden oynayabilir ve dizin kilitlenmesine neden olabilir. İç menisküste travmatik yaralanma daha sık görülür. Dejeneratif yırtıklar, dejeneratif süreçlere bağlı olarak ortaya çıkan yırtıkları tanımlamak için kullanılan ve yatay, flep ve karmaşık yırtıkların yanı sıra meniskal dejenerasyon ve yıkımı da içeren bir yırtık türüdür.


MANYETİK REZONANS GÖRÜNTÜLEME (MRG)

Manyetik Rezonans Görüntüleme (MRG) invaziv olmayan bir yöntem olması, yüksek kalitede görüntü oluşturabilmesi ve radyo frekans (RF) sinyallerine bağlı olarak vücuda zarar vermeden çalışması sebebiyle birçok hastalığın teşhisinde ve klinik araştırmalarda kullanılan en önemli tekniklerden birisidir. Görüntüleme teknikleri içerisinde en sık kullanılan yöntemlerden birisi olan MRG’de görüntü sinyallerinin nasıl oluşturulduğu, uyarım dizileri ve diz eklemine MRG’ye ait teknik detaylar bu bölümde verilecektir.

3.1 MRG’nin Temelleri

MR görüntüleme 1980’lerin başında klinik tanı ve tedavilerde kullanılmaya başlanmıştır [105]. O günden beri sıklıkla kullanılan bir tanı koyma yöntemine dönüşmüştür. Manyetik rezonans görüntülemeyi en basit haliyle güçlü bir manyetik alan içerisinde atom çekirdeğinin davranışlarının görüntülenmesi olarak tanımlamak mümkündür. Yüksek çözünürlükte görüntü üretebilmesinden dolayı birçok rahatsızlığının teşhisinde altın standart haline gelmiştir. Standart bir MRG cihazı su ve yağ moleküllerinde yer alan hidrojen atomunun titreştirilmesiyle elde edilen sinyaller yardımıyla görüntüyü oluşturmaktadır. MR radyo frekans sinyalleri ile görüntü oluşturduğu ve radyasyon içermediği için vücuda zararsız çalışmaktadır.

MRG’nin tercih edilme sebepleri arasında yumuşak dokuların görüntülenmesindeki yüksek başarısı yer almaktadır. MR aynı zamanda üç boyutlu hacimsel görüntü oluşturabilme yeteneğine sahiptir. Bunun yanı sıra MR Şekil 3.1’de görüldüğü gibi sagittal, koronal ve aksiyal olmak üzere üç farklı düzlemde görüntü üretebilmektedir. Örneğin bilgisayarlı tomografi sadece aksiyal düzlemde görüntü üretebilmektedir.



Şekil 3. 1 MR görüntülerde elde edilebilecek farklı düzlemler [106]

3.1.1 Sinyal Üretimi

MR görüntüleme, klasik mekanikteki açısal momentuma benzeyen çekirdeklerin dönme hareketlerinin fiziksel olgusuna dayanır. Bir protonun pozitif elektrik yüklü bir dönme parçacığı olduğunu varsayalım. Elektrodinamik yasalarından yola çıkarak, bu cismin manyetik bir momenti olması gerekir. Bu manyetik moment, iletken bir döngüde hareketli yüklerin neden olduğu manyetik alana benzetilen belirli bir uzunluk ve yöne sahip bir vektör olarak tanımlanabilir. Temel fizik kurallarına göre kütle, maddenin yerçekimi alanı ile etkileşiminden sorumlu olan özelliğidir. Yük, elektrik alanı ile etkileşime girer. Dönmeye bağlı manyetik moment, maddenin manyetik alanla etkileşimi ile ortaya çıkar. MR’da bu özelliği kullanmaktadır [107], [108], [109].

Çekirdeklerin temel özelliği, genellikle dönme (spin) olarak adlandırılan açısal momentumlara sahip olmalarıdır. Dönme hareketine sahip olan her çekirdek kendi

ekseni etrafında döner. Faraday'ın indüksiyon yasasına göre çekirdek ile ilişkili net bir elektrik yükü varsa, bu çekirdeğin etrafında bir manyetik alan oluşur. Örneğin H bir protona sahiptir ve bu nedenle net açısal momentumu vardır. Bununla birlikte, normal koşullar altında, rastgele hareket neticesinde sıfır net mıknatıslanma nedeniyle manyetik alanın yönü rastgeledir. Görüntüleme amacıyla, rastgele hareketin etkisini ortadan kaldırmaya yarayan hacimsel manyetik alan oluşturmak için güçlü bir harici manyetik alan gereklidir. Statik manyetik alanlar herhangi bir sinyal üretmediğinden, bu tutarlılık yalnızca tespit edilebilir bir sinyal üretmek için yeterli değildir. Tutarlılık oluştuğunda, manyetik alanın yönünü değiştirmek için sisteme bir giriş sinyali (RF uyarımı) uygulanır ve bu manyetik alana bir değişiklik getirir ve çıkış sinyali olarak kaydedilecek bir yanıt üretir. Bu sinyallerde bir alıcı sayesinde kaydedilerek MR görüntüleri oluşturulmaktadır [107].

3.1.2 MRG'de Uyarım Dizileri

MRG'de elde edilen görüntü sinyalleri radyo frekansları (RF) yardımı ile oluşturulmaktadır. Yüksek bir manyetik alan içerisinde hidrojen atomlarının çekirdeğinde bulunan proton atomları yörüngelerinden sapıp manyetik alan vektörüne paralel bir şekilde dizilirler. Ardından radyo frekanslar yardımıyla enerji gönderilir ve dizilmiş olan protonlar bu enerji sayesinde yörüngelerinden saparlar. Enerji kesildiğinde ise protonlar eski konumlarına geri dönerler. Bu dönüş esnasında aldıkları enerjiyi geri bırakırlar. Ve bu enerji sayesinde görüntü sinyalleri oluşur.

Radyo frekans sinyallerinin bitişi ve protonların eski hallerine dönüşü her doku için farklı sürelerde gerçekleşmektedir. Radyo frekans sinyalleri ardışık olarak uygulanmaktadır. İki RF uyarımı arasında geçen süreye de T_R (repetition time) süresi denmektedir. Bu süre dokular arasındaki geriye dönüş süresinde (T_1) farklılıkları ortaya çıkarmaktadır. Sinyal dinleme süresinde (T_E) dokular arasındaki sinyal bitiş süresindeki farklılıkları oluşturmaktadır. Bu şekilde T_R ve T_E süreleri sayesinde oluşturulan görüntü elde etme protokollerine uyarım dizileri adı verilir [110].

MR cihazlarında görüntünün oluşturulmasında yinleme zamanı (repetition time) T_R ve dinleme zamanına (echo time) T_E 'ye göre farklı uyarım dizilerinde görüntüler oluşturulur. Bu uyarım dizilerinden en bilinenleri T_1 , T_2 ve proton ağırlıklı uyarım dizileridir. T_1 ağırlıklı

uyarım dizisinde T_R ve T_E kısa, T_2 ağırlıklı uyarım dizisinde T_R ve T_E uzun, proton ağırlıklı uyarım dizisinde ise T_R uzun T_E kısadır. Bu uyarım dizilerinden farklı olarak radyo frekans sinyallerinin titreşiminin açısına ve diğer özelliklerin yapısına bağlı olarak değişik uyarım dizileri elde edilebilmektedir. Bizim tez çalışmamızda kullanmış olduğumuz veri seti denge durumunda su uyarımlı çift yankılı (water excitation double echo steady state (weDESS)) uyarım dizisine göre görüntü oluşturmaktadır. Bu uyarım dizisi Siemens firmasına ait ticari markalı bir üründür. weDESS’de yinleme süresinin (T_R) kısa olması bir sonraki RF darbesi uygulanmadan önce enine manyetizasyonun bozulmasını önler. İkinci olarak, kesitlerde seçilen RF darbesi eşit aralıklarla yerleştirilir. Aynı çevirme açısına sahip faz uyumlu RF darbeleri, T_2 dokusundan daha kısa bir sabit T_R ile uygulanırsa, enine ve boyuna manyetizasyon arasında dinamik bir denge sağlanır. weDESS harekete karşı çok hassastır, bu yüzden kullanımı öncelikle 3D diz görüntülemesi gibi ortopedik uygulamalarla sınırlıdır. weDESS özellikle eklem kıkırdaklarının tespiti için oluşturulmuş bir uyarım dizisidir [111]. Üç boyutlu denge durumunda su uyarımlı çift yankılı uyarım dizisi (3D-weDESS), diz kıkırdağının manyetik rezonans görüntüleme ile daha iyi değerlendirebilmek için uyarım dizisi parametrelerini belirlemiştir. Yaygın olarak kullanılan flip açısı (FA) değerleri ile kıkırdak ve sinovyal sıvı arasındaki yoğunluk, kıkırdak yüzeyinin küçük doku bozukluklarını tanımlamak için çok düşük tutulmuştur [111].

Çizelge 3.1’ de incelemiş olduğumuz çalışmalara ait kullanılan cihazların manyetikleme yetenekleri, uyarım dizileri, görüntüleme düzlemi, çözünürlük değerleri ve kesit kalınlıkları görülmektedir. Kullanılan cihazların genellikle yüksek alan tarayıcılar olduğunu manyetikleme yeteneklerinden görmek mümkündür. Yüksek alan tarayıcıların yumuşak dokuların görüntülenmesinde daha yüksek çözünürlükte sonuçlar üretmesi tercih edilme sıklığını arttırmaktadır. Bunun yanı sıra farklı uyarım dizilerinin genellikle sagittal düzlemde elde edilmiş görüntülerinin kullanıldığı da çizelgeden görülmektedir. Diz eklemesindeki yapıların anatomik olarak değerlendirmesinde ve bilgisayar destekli sistemlerle gerçekleştirilmesinde sagittal düzlemin bir adım önde olduğunu söylemek yanlış olmayacaktır. Bölüm 3.3’te bu konuyla alakalı daha detaylı bilgiler yer almaktadır.

Çizelge 3. 1 Literatürdeki incelediğimiz çalışmalarda kullanılan MR cihazlarının manyetikleme yetenekleri, uyarım dizileri, görüntü düzlemi, çözünürlüğü ve kesit kalınlığı

Yazar(lar) ve Yılı	Manyetikleme Yeteneği (Tesla)	Uyarım Dizisi	Görüntüleme Düzlemi	Çözünürlük (mm)	Kesit Kalınlığı (mm)
Fripp vd. 2009	3	FS SPGR	Sagital	0.23/0.23	1.5
Swanson vd. 2010	3	T2	Sagital	0.3125/0.3125	3
Zhang vd. 2013	3	Çoklu	Sagital	0.625/0.625	1.5
Paproki vd. 2014	3	weDESS	Aksiyal	0.37/0.37	0.7
Dam vd. 2015	CCBR: 0.18 OAI: 3 SKI10: 1, 1.5, 3	CCBR: T1 OAI: weDESS SKI10=: Çoklu	Sagital	CCBR: 0.7/0.7 OAI: 0.36/0.36	CCBR: 0.8 OAI: 0.7
Bu Çalışma 2017	3	weDESS	Sagital	0.36/0.36	0.7

3.2 Diz Ekleminde Manyetik Rezonans Görüntüleme

Diz manyetik rezonans görüntülemesi (MRG) için güçlü bir manyetik alan ve radyo dalgaları kullanılır. Bu sayede diz eklemindeki yapıların ayrıntılı görüntülerini üretmek mümkündür. Genellikle diz ekleminde ve çevresinde ağrı, güçsüzlük, şişlik durumlarının teşhis edilmesinde ve değerlendirilmesinde kullanılır. Diz MRG, iyonlaştırıcı radyasyon kullanmaz ve cerrahi bir müdahale gerekip gerekmediğinin tespitinde kullanılır. Ayrıca MRG, vücuttaki yumuşak dokuların kemiklerle birlikte görüntülenmesini sağlar. Bu sayede diz üzerindeki aşınma ve yıpranmaların saptanmasını ve dizin kemikler, kıkırdak, tendonlar, kaslar, kan damarları ve bağlar gibi çeşitli bölümlerinin detaylı görüntülenmesini sağlar [112], [113], [114], [115], [116].

MR tarayıcılar manyetikleme yeteneğine göre sınıflandırılmaktadır. 1.5 Tesla'dan 9 Tesla'ya kadar olan tarayıcılar yüksek alan olarak, 1.5 Tesla'dan düşük olan MR tarayıcılar ise düşük alan tarayıcılar olarak adlandırılır. Son yıllarda yüksek alan tarayıcılar Çizelge 3.2'de yer alan özellikleri sayesinde tıbbi tanı koymada ve teşhis işlemlerinde sıklıkla tercih edilmektedir. Yüksek alan tarayıcıların görüntülenen anatomik yapıların yüksek kesinlikte şekli ve nicel değerlendirilmesine imkan sağlaması, gelecekte bu

değerlendirmeleri yapan yazılımların MR cihazlarına gömülmesiyle nicel MR tarayıcılar üretilmesini mümkün kılacaktır [117].

Çizelge 3. 2 Düşük alanlı tarayıcılarla yüksek alanlı tarayıcıların karşılaştırılması.

Düşük alanlı tarayıcılar	Yüksek alanlı tarayıcılar
Görece düşük kalitede görüntü üretir	Yüksek kalitede görüntü üretir.
Görüntüleme, kurulum ve bakım maliyeti düşük.	Görüntüleme, kurulum ve bakım maliyeti yüksek.
Düşük ses seviyesiyle hasta için rahatsız edici değildir.	Yüksek ses seviyesi hasta için rahatsız edicidir.
Görüntülenen anatomik yapıların şekli ve nicel değerlendirilmesine imkân sağlar.	Görüntülenen anatomik yapıların yüksek kesinlikte şekli ve nicel değerlendirilmesine imkân sağlar.

Yüksek alan tarayıcıların görüntülenen anatomik yapıların yüksek kesinlikte şekli ve nicel değerlendirilmesine imkan sağlaması, gelecekte bu değerlendirmeleri yapan yazılımların MR cihazlarına gömülmesiyle nicel MR tarayıcılar üretilmesini mümkün kılacaktır [117]. Dizde MR görüntülemeyi gerektirecek durumlara aşağıdakiler örnek olarak verilebilir [114], [116];

- Artrit ve diğer dejeneratif eklem rahatsızlıkları
- Kemik kırıkları
- Hasarlı kıkırdak, bağlar, tendonlar veya menisküs
- Diz eklemine hareketinin azalması
- Dizdeki sıvı birikimi
- Enfeksiyon ve tümörler
- Spor veya travmaya bağlı yaralanma

MRG'nin tercih edilme sebepleri oldukça fazladır. Bunun yanında MRG kullanımında oluşabilecek riskler az sayıda olsa da bulunmaktadır. Tercih edilme sebeplerini ve risklerini şu şekilde listelemek mümkündür [114], [116];

Tercih edilme sebepleri;

- MRG, iyonlaştırıcı radyasyona maruz kalmayı içermeyen, invaziv olmayan bir görüntüleme tekniğidir.
- MR, tendon, bağ, kas, kıkırdak ve kemik anormallikleri dahil olmak üzere geniş bir yelpazede koşulların teşhis edilmesinde değerli olduğunu kanıtlamıştır.

- MR, diz yaralanmaları olan hastaların cerrahi müdahale gerektirip gerektirmediğinin belirlenmesinde yardımcı olmaktadır.
- MRG, x ışınları ve diğer testler kesin sonuç vermediğinde kemik ile ilgili normal olmayan durumların teşhis edilmesine yardımcı olmaktadır.
- MR, diğer görüntüleme yöntemleriyle kemik tarafından örtülebilecek anormalliklerin keşfedilmesini sağlamaktadır.
- MR, kan damarlarının sorunlarının teşhisi için röntgen, anjiyografi ve bilgisayarlı tomografiye invaziv olmayan bir alternatif sunmaktadır.


Riskler;

- Güçlü manyetik alan kendi başına zararlı olmasa da, metal içeren implante edilmiş tıbbi cihazlar, MR incelemesi sırasında arızalanmakta veya sorunlara neden olabilmektedir.
- Nefrojenik sistemik fibroz şu anda, böbrek fonksiyonları zayıf olan hastalarda yüksek dozda gadolinyum esaslı kontrast maddenin enjekte edilmesinden kaynaklandığı düşünülen manyetik rezonans görüntülemenin bilinen fakat nadir görülen bir komplikasyonudur. Bir kontrast enjeksiyonu düşünmeden böbrek fonksiyonunun dikkatle değerlendirilmesi bu çok nadir komplikasyon riskini en aza indirmektedir.
- Kontrast madde enjekte edilirse alerjik reaksiyon riski çok düşüktür. Bu gibi reaksiyonlar genellikle hafiftir ve ilaçlarla kolaylıkla kontrol edilmektedir.
- Kurulum ve bakım giderlerinin maliyetli olması sebebiyle MR ile görüntüleme fiyatları da yüksektir.

3.3 Diz MR Görüntülerinde Sagittal, Koronal ve Aksiyal Düzlemler


MR görüntülerinde sagittal, koronal ve aksiyal olmak üzere üç düzlemde görüntüler elde edilebilmektedir. Ön çapraz bağın görüntülenmesi için (genellikle meniskal ve bağ doku bozuklukları) diz ekleminde sagittal görüntüler elde edilir. Her üç düzlemde de görüntüleme yararlı olsa da, tüm diziler tüm düzlemler üzerinde gerçekleştirilmemelidir. T1 ağırlıklı diziler sagittal düzlem üzerinde yapılırken T2 ağırlıklı diziler üç mekansal düzlemde (sagittal, koronal ve aksiyel) gerçekleştirilir [118].

Proton ağırlıklı yağ bastırılmış uyarım dizisinin sagital düzlemi menisküs görüntüsü için tasarlanmıştır (Şekil 3.2) [119]. Kıkırdak da bu uyarım dizisi ile iyi görselleştirilir, bu da rutin çalışmalar üzerinde özel yumuşak tonlamalı uyarım dizilerine olan ihtiyacı ortadan kaldırır [119].



Şekil 3. 2 Proton ağırlıklı yağ bastırılmış uyarım dizisi için sagital düzlemde örnek görüntü [119]

Koronal düzlemde proton ağırlıklı yağ bastırılmış dizi, özellikle bir yaralanmanın akut olduğu durumlarda anatomik yapıların değerlendirilmesi için tasarlanmıştır (Şekil 3.3) [119]. Menisküs yırtıkları da koronal planda saptanabilir.



Şekil 3. 3 Koronal düzlemde proton ağırlıklı yağ bastırılmış uyarım dizisi için örnek görüntü [119]

Şekil 3.4'te kullanmış olduğumuz veri seti içerisinde yer alan görüntülerden sagittal, koronal ve aksiyal düzlem için örnek MR kesit görüntüleri görülmektedir.



Sagittal Düzlem MR Kesiti

Koronal Düzlem MR Kesiti

Aksiyal Düzlem MR Kesiti

Şekil 3. 4 Veri seti içerisinde MR kesit görüntülerinde elde edilebilecek 3 farklı düzlem için örnekler

Literatürde gerçekleştirilmiş olan çalışmalardan [118]'de radyoloji uzmanları açısından menisküs yırtığı tanısında görüntü düzlemi grupları arasında istatistiksel olarak anlamlı bir fark gözlenmediği belirtilmiştir. Ancak diz MR görüntülerinde menisküslerin ve kıkırdak yapılarının otomatik tespit edilmesi için gerçekleştirilen çalışmalarda Çizelge 3.1'de de görüldüğü gibi en sık kullanılan düzlem sagittaldir. Sagittal düzlemde elde edilmiş görüntüler menisküslerin detaylı analizlerine imkan sağlayan görüntülerdir [114], [115], [116]

MANYETİK REZONANS GÖRÜNTÜLERİNDEN DİZ MENİSKÜSLERİNİN OTOMATİK BÖLÜTLENMESİ İÇİN BİLGİSAYAR TEMELLİ YENİ BİR YAKLAŞIM

Osteoartrite genellikle eklemlerde acı ve hareket kabiliyetinde azalma şeklinde ortaya çıkan bir rahatsızlıktır. Yaş ilerledikçe diz ekleminde osteoartrite oluşma riski artar. Diz osteoartritesi (OA) eklem kıkırdaklarının aşınması sonucunda kendini belli eder. Menisküs yırtıkları da OA rahatsızlığına sebep olabilir ya da rahatsızlığı tetikleyebilir. Öte yandan OA rahatsızlığı da kıkırdak dokularındaki zedelenmelerden dolayı menisküs yırtılmalarına sebep olabilir. Menisküslerin dize yapılan yükün taşınması ve diz eklemindeki sürtünmenin azaltılması gibi birçok önemli görevi vardır. Bu sebeple menisküslerin zarar görmesi dizdeki kıkırdakların da zarar görerek hareket yeteneğinin kısıtlanmasına sebep olabilir. Bu yüzden menisküs bölgelerindeki problemlerin erken tedavisi, ilerlemiş rahatsızlıkların ortaya çıkmasına engel olacak bir durumdur.

MRG erken tanı ve tedaviye olanak sağlayacak en sık kullanılan görüntüleme biçimlerinden birisidir. Vücuda zarar vermeden çalışıyor olması, invaziv olmayan bir yöntem olması ve yüksek kalitede görüntü üretebilmesi sebebiyle sıklıkla tercih edilmektedir. Ayrıca, MRG menisküsün nicel görüntü analizi için ideal bir yöntemdir. Çünkü erişilemeyen dokuların radyologlar tarafından ayrıntılı olarak görüntülenmesine imkan tanır [120]. Menisküs yaralanmalarının MRG ile saptanması %85-90'lık bir doğruluk derecesine sahiptir ve bu akut yaralanmış dizlerin tanı ve tedavisinde otomatik tespit yöntemlerinin geliştirilmesine sebep olmuştur [120]. Bu bulguların ışığında literatürde de en sık kullanılan görüntüleme yöntemi olması sebebiyle MRG bu çalışmada diz eklemi görüntülenmesinde kullanılmıştır.

Tez kapsamında yapmış olduğumuz bu çalışma, menisküs dokularının MR görüntülerinden otomatik bölütlenmesi için yeni bir yöntem önermektedir. Radyologlar, MR görüntülerinden menisküs bölgeleri için tanı koyarken değerlendirmelerini elle gerçekleştirirler. Bu zaman alan süreç, hastalığın teşhisini erteleyebilir. Buna ek olarak, elle bölütleme işleminde MR görüntülerini değerlendirenlerin neden olduğu hatalarla karşılaşılabilir. Bu konular, bu çalışmada yapılan otomatik bölütleme yaklaşımlarını motive etmektedir. İzleyen bölümlerde bu çalışmanın gerçekleşmesi için kullanılan materyal ve yöntemlerden, ardından elde edilen deneysel sonuçlardan bahsedilecektir.

4.1 Materyal ve Yöntem

Menisküsler daha önce Şekil 2.1’de gösterildiği gibi uyluk ve kaval kemikleri arasında yer alan hilal görünümünde kıkırdak yastıkçıklardır. Menisküsler hareket kabiliyetinin sağlanmasında, uyluk ve kaval kemiklerinin başlarını sararak diz eklemindeki sürtünmenin azaltılmasında görevlidir [121]. Bunların yanı sıra eklem yüzeylerinin uyumlu bir şekilde çalışmasında ve eklem sıvısının eklem içi dolaşımının sağlanmasında görevlidirler [122]. Menisküslerin zarar görmesi bu görevlerin sağlıklı bir biçimde gerçekleştirilmesine mani olur ve kıkırdak dokularında aşınmalar ortaya çıkar. Kıkırdaktaki aşınmalar da osteoartrite rahatsızlığını tetikler. Her diz ekleminde birisi dizin iç kısmında diğeri de dizin dış kısmında yer alan iki menisküs vardır. İç menisküslerin esnekliğinin dış menisküslere göre daha az olması sebebiyle menisküs yırtılmalarının %67’si iç, %33’ü de dış menisküste ortaya çıkar [123].


Literatürde bu alanda yapılan çalışmaların bir kısmında, kullanılan MR görüntüleri sadece sağlıklı insanların görüntülerinden oluşmaktadır [67]. Ancak böyle bir yaklaşım çok makul ve yerinde bir yaklaşım olmamaktadır. Yapılan değerlendirmelerin hem sağlıklı hem de sağlıklı olmayan menisküsler üzerinde gerçekleştirilmesi daha yerinde bir yaklaşım olacaktır. Bu sebeple gerçekleştirilen bu çalışmada yer alan katılımcıların dizlerinin Kellgren-Lawrence (K-L) dereceleri 2 ve üzerinde seçilmiştir [124]. K-L derecelendirmesi dizdeki OA rahatsızlığının seviyesine göre belirlenmektedir. Yok (0), Şüpheli (1), Minimal (2), Orta (3), Şiddetli (4) olmak üzere 5 farklı K-L seviyesi vardır. Bu sınıflandırma Kellgren ve Lawrence tarafından 1957’de önerilmiştir [124]. Çalışmada kullanılan veri setinin K-L dağılımı Çizelge 4.1’de görülmektedir.

Çizelge 4. 1 Sol ve sağ diz için K-L dereceleri

	Sol Diz / Sağ Diz				
	0	1	2	3	4
Erkek	0 / 1	6 / 7	7 / 7	24 / 26	8 / 4
Kadın	1 / 2	3 / 3	10 / 11	27 / 19	2 / 8
Toplam	1 / 3	9 / 10	17 / 18	51 / 45	10 / 12

Çalışmada kullanılan veri seti halka erişimi açık olan Osteoartrite Girişimi (OAI) veri tabanından elde edilmiştir. Veri seti içerisinde katılımcıların diz eklemlerinden düzenli olarak alınmış sagittal, koronal ve aksiyal düzlemin her üçünde de elde edilmiş tıbbi takip verileri ve referans gerçeklik verileri yer almaktadır. Diz eklemindeki rahatsızlığı ilerlemiş olan 1390 katılımcı, 3284 başlangıç seviyesinde olan katılımcı ve 122 kontrol grubundan oluşan toplamda 4796 katılımcıya ait veriler bulunmaktadır. Kullanılan her bir MR görüntüsü sagittal düzlemde denge durumunda su uyarımlı çift yankılı (weDESS) uyarım dizisi standardında, yüksek alan (3 Tesla) tarayıcılarla elde edilmiştir. Görüntüler kesit aralığı 0.7 mm olan 160 adet kesit görüntüsünden oluşmaktadır. Özetle veri seti içerisinde yer alan MR görüntüleri 384×384×160 boyutunda, satır, sütun ve kesitte 0.36 mm, 0.36 mm, 0.7 mm çözünürlüklerindeki yüksek alan diz görüntüleridir. Görüntüler başlangıç ve izleme verilerinden oluşmaktadır. İzleme verileri 12, 18, 24, 30, 36, 48 ve 72 aylık periyotlarda alınmış görüntülerdir. Veri seti içerisinde hem menisküs hem de kıkırdak dokuları için radyoloji uzmanları tarafından elle bölütlenmiş 88 adet referans gerçeklik görüntüsü bulunmaktadır.

Çalışmamızda referans gerçeklik verisine sahip 88 MR görüntüsünün tamamı kullanılmıştır. Otomatik bölütleme için gerçekleştirdiğimiz işlemlerin adımlarını Şekil 4.1'deki akış diyagramından görmek mümkündür.




Şekil 4. 1 Menisküs sınırlarının belirlenmesi için akış şeması

4.2 Bütünsel Sınırlayıcı Kutunun (Global Bounding Box) Bulunması

Veri setinde yer alan MR görüntülerinin her bir kesiti 384x384 piksel boyutundadır. Şekil 4.2’de veri setinden elde edilmiş, radyoloji uzmanları tarafından elle bölütlenmiş bir MR kesit görüntüsü ve bu görüntüyü çevreleyen bir bütünsel sınırlayıcı kutu (bounding box) görülmektedir. Şekilden de görüldüğü gibi menisküs gerçek görüntünün belli bir bölgesinde ve küçük bir alanda yer almaktadır.


Üzerinde işlem yapılan toplam 88 MR görüntüsü ve her bir MR görüntüsünde de 160 kesit olduğu düşünüldüğünde görüntünün tamamında işlem yapmak maliyetli bir işlem olmaktadır. Bu sebeple menisküs arama işlemi için görüntünün tamamının kullanılması yerine sadece menisküslerin yer alma ihtimallerinin olduğu daha dar bir alanda çalışma yapmanın zaman ve işlem maliyetini azaltacağı kanısına varılmıştır. Bunu sağlamak için veri setinde yer alan elle bölütleme verilerinden faydalanılmıştır. MR görüntülerindeki bütün kesitlerin belli bir bölümünde menisküsler görülmektedir. Referans gerçeklik verileri içerisinde menisküs yapılarının MR görüntülerinin hangi kesitlerinde ve bu kesitlerin hangi koordinatlarında olduğu bilgisi tutulmaktadır. İşte tam da bu noktada sınırlayıcı kutu elde etme işleminin doğru olacağı kanaatine varılmıştır. Bu işlem için her

bir MR görüntüsü içerisinde menisküslerin bulunduğu kesitlerin koordinatlarına bakılmış ve o MR görüntüsü için menisküslerin yer aldığı maksimum ve minimum koordinatlar belirlenmiştir. Bu işlemi bütün MR görüntüleri için uygulayıp bütünsel minimum ve bütünsel maksimum noktaları elde edilmiştir. Bu sayede Şekil 4.2'deki gibi bir sınırlayıcı kutu elde edilmiştir.



Şekil 4. 2 Bütünsel sınırlayıcı kutu içerisinde elle bölütlenmiş örnek MR kesit görüntüsü

Veri setinde yer alan tüm MR görüntülerinin bütün kesitlerinde gerçekleştirilen bu minimum ve maksimum koordinatlarının belirlenme işleminin ardından bütünsel sınırlayıcı kutunun boyutu 209×135 piksel olmuştur. 384×384 'lük mevcut arama bölgesi %80 oranında azalmıştır. Bu da işlem maliyetini oldukça düşürmüştür. Şekil 4.3'te 88 MR görüntüsünde HOG özelliklerinin çıkartılması için bütünsel sınırlayıcı kutu kullanıldığında geçen süreler (kırmızı çizgi) ve bütünsel sınırlayıcı kutu kullanmadan görüntünün tamamı kullanıldığında geçen süreler (mavi çizgi) görülmektedir. Bütünsel sınırlayıcı kutu kullanmadan görüntünün tamamında işlemler gerçekleştirildiğinde geçen süre yaklaşık olarak 14 saattir. Ancak bütünsel sınırlayıcı kutu ile bu süre 40 dakikaya düşmektedir. Bu da yapılan işlemin zaman maliyetini büyük ölçüde düşürdüğünü göstermektedir.



Şekil 4. 3 Görüntüsün tamamında ve bütünsel sınırlayıcı kutuda gerçekleştirme zamanları

4.2.1 Bütünsel sınırlayıcı kutu içerisinde alansal örtüşme hesabı


Veri setinde yer alan görüntüler incelendiğinde menisküslerin boyutlarının MR kesitlerinde farklılık gösterdiği tespit edilmiştir (Şekil 4.4). Bu yüzden en uygun menisküs çerçevesinin elde edilebilmesi için farklı büyüklüklerde pencerelerin gezdirilmesinin doğru olacağı kanaatine varılmıştır. 90×30, 140×40 ve 160×40'lık 3 farklı pencere büyüklüğü kullanılmıştır. Bu pencere büyüklükleri elle bölütlenmiş MR görüntüleri incelenerek elde edilmiştir.



Şekil 4. 4 MR kesit görüntülerinde farklı menisküs büyüklükleri

Özellik çıkarma işleminde öncelikle, bütünsel sınırlayıcı kutu içerisinde farklı pencere büyüklüklerine göre x ve y yönlerinde 2 piksel kaydırma işlemi gerçekleştirilmiştir. Menisküs pencere tahminlerinde herhangi bir bilgi kaybı yaşamamak ya da başka bir ifadeyle doğru pencereyi en başarılı şekilde yakalamak adına kaydırma ölçeği 2 piksel

olarak belirlenmiştir. Her bir adımda 1 piksel kaydırma ile de bu işlem gerçekleştirilebilirdi ancak o durumda hafıza ihtiyacı problemleri ortaya çıkmaktadır. Bu kaydırma işleminde her bir pencerenin gerçek pencere ile olan alansal örtüşmesinin nasıl gerçekleştiğini Şekil 4.5'ten görmek mümkündür.



Şekil 4. 5 Alansal örtüşme hesabı

Gerçek pencere ile kayan pencere arasındaki örtüşen alanlar, her bir kayan pencereden çıkarılan özellikleri haritalamak için hedef değişken olarak kullanılır. Şekil 4.5'te görüldüğü gibi, iki piksel, aralıklı örtüşmeyi bulmak ve hedef değişken olarak kullanmak üzere, bütünsel sınırlayıcı kutudaki her yinelemede pencere kaydırılmıştır. Bu hedef değişken regresyon aşamasında kullanılacaktır.

Alansal örtüşme miktarı Eşitlik 4.1'de görülen Dice benzerlik ölçütü kullanılarak hesaplanmıştır.

$$DSC(\text{Gerçek}, \text{Tahmin}) = 2 * \frac{|\text{Gerçek} \cap \text{Tahmin}|}{|\text{Gerçek}| + |\text{Tahmin}|} * 100 \text{ veya}$$

$$DSC(\text{Gerçek}, \text{Tahmin}) = \frac{2 * TP}{(2 * TP + FP + FN)} * 100 \quad (4.1)$$

TP, TN, FP ve FN ise sırasıyla doğru pozitif (true positive), doğru negatif (true negative), yanlış pozitif (false positive) ve yanlış negatif (false negative) anlamına gelmektedir.

4.3 Özellik çıkarımı ve indirgenmesi (Feature extraction and reduction)

Görüntü işlemede birçok özellik çıkarımı yöntemi mevcuttur. Ancak bazı yöntemler birçok farklı problemin çözümünde başarılı bir şekilde uygulanmaktadır. Yönelimli gradyan histogramları (Histogram of Oriented Gradients (HOG)) [125] ve yerel ikili

örüntü (Local Binary Pattern (LBP)) [126], [127] yöntemleri özellik çıkarma işleminde farklı tanımlayıcı sistemlerde başarılı sonuçlar veren iki yöntemdir. Bu iki yöntemin medikal görüntü işleme [128], [129], [130], parmak izi tanıma [131], [132], insan tespiti [125], [133], nesne tanıma [134] ve yüz tanıma [135], [136] gibi birçok alanda başarılı bir şekilde uygulandığı görülmektedir. Bu yöntemlerin yanı sıra Gabor filtreleri [137], [138] ölçeklemeden bağımsız özellik dönüşümü (Scale Invariant Feature Transform (SIFT)) [139], hızlandırılmış sağlam özellikler (Speeded up Robust Features (SURF)) [140], gri seviye eş-oluşum matrisi (Gray Level Co-occurrence Matrix (GCCM)) [141] ve yerel üçlü örüntü (Local Ternary Pattern (LTP)) [142] yöntemleri de özellik çıkarımı için başarılı bir şekilde uygulanan yöntemlerdir. Öte yandan Gabor filtreleri, LBP ve HOG yöntemlerinin bir arada kullanıldığı çalışmalarda da elde edilen başarılar dikkate değerdir [143], [144]. Farklı nesne ve dokuların tespitinde ayırt edici bir güce sahip olduklarının birçok bilimsel çalışma ile ispatlandığı, aydınlatma değişimleri gibi görüntü dönüşümlerine karşı toleranslı olmaları, bellek ve hesapsal maliyetlerinin düşük olması ve kullandığımız görüntülerin anatomik yapılarına uygun olmaları sebebiyle HOG, LBP ve SIFT yöntemleri ile çalışmaların gerçekleştirilmesine karar verilmiştir. Ancak yapılan ilk deneysel çalışmalar sonucunda hem tanımlayıcı boyutunun yüksek olmasının bellek maliyetine etkisi hem de regresyon performansının düşük olması nedeniyle SIFT yöntemi çıkartılmış ve böylece özellik çıkarımı aşamasında HOG ve LBP yöntemleri kullanılmıştır (Görsel özelliklerin çıkartılması için açık kaynaklı vlfeat kütüphanesi kullanılmıştır [145]). Devam eden bölümde kullanılan bu yöntemlerin teknik detaylarına yer verilecektir. Ardından elde edilen özelliklerin modellenmesi için kullanılan yöntemler açıklanacaktır.

4.3.1 Yönelimli Gradyan Histogramları

Yönelimli gradyan histogramları (Histogram of Oriented Gradients (HOG)) nesne ve örüntü tanımda başarılı sonuçlar veren bir tanımlayıcı çıkarma yöntemidir. HOG yönteminde piksellerin gradyan değerleri ve yönelim açılarıyla özellik çıkarımı gerçekleştirir. Temel amaç, görüntüyü yerel histogramlar şeklinde temsil etmektir [125]. Bu yönüyle ölçekten bağımsız özellik dönüşümü (Scale-invariant feature transform (SIFT)) [146] ve hızlandırılmış sağlam özellikler (Speeded-up robust features (SURF)) [140] yöntemleri ile benzerlik göstermektedir. Ancak HOG örtüşen bloklar kullanması ve

yerel parlaklık normalizasyonu gibi özellikleri sayesinde bu yöntemlerden daha başarılı bir betimleyicidir. HOG yönteminde uygulanan algoritmanın işlem adımları şu şekildedir;

-
- I. *Giriş görüntüsün alınması*
 - II. *Giriş görüntüsünün daha küçük boyutlarda alt görüntülere bölünmesi: “hücreler”*
 - a. *Hücreler problemin türüne göre karesel (R-HOG) veya dairesel (C-HOG) seçilebilir.*
 - III. *Her bir hücre için gradyan büyüklüklerinin (G) ve gradyan yönlendirme açılarının (θ) hesaplanması*
 - a. *Bu hesaplama için görüntünün kenarlarının bulunması (G_x ve G_y)*
 - i. *Kenar belirleme işlemi için Roberts, Prewitt ve Sobel vb. operatörlerinden birinin seçilmesi*
 - IV. *Her piksel için hesaplanan gradyan büyüklüklerinin hücrelerin gradyan histogramlarının hesabı için kullanılması*
 - a. *Her bir pikselin gradyan büyüklüğüne karşılık gelen gradyan yönlendirme açısına göre kanallara (bin) oy verme işleminin gerçekleştirilmesi*
 - i. *Histogram kanalları gradyan değerinin işaretli (signed) veya işaretsiz (unsigned) olup olmadığına bağlı olarak 0-180 derece veya 0-360 derece arasında eşit olarak dağılır.*
 1. *0-180 derecelik işaretsiz gradyanların seçilmesi durumunda histogramın 20 derecelik açılardan oluşan 9 kanala ayrılması (0, 20, 40, ... , 160).*
 2. *Gradyan yönlendirme açısının değerine göre gradyan büyüklüklerinin kanallara aktarılması.*
 - V. *Elde edilen sonuçların aydınlatma koşullarından etkilenmesini önlemek için blok normalleştirilmenin gerçekleştirilmesi.*
 - VI. *HOG özellik vektörlerinin elde edilmesi.*
-


Yukarıda verilmiş olan algoritmanın veri setimizdeki görüntülere uygulanması için gerçekleştirilen işlemler;

HOG özelliklerini çıkarmak için öncelikle gradyan (yön vektörü) büyüklüğü ve gradyan yönlendirme açısı hesaplanır. Bunun için, G_x ve G_y kenarları görüntüye yatay ve dikey Sobel filtreleri uygulanarak belirlenir (4.2). Ardından, gradyan büyüklüğü ve gradyan yönlendirme açısı (G ve θ) 4.3'de görüldüğü gibi hesaplanır.

$$G_x = I * [-1 \ 0 \ 1], G_y = I * [-1 \ 0 \ 1]^T \quad (4.2)$$


$$G = \sqrt{G_x^2 + G_y^2}, \theta = \arctan \frac{G_x}{G_y} \quad (4.3)$$

Burada hesaplanmış olan açı (θ) gradyan histogramlarında girdi değeri olarak kullanılmaktadır. Her hücrede yer alan pikseller için 0-180 dereceyi ya da 0-360 dereceyi kapsayan ve 20 derecelik aralıklardan oluşan gradyan histogramı oluşturulmaktadır. Dalal ve Triggs yaptıkları çalışmada Şekil 4.6'da görülen işaretli 0-180 derece arasında 9 kanallı (bin) histogram oluşturma'nın daha iyi sonuçlar verdiğini ortaya koymuşlardır [125].




Şekil 4. 6 İşaretsiz 0-180 derecenin 9 kanala ayrılması

Her piksel için hesaplanan gradyan büyüklükleri hücrelerde gradyan histogramlarının hesabı için kullanılmaktadır. Burada her bir pikselin gradyan büyüklüğüne karşılık gelen gradyan yönlendirme açısına göre 9 farklı kanala oy verme işlemi gerçekleştirilmektedir. Örneğin Şekil 4.7'de görülen gradyan histogramlarında bir pikselin değeri 155 olduğu için 150 derecelik kanala oyun $\frac{3}{4}$ 'ü verilirken, 170 derecelik kanala oyun $\frac{1}{4}$ 'ü verilmektedir. Bu şekilde her bir hücrede yer alan pikseller için oy verme işlemi gerçekleştirilerek Şekil 4.7'deki gibi bir gradyan histogramı oluşturulmaktadır.



Şekil 4. 7 Gradyan (Yön Vektörü) Histogramlarının oluşturulması

HOG yönteminde görüntüler üzerindeki zıtlık etkisinin azaltılması ve ışık aydınlatması etkisinin minimuma indirilmesi için gradyan büyüklüklerinde normalleştirme işlemi gerçekleştirilir. Bu normalleştirme işleminde Şekil 4.8’de görüldüğü gibi hücreler bir araya getirilerek bloklar oluşturulur. Şekil 4.8’de mavi çerçeve ile görülen ve 4 hücrenin birleştirilmesi ile oluşturulan 2x2’lik bir blok görülmektedir. HOG tanımlayıcıları elde edilirken bir önceki blokla bir sonraki blokun üst üste örtüştürülerek kesişmesi sağlanır (Şekil 4.8’de sarı ve mavi bloklarda olduğu gibi).



Şekil 4. 8 Tanımlayıcı bloklarının oluşturulması

HOG yönteminde tanımlanmış iki farklı blok geometrisi bulunmaktadır. Bunlardan ilki Şekil 4.8’de de örneklenmiş olan dikdörtgen şekilli R-HOG bloklarıdır. R-HOG blokları kare şekline sahip SIFT tanımlayıcılarına çok benzeyen blok yapılarıdır. Yön düzeltmesi olmadan tek bir boyutta hesaplanmaları açısından SIFT’den ayrılmaktadır. Bir diğer blok

ise C-HOG bloklarıdır. Bu blok tipide tek ve merkezi bir hücreye sahip olanlar, açısız olarak bölünmüş olanlar şeklinde iki gruba ayrılırlar.

HOG'un ışık aydınlatması ve gölgelerden kaynaklanan değişimlere karşı gürbüz bir yöntem olduğu daha önce dile getirilmişti. Bunu sağlayan işlem blok normalleştirme işlemidir. Bu işlemde her hücredeki piksel değerlerinin ortalaması alınarak hücrelerden oluşan bloklara uygulanır. Blok normalleştirme için uygulanan 3 yöntem bulunmaktadır. v her bir bloktaki tüm histogramları içeren normalleştirilmemiş değerleri göstermek ve ϵ 'de bir sabit olmak üzere normalleştirme fonksiyonları şu şekilde tanımlanmaktadır;


$$L1 - norm: v \rightarrow v / (\|v\|_1 + \epsilon) \quad (4.4)$$

$$L2 - norm: v \rightarrow v / \sqrt{(\|v\|_2^2 + \epsilon^2)} \quad (4.5)$$

$$L1 - sqrt: v \rightarrow \sqrt{v / (\|v\|_1 + \epsilon)} \quad (4.6)$$


Dalal ve Triggs yaptıkları çalışmada L2-norm ve L2-sqrt ile normalleştirme yapmanın daha iyi sonuçlar verdiğini söylemektedirler [125]. Bu sebeple bizim çalışmamızda da L2-norm kullanılmıştır.

Şekil 4.8'de yer alan görüntüde mavi renkli blok için elde edilmiş olan yönelimli gradyan histogramları Şekil 4.9'da görülmektedir.




Şekil 4. 9 Örnek bir blok üzerinde yönelimli gradyan histogramlarının görselleştirilmesi

HOG özellikleri çıkartılırken farklı hücre büyüklüğü (cell size) parametreleri deneysel çalışmalar sonucunda kullanılan pencere boyutlarına ve bellek miktarına göre 10 olarak belirlenmiştir. Bu, x ve y yönlerinde pencerenin 10x10'luk hücrelere bölündüğü ve her bir hücre için tanımlayıcıların (descriptor) hesaplandığı anlamına gelmektedir. Şekil 4.8'de de görüldüğü gibi 2×2 'lik bloklar kullanılmıştır. Hücre büyüklüğünün 10 seçilmesi neticesinde elde edilen yönelimli gradyan histogramlarına ait bir örnek Şekil 4.10'da görülmektedir.



Şekil 4. 10 Menisküs dokusuna ait yönelimli gradyan histogramlarının görselleştirilmesi (Hücre büyüklüğü=10)

Şekil 4.11'de hücre büyüklüğünün 3 seçilmesi durumunda yönelimli gradyan histogramları yönteminin elde ettiği görselleştirilmiş sonuçlar görülmektedir. Görüntü incelendiğinde elde edilen sonuçların menisküs dokularını daha başarılı bir şekilde ortaya çıkardığı anlaşılmaktadır. Ancak hücre büyüklüğü ne kadar küçükse bellek maliyeti de o ölçüde artmaktadır. Bu sebeple mevcut bellekle işlenebilecek ve en iyi başarıyı verebilecek bir hücre büyüklüğü belirlenmiştir.



Şekil 4. 11 Menisküs dokusuna ait yönelimli gradyan histogramlarının görselleştirilmesi (Hücre büyüklüğü=3)

Literatürde farklı HOG türevleri önerilmiştir. Bu çalışmada, HOG-UoCTTI türevi kullanılmıştır. Bu türev, dört boyutlu doku enerjisi özelliğinin yanı sıra yönlendirilmiş ve yönlendirilmemiş gradyanları hesaplar, ancak sonucu 31 boyuta indirir [134]. Örnek olarak, hücre boyutu 10'u kullanan bir 90x30 pencere için, HOG özelliklerinin boyutu 9x3x31'dir (yani bir pencere için 837 boyutlu özellik vektörü). Her bir adımda 2 piksel kaydırılarak bütünsel sınırlayıcı kutudan, 90x30 boyutunda 3180 farklı pencere elde edilir. Böylece, her biri 837 boyuta sahip 3180 özellik vektörü, tek bir kesit için çıkarılır. MR'dan MR'a farklılık göstermekle birlikte her bir MR'da menisküslerin yer aldığı yaklaşık 45 kesit bulunmaktadır. Bu nedenle, her MR görüntüsü için $(45 \times 3180) \times 837 = \sim 143.000 \times 837$ boyutlarında bir özellik matrisi elde edilir.

4.3.2 Yerel İkili Örüntü

Yerel ikili örüntü (Local Binary Pattern (LBP)), parametrik olmayan bir özellik çıkarımı yöntemidir [126], [127]. LBP yerel kontrastın ortogonal ölçüsü olarak nitelendirilebilir.

Başlangıçta bir doku örüntü analizi tekniği olarak ortaya atılmıştır [147]. LBP'nin farklı aydınlatma koşullarına sahip görüntülere karşı toleransının yüksek olması, gri-seviye görüntülerdeki küçük değişimlere karşı duyarlı olması ve hesaplama maliyetinin düşük olması gibi önemli avantajlara sahip olması özellikle görüntü işleme çalışmalarında sıklıkla tercih edilmesine neden olmaktadır [148].

LBP yönteminde uygulanan algoritmanın temel işlem adımları şu şekildedir;

-
- I. *Giriş görüntüsün alınması*
 - II. *Görüntünün daha küçük boyutlara sahip alt görüntülere ayrılması: "hücreler". (Örneğin her bir hücre için 16×16 piksel)*
 - III. *Bir hücredeki her pikselin komşuları ile karşılaştırılması (sol üst, sol orta, sol alt, sağ üst vb.).*
 - a. *Komşuluklar genellikle (8, R) ve (16, R) yapısındadır. Burada R komşulara olan uzaklığı ifade etmektedir. 8 ve 16 ise komşu sayısını göstermektedir.*
 - IV. *Pikseller bir daire boyunca, yani saat yönünde veya saatin tersi yönünde takip edilir*
 - a. *Orta pikselin değeri komşunun değerinden büyük ya da eşit olduğunda "0", aksi takdirde "1" yazılır.*
 - i. *Bu işlem sonucunda 8 komşuluğa bakılıyorsa eğer 8 basamaklı ikili bir sayı oluşturulur*
 1. *Genellikle kolaylık sağlamak için elde edilen ikilik sayı ondalık sayıya dönüştürülür.*
 - V. *Hücredeki her sayı frekansının histogramının hesaplanması (Bu histogram, 256 boyutlu bir özellik vektörüdür)*
 - a. *Bitsel geçişlere göre 256 boyutlu özellik vektöründen 59 boyutlu düzgün (uniform) örüntülerin elde edilmesi*
 - b. *Tüm hücrelerin birleştirilmiş (normalize edilmiş) histogramlarının elde edilmesi (Bu, görüntünün tümü için bir özellik vektörü verir).*
-

3x3'lük bir çerçeve içerisinde 8-komşuluğa göre elde edilen LBP tanımlayıcısının hesaplanmasına ilişkin görsel Şekil 4.12'de görülmektedir. Bu işlemler Eşitlik 4.7 kullanılarak hesaplanır;


187	177	166		1	0	0		
188	178	165	→	1		0	→	(10000111) =135
188	182	168		1	1	0		

Şekil 4. 12 LBP tanımlayıcı kodu oluşturmak için bir örnek

$$LBP_{P,R}(x_c) = \sum_{p=0}^{P-1} u(x_p - x_c) 2^p, \quad u(y) = \begin{cases} 0, & \text{if } y < 0 \\ 1, & \text{if } y \geq 0 \end{cases} \quad (4.7)$$

x_c = merkez piksel, x_p = merkez pikselin komşuları, R = merkez pikselin komşularına olan uzaklığı, P = işlem gören komşu sayısı.


Şekil 4.13'te LBP için farklı dairesel komşuluklar görülmektedir. Bu daireler merkez pikselin komşu sayısına ve komşu piksellere olan uzaklıklarına göre çeşitlenmektedir.



Şekil 4. 13 Dairesel (8, 1), (16, 2) ve (8, 2) komşulukları [149]


Eşitlik 4.7'e göre P -bitlik ikili sayı için 2^P adet farklı LBP kodu oluşur. Yani Şekil 4.12'deki gibi bir örnek için $2^8=256$ farklı örüntü oluşur. LBP'de elde edilen bu örüntülerin bir bölümü düzgün (uniform) bir bölümü de düzgün olmayan (non-uniform) olarak iki gruba ayrılır. Birçok doku analizi uygulamasında giriş görüntüsünün dönmesine (rotation) karşı değişmez (invariant) özellikler elde edilmesi istenir. $LBP_{P,R}$ örüntüleri merkez piksel etrafında dairesel örnekleme yapılarak elde edildiğinden giriş görüntüsünün dönmesi iki etkiye sahiptir; her bir yerel komşuluk diğer piksel konumlarına döndürülür ve her komşuluk içerisinde merkez pikseli çevreleyen örnekleme noktaları farklı bir yöne döndürülür. Birçok uygulamada LBP'nin farklı bir uzantısı olan düzgün örüntüler kullanılmaktadır [150]. Bunun için 0'dan 1'e bitsel (bitwise) geçişlerin sayısını gösteren bir

tekdüzelik (uniformity) ölçütü tanımlanmıştır. Bir yerel ikili örüntü eğer tekdüzelik ölçütü en fazla 2 ise düzgün olarak nitelendirilir. Örneğin 0000000 (0 geçiş), 00011100 (2 geçiş) ve 11101111 (2 geçiş) örüntüleri düzgündür. Ancak 00110100 (4 geçiş) ve 01010100 (6 geçiş) düzgün olmayan örüntülerdir. Düzgün LBP haritalamada, her bir düzgün örüntü için ayrı bir çıktı etiketi bulunur ve tüm düzgün olmayan örüntüler tek bir etikete atanır. Böylece P bite sahip örüntülerin haritalanması (mapping) için farklı çıktı etiketlerinin sayısı $P(P-1)+3$ olacaktır. Örneğin 8 örnekleme noktasının komşulukları için çıktı etiketleri sayısı 59, 16 örnekleme noktası için 243 olacaktır. Şekil 4.14'te 8 bitlik LBP için 58 farklı düzgün örüntü görülmektedir. Şekilde açık mavi daireler merkez pikseli, beyaz daireler 0 bitini ve mavi renkli daireler de 1 bitini temsil etmektedir.




Şekil 4. 14 (8, R) komşuluğu için 58 farklı düzgün örüntü [149]

Düzgün olmayan örüntülerin çıkartılmasının iki farklı gerekçesi bulunmaktadır. Öncelikle doğal görüntülerde yerel ikili örüntülerin çoğunun düzgün olmasıdır. LBP ile gerçekleştirilen bir çalışmada [136] (8, 1) komşuluğunda düzgün örüntülerin oranının %90.6 ve (8, 2) komşuluğunda da bu oranın %85.2 olduğu belirtilmiştir. Düzgün örüntüler oluşturma'nın bir başka nedeni istatistiksel sağlamlıktır (robustness). Olası tüm örüntüler yerine düzgün örüntülerin kullanılması birçok uygulamada daha iyi tanıma sonuçları üretmektedir. Diğer taraftan, düzgün örüntülerin daha istikrarlı, yani gürültüye daha az eğilimli olduğuna ve sadece düzgün örüntüler göz önüne alındığında olası LBP etiketlerinin sayısını önemli ölçüde düşürdüğüne değinmekte fayda vardır. LBP'nin tespit edebildiği yapılara noktalar, düz bölgeler, kenarlar ve köşeleri örnek vermek mümkündür. Bu yapılardan bazıları Şekil 4.15'te görülmektedir. Şekilde, 1 bit değeri siyah daire ile 0 bit değeri beyaz daire ile gösterilmektedir. Gri daire ise merkez pikseli işaret etmektedir.




Şekil 4. 15 (8, R) komşuluğu için 58 farklı düzgün örüntü [149]

Kullandığımız görüntülerin anatomik yapısına uygun olması, kontrast temelli özellik çıkarımı yapması, farklı aydınlatma koşullarına sahip görüntülere karşı toleransının yüksek olması, gri-seviye görüntülerdeki küçük değişimlere karşı duyarlı olması, bellek maliyetinin diğer yöntemlere göre düşük olması gibi özellikleri sebebiyle LBP yöntemi çalışmamız için bir özellik çıkarım yöntemi olarak belirlenmiştir. Şekil 4.16'da elde edilen örnek bir menisküs penceresi üzerinde LBP özelliklerinin çıktıları analiz edilebilmektedir. LBP özellik vektörlerinin görseli incelendiğinde menisküs yapılarının dokusal özelliği ile arka planın dokusal özelliklerinin başarılı bir şekilde ortaya konduğu görülmektedir.



Şekil 4. 16 Örnek bir menisküs penceresinde LBP özelliklerinin görselleştirilmesi

Şekil 4.17’de de farklı bir pencere üzerinde LBP özelliklerinin görselleştirilmesi gerçekleştirilmiştir. Bu görüntüde menisküs bölgesinin dokusal yapısının ortaya konduğu görülmektedir.




Şekil 4. 17 Başka bir örnek menisküs penceresinde LBP özelliklerinin görselleştirilmesi

Çalışmamızda LBP hücre büyüklüğü pencere boyutlarını ve bellek maliyetini de dikkate alarak farklı büyüklere göre deneysel çalışmaların neticesinde 10 olarak belirlenmiştir. Örnek olarak, 90×30 boyutlarında bir pencere için 9×3×58 boyutunda LBP özelliği tanımlanır (yani bir pencere için 1566 boyutlu özellik vektörü). Her bir MR görüntüsü için

(yaklaşık 45 kesit için) LBP özellik matrisi boyutu $45 \times 3180 \times 1566$ 'dır (bütünsel sınırlayıcı kutusunda 90×30 'luk bir pencere boyutu için her adımda 2 piksel kaydırıldığında 3180 pencere elde edilir).

4.3.3 Rastgele Alt Örnekleme (Random Subsampling)

Çalışmamızda elde edilen özelliklerin boyutlarının oldukça yüksek olduğu HOG ve LBP başlıkları altında gösterilmiştir. Özellik çıkarımında kullandığımız pencerelerin her biri bizim bir örneğimizi temsil etmektedir. Şekil 4.18'deki gibi bir bütünsel sınırlayıcı kutu içerisinde farklı pencere büyüklüklerine göre pencerelerin gezdirilmesi ve en uygun tahmin pencerelerinin elde edilmesi işlemi gerçekleştirilmektedir.




Şekil 4. 18 Örnek bir MR kesit görüntüsü üzerinde bütünsel sınırlayıcı kutu

Bölüm 4.2.1'de anlatıldığı şekilde her bir pencere için bir alansal örtüşme hesabı yapılmaktadır. Bütünsel sınırlayıcı kutular içerisinde elde edilen örneklerin yani gezdirilen pencerelerin alansal örtüşme oranlarına göre dağılımları Şekil 4.19'da görülmektedir. Şekli incelediğimizde tek bir MR görüntüsü için elde edilen yaklaşık 150.000 örneğin yarısından fazlasının örtüşme oranının $[0, 0.1]$ aralığında olduğu görülmektedir. Buna karşın örtüşme alan oranı $[0.8, 0.9]$ aralığında olan oldukça az sayıda örnek elde edildiği görülmektedir. Şekil 4.18'e tekrar bakıldığında gerçek menisküs penceresinin dışında kalan alanın oldukça geniş olduğu bu sebeple gezdirilen

pencerelerin gerçek menisküs pencereleri ile olan örtüşme oranlarının en yoğun $[0, 0.1]$ aralığında olacağı anlaşılmaktadır.

Çalışmamızda elde edilecek başarıyı etkilemeyecek şekilde hesapsal maliyeti azaltmak için bu örneklerde bir azaltma işlemi yapılmıştır. Bu işlem için Şekil 4.19’da görülen belirli bir eşik değere göre belirlenen kırmızı kesikli çizginin altında kalan örnekler seçilmiştir. Bunun için bu çizginin altında kalan örnek sayısının her bir aralık için rastgele seçilmesi işlemi yapılmıştır. Yani $[0, 0.1]$ aralığında yaklaşık 80.000 örnek olduğu görülmektedir. Kırmızı çizginin altından kalan 1000 örneğin belirlenmesi işlemi için bu 80.000 örnek içerisinde rastgele 1000 örnek belirlenmiştir.



Şekil 4. 19 Tek bir MR görüntüsü için örtüşme oranlarına göre elde edilen örnek sayılarının histogramı

Rastgele alt örneklemeden sonra, her bir MR görüntüsü için elde edilmiş olan yaklaşık 150.000 örneğin boyutu 7000 seviyelerine indirgenmiştir. Örneğin 90×30’luk bir pencere genişliği için elde edilen özellik vektörü boyutu 837 idi. Alt örneklemeden sonra her bir MR elde edilen özellik vektörü boyutu yaklaşık olarak 7000×837 seviyelerinde olmuştur.

4.3.4 Temel Bileşen Analizi

Temel bileşen analizi (Principal component analysis (PCA)) 1901 yılında Pearson tarafından geliştirilmiş bir boyut indirgeme yöntemidir [151]. 1986 yılında da Jolliffe tarafından günümüzdeki halini almış bir yöntem olmuştur [152] Çoğu zaman yaptığı iş

aralarında yüksek ilinti bulunan verilerin farklı bir uzaya taşınarak aralarında ilinti bulunmayan doğrusal bileşenlere dönüştürülmesi ve boyutların azaltılmasını sağlamaktır. Başka bir deyişle veri içindeki varyansların en iyi şekilde ifade edilmesidir. PCA kullanıcıya elindeki veri seti hakkında en bilgilendirici bakış açısını sunan ancak bu işlemi daha düşük boyutlarda yapabilen bir resim sunar. PCA verileri yeni bir koordinat sistemine taşımak için doğrusal ortogonal bir dönüşüm kullanır. Bu sayede başlangıçtaki veri için elde edilen daha düşük boyutlu verinin en büyük varyanslı elemanı birinci koordinatta yer alır ve ilk temel bileşen adını alır. PCA'nın bu işlemi nasıl gerçekleştirildiğini belirtmek için öncelikle kovaryansı ve kovaryans matrisinin nasıl elde edildiğini anlamak gerekmektedir. Kovaryans iki farklı grup değişkenin birlikte nasıl değiştiklerinin ölçüsüdür. X ve Y gibi iki değişkenin arasındaki kovaryans Eşitlik 4.8'deki gibi hesaplanır;

$$cov = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{N-1} \quad (4.8)$$

Veri seti içerisindeki tüm olası kovaryanslar hesapladığında ise kovaryans matrisi elde edilir. Eşitlik 4.9'da x, y, z verilerinden oluşan bir veri setinin kovaryans matrisi görülmektedir.

$$C = \begin{pmatrix} cov(x, x) & cov(x, y) & cov(x, z) \\ cov(y, x) & cov(y, y) & cov(y, z) \\ cov(z, x) & cov(z, y) & cov(z, z) \end{pmatrix} \quad (4.9)$$

Kovaryans matrisi simetrik bir matristir. Ayrıca bu matrisin köşegeninde yer alan kovaryans değerleri varyansları göstermektedir. M adet veriden oluşan N boyutlu X verisi 4.10'da görülmektedir.

$$X = \begin{bmatrix} x_{11} & \cdots & x_{1M} \\ \vdots & \ddots & \vdots \\ x_{1N} & \cdots & x_{NM} \end{bmatrix} \quad (4.10)$$

Bu veriye ait temel bileşen analizinin gerçekleştirilmesi için öncelikle 4.11'deki N boyutlu her bir sütunun ortalaması hesaplanır ve bu ortalama değer o sütundaki değerlerden çıkartılarak sıfır ortalamalı X_{yeni} isminde yeni bir özellik kümesi elde edilir.


$$X_{yeni} = X_i - \bar{X} \quad (4.11)$$

Elde edilen bu yeni veri kümesi için $C = X_{yeni}^T X_{yeni}$ kovaryans matrisi hesaplanır. Bulunan bu kovaryans matrisinin öz vektörleri hesaplanır. Bulunan bu öz vektörlerden X_{yeni} özellik kümesi çıkartılarak boyutları düşürülmüş vektörler kümesi elde edilir.

Temel bileşen analizinde en önemli nokta elde edilen bu özvektörlerden hangilerinin seçileceğidir. Bunun için öz değerler büyükten küçüğe doğru sıralanır. Özvektörler de bu sıralamaya uygun hale getirilir. Bu sıralama sonucunda elde edilen özvektörlerin ilki varyansın en yüksek olduğu bileşeni göstermektedir. PCA'de yapılan işlem veriler hakkında en fazla bilgiyi taşıyan varyans değerleri olduğu için, büyükten küçüğe sıralanmış olan temel bileşenlerden ilk k tanesi verinin çok yüksek bir oranını temsil edecektir. Kaç tane özvektörün seçileceğinin belirlenmesi için elde edilen özdeğerlerin kümülatif toplam değerinin tüm özdeğerlerin toplamına bölünmesiyle elde edilen oran, seçilen özdeğerin verinin varyansını hangi oranda gösterdiğini belirtmektedir. Literatürde genellikle bu oran %95 olarak belirlenmiştir. Bu oran tercihe ve probleme bağlı olarak arttırılabilir ya da azaltılabilir. Yaptığımız çalışmada da elde edilen özelliklerin boyutlarının indirgenmesi için PCA'den faydalanılmıştır. Mevcut özellik vektörü için özdeğerler hesaplanmış ve bu özdeğerlerin varyanslarının verinin %95'ini kapsayacak kadarlık kısmı yani 200 özvektör seçilmiştir. PCA işleminin ardından model eğitimi aşamasına geçilmiştir. Model eğitme işlemi ELM ve RF yöntemleri ile gerçekleştirilmiştir.

4.4 Model Eğitimi

Regresyon işleminde her bir kesit için hedef değişken, gerçek pencere ile kayan pencere arasındaki örtüşen alanın oranıdır. İlk olarak, bu pencerelerin Şekil 4.20'de görüldüğü gibi örtüşüp örtüşmedikleri belirlenir. Bu görüntü, örtüşme alanını örneklemek için üç farklı kesit görüntüsü göstermektedir. Şekil 4.20-a'da, üst üste binen alan 0'dır, çünkü pencereler arasında kesişme yoktur. Şekil 4.20-c'de tam bir örtüşme vardır, ancak kayan pencere gerçek pencereden daha büyüktür. Bu sebeple Şekil 4.20-c'deki örtüşen alan oranı 0.723'tür. Bu değer, regresyon modellerinde hedef değişken olarak kullanılacaktır.




Şekil 4. 20 Örtüşen alanlar için örnek görüntüler

Çalışmada, 66 MR görüntüsü (% 75) eğitim için ve 22 MR görüntüsü (% 25) test için ayrılmıştır. Gerçekleştirilen rastgele alt örnekleme işleminin ardından eğitim ve test amaçlı olarak yaklaşık 450.000 ve 150.000 örnek elde edilmiştir. Hazırlanan eğitim örnekleri ELM ve RF yöntemleri kullanılarak modellenmiştir.

4.4.1 Model Eğitici: Aşırı Öğrenme Makinesi

Aşırı öğrenme makinesi (Extreme Learning Machine (ELM)), Şekil 4.21’de gösterildiği gibi tek gizli katmanlı ileri beslemeli yapay sinir ağının (Single Layer Feedforward Network (SLFN)) bir modelidir [153]. Bu yöntemde, girdi ağırlıkları rastgele belirlenirken, çıktı ağırlıkları analitik olarak belirlenir. 2006 yılında Huang vd. eğitim süresi ve doğruluğu açısından SVM, ELM ve geri yayılım tabanlı SLFN yöntemlerinin performansını karşılaştırmışlardır [154]. Giriş katmanındaki ağırlık ve yanlılık değerleri verilerden bağımsız olarak rastgele belirlenmektedir. Çıktı ağırlıkları ise gizli katmanda en küçük kareler yöntemi ile etkili bir şekilde belirlenir.



Şekil 4. 21 ELM ağ yapısı

Genelleştirilmiş SLFN'ler için ELM'in çıkış fonksiyonu;

$$f_L(x) = \sum_{i=1}^L \beta_i h_i(x) = h(x)\beta \quad (4.12)$$

Burada $\beta = [\beta_1, \dots, \beta_M]^T$ çıkış katmanı ile gizli katmanlar arasındaki çıkış ağırlıkları vektörü, $h(x)$ gizli katmanın çıkış vektörü, $h(x) = [G(a_1, b_1, x), \dots, G(a_L, b_L, x)]$ ise $G(a, b, x)$ lineer olmayan parçalı sürekli fonksiyon (nonlinear piecewise continuous function), $\{(a_i, b_i)\}_{i=1}^L$ aktivasyon fonksiyonuna göre rastgele üretilen giriş değerleridir. Çalışmamızda literatürdeki yaygın kullanımı sebebiyle sigmoid aktivasyon fonksiyonu kullanılmıştır.

$$\text{Sigmoid Fonksiyonu: } G(a, b, x) = \frac{1}{1 + \exp(-(a \cdot x + b))} \quad (4.13)$$

Burada giriş katmanından gizli katmana doğru, x bir giriş örneği, a ağırlık değeri ve b 'de yanlılık değeridir. $\{a, b\}$ çifti rastgele oluşturulmaktadır. ELM, eğitim hatasını ve çıktı ağırlıklarının normunu en aza indirmektedir [153], [154]. Minimize edilen: $\|H\beta - T\|^2$ ve $\|\beta\|$ burada H gizli katman çıkış matrisi;

$$H = \begin{bmatrix} h_1(x_1) & \cdots & h_L(x_1) \\ \vdots & \ddots & \vdots \\ h_1(x_N) & \cdots & h_L(x_N) \end{bmatrix} \quad (4.14)$$

ELM'nin uygulama aşamasında standart optimizasyon yöntemleri yerine en küçük kareler yöntemi kullanılmıştır [155].


$$\beta = H^+T, \quad (4.15)$$

T etiket matrisi ve H^+ ise Moore-Penrose genelleştirilmiş gizli katman çıkış matrisi tersidir. $H = [h^T(x_1), \dots, h^T(x_N)]^T$ N eğitim örneği ile elde edilir. Moore-Penrose genelleştirilmiş gizli katman çıkış matrisi tersinin hesaplanması için kullanılan yöntemlerden birisi ortogonal projeksiyon metodudur: $H^+ = (H^TH)^{-1}H^T$. Ridge regresyon kuramına göre, H^TH 'nin köşegenine C adında bir düzenleme sabiti eklenebilir. Eğer ki eğitim verisi çok büyükse örneğin, bizim çalışmamızda olduğu gibi eğitim verisi gizli katman sayısından çok büyükse, $N > L$, çözüm [155];

$$f_L(x) = h(x) \left(\frac{I}{C} + H^TH \right)^{-1} H^TT \quad (4.16)$$


şekline dönüşür. Bu haliyle çok daha uyarlanabilir ve daha iyi bir genelleştirme performansı vardır.

Aşırı öğrenme makinelerinde gizli katman sayılarının ve düzenleme parametrelerinin başarı üzerinde önemli etkileri bulunmaktadır. Bu sebeple bu parametrelerin en uygun olanın seçilmesi sistemin genel başarısı açısından dikkat edilmesi gereken bir noktadır. Bu sebeple gerçekleştirilen çalışmalar için farklı gizli katman sayılarına göre deneysel çalışmalar yapılmış ve en uygun gizli katman sayısının 4096 olduğuna karar verilmiştir. Bu deneysel çalışmalarla gizli katman sayısının nasıl belirlendiğini Şekil 4.22'den görmek mümkündür.



Şekil 4. 22 ELM gizli katman sayılarının belirlenmesi

Gizli katman sayılarının belirlenmesi için yapılan deneysel çalışmalar düzenleme parametresinin belirlenmesi içinde uygulanmıştır. Şekil 4.23'te de görüldüğü gibi en uygun düzenleme parametresi değeri 0.1'dir.



Şekil 4. 23 ELM düzenleme parametresinin belirlenmesi

4.4.2 Model Eğitici: Rastgele Ormanlar

Rastgele ormanlar (Random Forests (RF)), sınıflandırma veya regresyon işlemleri için bir dizi karar ağacını bir araya toplayarak çalışır. RF sınıflandırma için sınıf etiketlerini, regresyon için ise ağaçların tahmin ortalamasını çıkış etiketi olarak kullanır ve çok sayıda karar ağacının bir arada olduğu bir sistem inşa eder [156], [157], [158].

RF eğitim aşamasında torbalama (bootstrap aggregating(bagging)) yöntemini uygular. $Y = y_1, \dots, y_n$ çıktıları içeren bir eğitim seti $X = x_1, \dots, x_n$ verildiğinde, torbalama tekrar tekrar (N kez) eğitim seti içerisinde rastgele bir örnek seçer ve ağacı bu örneklere göre yeniden inşa eder:

For $i = 1, \dots, N$:

Veri seti içerisinde değişimli olarak x_i, y_i eğitim örneklerinin seçimi;

x_i, y_i örneğine göre f_i regresyon ağacının eğitilmesi.

Eğitimden sonra, bilinmeyen x' gibi örnekler için tahminler tüm bireysel regresyon ağacından gelen öngörülerin ortalaması alınarak yapılır [156], [157], [158].

4.5 Regresyon Sonuçlarının Analizi

Yapılan regresyon işleminin amacı menisküsü çevreleyen en ufak pencerelerin yerini tespit etmektir. Menisküsün belirli standart bir boyutu yoktur, kesitten kesite ve MR'dan MR'a farklılık gösterebilmektedir. Bu yüzden menisküsü çevreleyen pencereleri belirlemek için farklı pencere boyutları kullanılmıştır. Çizelge 4.2'den, farklı pencere büyüklüklerinin tahmin puanını nasıl etkilediğini görmek mümkündür. Tahmin skoru (predScore) regresyon skorunu temsil eder. Menisküsün büyüklüğü ile optimal pencere boyutu arasında doğrudan bir ilinti vardır. Böylece, menisküs boyutu ve pencere boyutu birbirine ne kadar benzerse, tahmin skoru Çizelge 4.2'de görüldüğü üzere o kadar yüksek olacaktır. Referans gerçeklik skoru (gtScore), elle bölütleme ile elde edilmiş gerçek pencere ile sistemin elde ettiği kayan pencere arasındaki alansal örtüşme oranını temsil eder. Başka bir deyişle, gerçek skor, ilgili pencere boyutu için elde edilebilecek maksimum örtüşme değerini belirtir. Çizelge 4.2'deki ilk satırı örnek olarak ele alırsak, kayan pencerenin genişliği [90, 30] iken, menisküsün gerçek penceresinin genişliği ve yüksekliği [143, 37]'dir. Bu sebeple en iyi çakışma oranı %67 olacaktır. Çizelge 4.2'den görülebileceği gibi, kayan ve gerçek pencere boyutları arasındaki benzerliğe bağlı olarak, aynı kesit üzerinde farklı pencere boyutlarını kullanarak farklı skorlar elde edilebilir. Burada, en yüksek tahmin skoruna sahip pencere boyutu seçilmiştir.

Çizelge 4. 2 Aynı kesit üzerinde farklı pencere boyutlarının en iyi regresyon sonuçlarının karşılaştırılması

MR No	Kesit No	En Yüksek Skorlu Pencere Koordinatları	En Yüksek Skorlu Pencerenin Genişliği ve Yüksekliği	Gerçek Pencere Koordinatları	Gerçek Pencerenin Genişliği ve Yüksekliği	Tahmin Skoru (predScore)	Gerçek Skor (gtScore)
79	91	[141, 227]	[90, 30]	[129, 233]	[143, 37]	0.61	0.67
79	91	[135, 227]	[140, 40]	[129, 233]	[143, 37]	0.88	0.95
79	91	[117, 229]	[160,40]	[129, 233]	[143, 37]	0.83	0.90

Farklı çerçeve büyüklükleri için elde edilmiş ilinti değerleri Çizelge 4.3'te görülmektedir. İlinti hesaplaması Eşitlik 4.17'deki gibi hesaplanmaktadır.

$$r = \frac{\sum_m \sum_n (A_{mn} - \bar{A})(B_{mn} - \bar{B})}{\sqrt{\sum_m \sum_n (A_{mn} - \bar{A})^2 \sum_m \sum_n (B_{mn} - \bar{B})^2}} \quad (4.17)$$

$\bar{A}$, (A)'nin ortalaması, $\bar{B}$, (B)'nin ortalamasını göstermektedir.

Çizelge 4. 3 Gerçek ve tahmin edilen pencereler arasındaki ilinti


	Pencere Boyutu		
	90x30	140x40	160x40
HOG + RF	0.889	0.910	0.911
HOG + ELM	0.879	0.899	0.898
LBP + RF	0.841	0.886	0.893
LBP + ELM	0.817	0.879	0.874

Bu değerler, gerçek doğruluk skorlarının, sistemin tahmin edilen pencere ile gerçek menisküs bölgesi arasındaki ilintiyi gösterir. Aynı zamanda Çizelge 4.3, tüm MR görüntüleri ve MR kesitleri için farklı yöntemlerin (pencere boyutu, özellik ve regresör kombinasyonları) başarısını göstermektedir. Çizelge incelendiğinde 160x40'lık çerçeve için HOG özellik çıkarma yöntemi ile elde edilmiş özelliklerin RF yöntemi ile modellendiği ve tahmin edildiği durumda en yüksek ilinti değerinin elde edildiği görülmektedir. Bir sonraki menisküs sınırlarının çıkartılması aşamasına girdi olarak verilen tahmin edilen menisküs pencereleri, bu sonuçların kararlarının birleştirilmesi ile elde edilmektedir. Yani her bir kesit görüntüsü için hangi özellik-regresör birleşiminin hangi pencere büyüklüğü en iyi sonucu verdi ise o kesit için o tahmin penceresi seçilmektedir. Bütün kesitler için aynı işlemi yapılmakta ve en iyi sonuçların yer aldığı tahmin pencereleri elde edilmektedir. Bu tahmin pencereleri üzerinden menisküs sınırlarının elde edilmesi işlemi gerçekleştirilmektedir.

4.6 Kesit Elemesi

Regresyon adımının amacı gerçek pencerelere en benzeyen tahmin pencerelerinin elde edilmesi idi. En yüksek tahmin skoruna sahip kayan pencereler her bir kesit için tahmin penceresi olarak belirlenmiştir. Ve menisküs sınırlarının çıkartılmasında bu tahmin pencereleri kullanılmıştır. Sınırları belirleme işlemine geçmeden önce hem menisküslerin yer almadığı kesitlerin hem de radyoloji uzmanlarının değerlendirme yapamayacağı kadar küçülmüş menisküslere sahip olan kesitlerin elenmesi işlemi gerçekleştirilmiştir. Menisküslerin yer almadığı kesit görüntülerinin tahmin skorları oldukça düşüktür. Ayrıca radyoloji uzmanlarının değerlendirme yapamayacağı kadar küçülmüş menisküslere sahip olan ve Şekil 4.24'te menisküs bölgesi beyaz noktalarla işaretlenmiş bir örneği gösterilen kesitlerin de tahmin skorları düşük olmaktadır.

Menisküs sınırlarının çıkartılması aşamasına geçmeden önce bu kesitlerin elenmesi işlemi gerçekleştirilmiştir.




Şekil 4. 24 Elenen kesitler için bir örnek

Bu eleme işlemi için, önceki adımda elde edilen pencere tahmin sonuçları kullanılmıştır. İlk olarak, en yüksek tahmin skoruna sahip pencere, üç farklı pencere boyutu arasından seçilir. Aynı zamanda, her bir kesit için en yüksek tahmin skoru elde edilir. Sistem bu skor ile eşik değerini karşılaştırmak suretiyle kesitin seçilip seçilmeyeceğine karar verir. Eşik değeri regresyon tahmin skorları değerlendirilerek 0.5 olarak ayarlanmıştır. Bu nedenle, en yüksek tahmin skoru 0.5'in altındaysa, o kesit elimine edilir. Burada hedef, menisküslerin yer almadığı kesit görüntülerinin elenmesi ve çıktı bölütleme sonuçlarının radyologlar tarafından yorumlanabilmesinin sağlanmasıdır.


4.7 Menisküs Sınırlarının Çıkartılması

Bir kesit seçtikten ve menisküsü en doğru şekilde kuşatan pencerenin (tahmini pencere) konumlandırılmasının ardından, Şekil 4.25'te gösterilen işlem hattı menisküs sınırlarının belirlenmesi için uygulanır.



Şekil 4. 25 Menisküs çıkarım aşaması için akış şeması


Menisküs sınırları, tahmin edilen pencereler elde edildikten sonra belirlenmiştir. Şekil 4.27, menisküs sınırlarının belirlenmesi aşamalarını göstermektedir. Başlangıçta, gri seviye görüntüler incelenmiş ve görüntülerin gürültülü olduğu fark edilmiştir. (Şekil 4.26). Ortanca filtresi, bu gürültüleri ortadan kaldırmak için gri seviye görüntüye uygulanmıştır. Bu filtrede, giriş görüntüsündeki her piksel değeri ilgili pikselin etrafındaki 3×3 komşuluğundaki medyan değer ile değiştirilir.



Şekil 4. 26 Ortanca filtresi ile gürültülerin azaltılması

Ardından, menisküs bölgelerini daha fazla ayırt edebilmek için piksel değerleri [0.3, 0.7] aralığına ayarlanmıştır (Şekil 4.27-c). Bu aralık değeri deneysel olarak belirlenmiştir. Daha sonra, piksel değerleri ve piksellerin komşuluklarına bakılarak siyah arka plan elenmiştir (Şekil 4.27-d). Bundan sonra, görüntü OTSU [159] metodu ile eşiklemeye tabi tutulmuştur (Şekil 4.27-e). Bu yöntemin uygulanmasını takiben, menisküs çevresindeki gereksiz bölgelerin temizlenmesi için erozyon (erosion) işlemi uygulanmıştır. Menisküsün yapısına göre en yüksek hacme sahip bölgeler seçilmiştir. Ardından,

menisküsteki delikleri doldurmak için bir şişirme (dilation) işlemi uygulanmıştır. (Şekil 4.27-f). Menisküste yer alan gereksiz çıkıntılar için 3×3'lük karesel yapı elementi ile açma (opening) işlemi uygulanmıştır (Şekil 4.27-g). Gri seviye görüntü üzerinde elde edilen menisküs sınırları Şekil 4.27-h'de görülmektedir. Burada, siyah noktalar sistemin bulunduğu sınırları, beyaz noktalar ise referans gerçeklik değerleri ile elde edilmiş sınırları göstermektedir.



Şekil 4. 27 Menisküs sınırlarını belirleme aşamaları


Menisküs sınırları belirlendikten sonra gerçek ve tahmin edilen menisküs bölgeleri arasındaki benzerlikler ölçülmüştür. Bu performans ölçüm işlemleri için Dice (4.1) ve Duyarlılık metrikleri kullanılmıştır.

$$\text{Duyarlılık}(A, B) = \frac{TP}{(TP + FN)} * 100 \quad (4.18)$$

4.8 Deneyisel Sonuçlar

Elde edilen menisküs sınırları üzerinden Dice ve duyarlılık metriği ile sistemin başarısı elde edilmiştir. Öncelikle Şekil 4.27-h seçeneğinde gerçek ve tahmin edilen koordinatların çevrelediği görüntünün arasında kalan piksel koordinatları elde edilmiştir. Elde edilen bu koordinatlar sayesinde gezdirilen pencere büyüklüğü kadarlık bir pencere için ilgi bölgesi (ROI) maskesi oluşturulmuştur. Burada ilgi bölgeleri elde edilen menisküs bölgeleridir. Yani pencere büyüklüğü kadarlık bir maskenin içerisinde menisküs sınırları arasında kalan bölgelerin koordinatlarının değeri "1" diğer bölgelerin değeri ise "0"'dır. Bu işlem hem gerçek menisküs sınırları için hem de tahmin edilen sınırlar için uygulanıp

ardından elde edilen ikili maske Şekil 4.27-a seçeneğindeki gri seviye görüntüye uygulanarak Şekil 4.28'in b ve c seçeneklerindeki görüntüler elde edilmiştir. Elde edilen bu görüntüler arasındaki ilişkinin ve benzerliğin ölçülmesi için Dice (4.1) ve Duyarlılık (4.17) değerleri hesaplanmıştır.



Şekil 4. 28 a) gerçek ve tahmin edilen menisküs sınırları, b) gerçek menisküs bölgesi, c) tahmin edilen menisküs bölgesi

Daha önce de söylendiği gibi her bir MR görüntüsünde 160 kesit görüntüsü bulunmaktadır. Bu görüntülerin yaklaşık olarak 1/3'lik bölümünde menisküsler yer almaktadır. Ancak geriye kalan 1/3'lük bölümde de başlangıç ve bitiş kesitlerinde menisküsler radyoloji uzmanlarının değerlendirmeye yapamayacağı kadar küçülmüştür. Bu sebeple hesaplamaları bütün MR kesit görüntüleri için yapmanın hem hesapsal karmaşıklığı arttıracak olması hem de radyoloji uzmanları tarafından üzerinde yorum yapılamayacak kadar küçülmüş menisküslerin yer aldığı kesit görüntülerini dahil etmenin doğru olmayacağı düşünceleriyle her bir MR görüntüsünde anlamlı sonuç verecek kesitler belirlenerek kullanılmıştır. Seçilen bu MR kesit görüntüleri için Dice benzerliği ve duyarlılık değerleri hesaplanmıştır. Çizelge 4.4'te çalışmada uygulanmış olan HOG ve LBP özellik çıkarma yöntemleri ile regresyon aşamasında kullanılan ELM ve RF yöntemleri için elde edilmiş sonuçlar görülmektedir.

Çizelge 4. 4 Dice ve Duyarlılık için Ortalama (Ort.) ve Standart Sapma (Ss) Değerleri

Yöntemler		HOG	LBP	En İyi Skorlar {HOG, LBP}
RF	Dice Ort.	80.23	78.41	81.47
	Dice Ss.	3.95	4.48	3.79
	Duyarlılık Ort.	99.60	99.59	99.64
	Duyarlılık Ss.	0.028	0.026	0.25
ELM	Dice Ort.	80.01	74.94	80.91
	Dice Ss.	4.65	5.18	4.37
	Duyarlılık Ort.	99.49	99.44	99.53
	Duyarlılık Ss.	0.03	0.04	0.026
En İyi Skorlar {RF, ELM}	Dice Ort.	81.71	80.20	82.73
	Dice Ss.	4.40	4.88	3.78
	Duyarlılık Ort.	99.69	99.65	99.78
	Duyarlılık Ss.	0.03	0.03	0.02

Çizelgede, farklı yöntemlerin birleşik kararlarından elde edilen sonuçlar gösterilmektedir. Ayrıca, ELM ve RF yöntemlerinin birleşik sonuçları da çizelgeye dahil edilmiştir. Karar birleştirme aşamasında, alternatif pencere boyutları ve özellik-regresör kombinasyonları üzerindeki en yüksek skor öncelikle her bir kesit için belirlenmiştir. Ardından, gerçek ve tahmin edilen menisküs bölgesi arasındaki benzerlik analiz edilmiştir. Çizelge 4.4'te görüleceği üzere, farklı yöntemlerin (ELM ve RF) karar birleşimi genel bölütleme performansını arttırmaktadır. Sonuçlar HOG özelliğinin bu çalışmada LBP'den daha başarılı olduğunu göstermektedir. Ayrıca, Dice yöntemi kullanılarak elde edilen sonuçlara göre ELM ile karşılaştırıldığında RF yönteminin daha iyi sonuçlar verdiği görülmüştür. Çizelge 4.4, Dice benzerlik katsayısı (DSC) ile ölçülmüş % 82.73'lük en yüksek başarı oranını göstermektedir. Benzer şekilde, duyarlılık için en yüksek başarı oranı % 99.78 olarak ölçülmüştür.

4.9 Hesapsal Karmaşıklık ve Çalışma Süreleri

Tez kapsamında gerçekleştirdiğimiz çalışmalarımız 4 çekirdekli 2.4 GHz hızında işlemciye ve 24 GB RAM'e sahip bir sunucu üzerinde MATLAB 2015b uygulaması ile gerçekleştirilmiştir. MATLAB'ın uzun gerçekleştirme sürelerini azaltmak adına çalışmada kullanılan özellik çıkarımı ve sınıflandırma yöntemlerinin C++ programlama dili ile hazırlanmış halleri MATLAB içerisinden çağırılmıştır.


Gerçekleştirilen sisteme ait süreler Çizelge 4.5'te görülmektedir. Çizelgede eğitim süresi olarak gösterilen kısım veri setinde yer alan MR görüntülerinden HOG ve LBP yöntemleri ile özelliklerin çıkartılması, ELM ve RF yöntemleri ile bu özelliklere ait modelin oluşturulmasına kadar geçen süreyi göstermektedir. Oluşturulan modele göre test görüntüleri için pencere tahminlerinin oluşturulması süreleri de test süresinde görülmektedir. Burada gösterilen süre tek bir MR görüntüsünün test edilmesi için geçen süredir. MR görüntülerinde yer alan kesit görüntülerinin bölütlenmesi için geçen sürede bölütleme süresinde görülmektedir. Bölütleme süresinde yer alan değerler de tek bir MR görüntüsünün bölütlenmesi için geçen süreyi göstermektedir.

Çizelge 4. 5 Gerçekleme Süreleri (s: saniye)

	HOG + ELM	HOG + RF	LBP + ELM	LBP + RF
Eğitim Süresi	3868 s	3955 s	1993 s	2110 s
Test Süresi	5.01 s	2.17 s	4.89 s	2.13 s
Bölütleme Süresi	6.75 s			

Çizelge 4.5 detaylı analiz edildiğinde eğitim sürelerinde belirleyici elemanın özellik çıkarımı yöntemi olduğu görülmektedir. HOG yöntemi ile özellik çıkarımı ve model oluşturulması süreleri LBP yönteminin neredeyse 2 katıdır. Aynı özellik çıkarımı yönteminde kullanılan model eğiticilerinden ELM'nin küçük bir farkla daha iyi süreler elde ettiği ancak kayda değer bir fark olmadığı görülmektedir. Test aşamasında ise belirleyici rol, model eğiticiye geçmiştir. Aynı özellik çıkarımı yöntemi kullanılarak ELM ile yaklaşık 5 saniyede test işlemi gerçekleştirilmekte iken, RF ile bu süre yaklaşık 2 saniyedir.

Şekil 4.29'da da HOG ile özellik çıkarma işleminin LBP ile özellik çıkarma işleminde geçen sürenin yaklaşık 2 katı olduğunu görmek mümkündür. Bu durumun bölüm 4.3.1'de anlatılan HOG yönteminde özellik çıkarımı yapılırken kullanılan blokların %50 oranında örtüşmesi sonucunda ortaya çıktığı düşünülmektedir.



Şekil 4. 29 HOG ve LBP ile özellik çıkarımı için süre değerleri

Sistemin hesapsal karmaşıklığını gösterebilmek adına, örnek olarak bütünsel kutular içerisinde HOG özelliklerinin çıkartılması için gereken işlem karmaşıklığı anlatılacaktır. Hesaplama için gerekli olan parametreler Çizelge 4.6’da görülmektedir.

Çizelge 4. 6 Bütünsel kutu içerisinde HOG ile özellik çıkarımında kullanılan parametreler

Bütünsel kutu genişliği (piksel)	b_{kg}	Hücre büyüklüğü (piksel)	$h_b \times h_b$
Bütünsel kutu yüksekliği (piksel)	b_{ky}	Blok büyüklüğü (piksel)	$b_b \times b_b$
Pencere genişliği (piksel)	p_g	Her bir hücre için kutu (bin) sayısı	$h_{ks} \times h_{ks}$
Pencere yüksekliği (piksel)	p_y	Pencere içerisindeki hücre sayısı	$C_x \times C_y$
Kaydırılan piksel büyüklüğü	p_{kb}	Pencere içerisindeki blok sayısı	$B_x \times B_y$
Blok hücre sayısı	$b_{hs} \times b_{hs}$		

Bütünsel kutu içerisinde elde edilen pencereler için gerçekleştirilen işlemler

$\{((b_{kg} - p_g) / p_{kb}) \times ((b_{ky} - p_y) / (p_{kb})^2)\}$ yardımıyla hesaplanır. Elde edilen her bir pencere için pencerenin büyüklüğü kadarlık bölgenin HOG özelliklerinin çıkartılması için gerekli işlemsel karmaşıklık ise;

$\{(4 \times (h_b)^2 \times (b_{hs})^2) + ((b_{hs})^2 \times (h_{ks}) + 1) \} \times B_x \times B_y$ ile hesaplanır.

Örneğin, 209×135 büyüklüğünde bütünsel sınırlayıcı kutu içerisinde 90×30’luk pencere büyüklüğü için hücre boyutu 10, hücre için kutu (bin) sayısı 9 ve blok büyüklüğü 2×2 (4 hücre) seçildiğinde ve x-y koordinatlarında 2 piksel kaydırma ile pencere gezdirme

yapıldığında bütünsel kutu içerisinde elde edilen HOG özellikleri için $\sim O(10^8)$ bit bazlı işlem karmaşıklığı elde edilmektedir.

4.10 Tartışma

Öncelikle gerçekleştirilen çalışma iç menisküslerin başarılı bir şekilde bölütlenmesini sağlayan yeni bir yöntem önermiştir. Elle bölütlenmiş veriler üzerinden gerçekleştirilen doğrulama işlemi sonucunda Dice benzerlik ölçütü kullanılarak elde edilen iç menisküs bölütleme başarıları %82.73'tür. Kullanılan veri seti içerisindeki katılımcıların hem sağlıklı menisküslere sahip hem de farklı seviyelerde bozulmuş menisküslere sahip katılımcılar olması da çalışmanın artı bir yönüdür.

Çizelge 4.7'de çalışmamızın literatürde yer alan ve menisküs bölütlemesi yapan çalışmalarla karşılaştırılması görülmektedir. Çizelgede çalışmaların iç menisküs (İM) ve dış menisküs (DM) yapılarından hangisi veya hangilerinde değerlendirmeler gerçekleştirdiği, kullanılan veri setinin boyutu ve bizim çalışmamızda kullandığımız veri seti ile aynı olup olmadığı ve bölütleme işlemi sonucunda Dice metriğine göre elde edilmiş olan başarı sonuçları görülmektedir. Dice ile elde edilen sonuçlar "ortalama $\pm$ standart sapma" olarak gösterilmektedir. Çizelge 4.8'de ise aynı çalışmaların veri seti boyutları ve veri setinde yer alan katılımcıların diz eklemi sağlık durumları yer almaktadır. Osteoartrit olmuş diz görüntüleri için Çizelge 4.8'de OA kısaltması kullanılmıştır.

Çizelge 4. 7 Literatürde yer alan ve menisküs bölütlemesi yapan çalışmaların elde ettiği başarı oranları (İM: iç menisküs, DM: dış menisküs)

Yazar(lar) ve Yılı	Menisküs Tipi	Veri seti ve Boyutu	Dice (%)
Fripp vd. 2009	İM DM	Farklı 14 MR	77.10 $\pm$ 10.00 75.10 $\pm$ 10.00
Swanson vd. 2010	DM	Farklı 24	80 $\pm$ 6 69 $\pm$ 12
Zhang vd. 2013	İM DM	Farklı 11 MR	82 $\pm$ 3
Paproki vd. 2014	İM DM	OAI 88 MR	75 $\pm$ 3 81 $\pm$ 2
Dam vd. 2015	İM DM	OAI, CCBP ve SKI10 1907 MR	76 $\pm$ 8 83 $\pm$ 5
Bu Çalışma 2017	İM	OAI 88 MR	82.73 $\pm$ 3.78

Çizelge 4. 8 Literatürde yer alan ve menisküs bölütlemesi yapan çalışmaların kullanmış oldukları veri setlerinin boyutları ve katılımcıların sağlık durumları

Yazar(lar) ve Yılı	Veri seti boyutu	Sağlıklı / OA
Fripp vd. 2009	14 MR	Sağlıklı
Swanson vd. 2010	24 MR	10 Sağlıklı 14 OA
Zhang vd. 2013	11 MR	Bilinmiyor
Paproki vd. 2014	88 MR	Karışık
Dam vd. 2015	1907 MR	Karışık
Bu Çalışma 2017	88 MR	Karışık

Fripp vd. daha önce yapmış oldukları kemik bölütlemesinden faydalananarak gerçekleştirdikleri menisküs bölütleme çalışmalarında iç menisküs için %77, dış menisküs için %75'lik bir başarı elde etmişlerdir. Ortalama menisküs yüzeylerini kullanarak aktif yüzey modelleri ile menisküsleri bölütlemişlerdir. Çalışmada kullanılan ortalama yüzey modellerinden farklı bir menisküste yöntem doğru çalışmayabilir. Çalışmada sadece 14 farklı sağlıklı insana ait MR görüntüsünün kullanılması da bu öngörüü kuvvetlendirmektedir. Hem sağlıklı hem de farklı seviyelerde rahatsızlığa sahip diz MR görüntülerinde sadece dış menisküslerin bölütlenmesi işlemini gerçekleştiren Swanson vd. yaptıkları çalışmada Dice benzerlik ölçütüne göre sağlıklı görüntüler için %80, diğer görüntüler için ise %69'luk bir başarı elde etmişlerdir. Yaptıkları çalışma yarı otomatik bir bölütleme çalışmasıdır. Zhang vd.'nin yaptıkları çalışmada katılımcılara ait sağlık durumları bilinmiyor olsa da %82 gibi bir başarı oranı ile bizim çalışmamızda elde ettiğimiz başarı oranına çok yakın bir başarı oranı elde etmişlerdir. Zhang çalışmasında bizim çalışmamızın kısıtlarından birisi olan tek uyarım dizisinde değerlendirme yapmak yerine dört farklı uyarım dizisi ile elde edilmiş çoklu ağırlıklı bir veri setinde işlemler gerçekleştirmiştir. Öte yandan hem iç hem de dış menisküs için ortak bir değerlendirme gerçekleştirmiştir. Bu yönleri ile çalışma ön plana çıkmaktadır. Paproki vd. çalışmamızla aynı sayıda ve aynı tipte veri setini kullanarak her iki menisküs içinde başarılı bir bölütleme işlemi gerçekleştirmişlerdir. Bölütleme zamanlarının yaklaşık 30 dakika olması bizim çalışmamız ile karşılaştırıldığında eksi yönü olarak gösterilebilir. Dam vd.'nin yaptıkları çalışma bizim çalışmamızda dahil olmak üzere kapsamı en geniş çalışmadır.


1907 farklı MR görüntüsünde ve farklı uyarım dizilerine sahip üç farklı veri seti üzerinde iç menisküs için %76, dış menisküs için %83'lük bir bölütleme başarıları elde etmişlerdir. Hem düşük seviye hem de yüksek seviye görüntüler üzerinde değerlendirme yapmışlardır.

Görüntü işleme alanında derin sinir ağları ile gerçekleştirilen çalışmalar son yıllarda büyük bir ivme kazanmıştır. Özellik çıkarım işlemini de kendi içerisinde gerçekleştiren derin ağlar, üzerinde düşünülmesi gereken bir konumdur. Literatürdeki çalışmalar incelendiğinde derin sinir ağları ile çok yakın bir tarihte gerçekleştirilmiş tek bir menisküs bölütleme çalışması bulunmaktadır. Aldrin'in yaptığı çalışmada menisküs bölütleme için derin öğrenme kullanılmış ve %75'lik bir başarı oranı elde edilmiştir [53]. Elde edilen başarı bizim çalışmamızın başarısından oldukça düşüktür. Ancak çalışmada derin öğrenme ile birlikte rastgele ormanlar yöntemi de kullanılmıştır. Rastgele ormanlar kullanarak eğittiği sistem sonucunda elde ettiği bölütleme başarıları %54 iken derin öğrenme başarısının %75 olması derin öğrenme yönteminin bizim çalışmamızda da iyi sonuçlar verebileceği kanaatini oluşturmaktadır. Buradaki tek düşündürücü nokta çalışmamızdaki mevcut görüntü sayısının bir derin sinir ağı eğitmek için yeterli olmayabileceğidir.



Çalışmamızda sağlıklı görüntüler için genellikle başarılı sonuçlar elde edilmiştir. Elde edilen hatalı sonuçların ne tip hatalar olduğunu daha iyi anlayabilmek adına Şekil 4.30'da elde edilen hatalı bölütlemelere örnekler verilmiştir. Şekillerde mavi ile işaretlenmiş bölgeler gerçek menisküs bölgelerini, kırmızı ile işaretlenmiş bölgeler ise sistem tarafından tahmin edilen menisküs bölgelerini göstermektedir.

Çalışmamızda bölütleme işleminde menisküs sınırları belirlenirken görüntü yoğunluğunun çevresi ile olan farklılığına dayanan işlemler gerçekleştirilmektedir. Normal şartlarda sağlıklı bir menisküsün çevresinde daha yüksek parlaklıkta kıkırdak dokuları yer almaktadır. Bazı görüntülerde menisküs ve çevre yapılarındaki anatomik farklılıklarda bozulmalar oluşmakta ve görüntü sinyalleri farklı dokular için birbirine çok benzer olabilmektedir. Bu gibi durumlarda da hatalı bölütleme sonuçları oluşabilmektedir (Şekil 4.30-a, 4.30-b, 4.30-c). Yine Şekil 4.30-b'de arka boynuzda menisküsün alt kısmında yer alan yırtıktan ya da bozulmadan ötürü menisküsün


bozulmuş olan bölgesinde piksel yoğunluğunda azalmalar oluşmuştur. Bu sebeple de burada hatalı bir işaretleme gerçekleşmiştir.





a) Ön boynuzda menisküs dışı yapılarda işaretlenmiş




b) Ön boynuzda kısmi bir fazla seçim, arka boynuzda kısmi bir eksik seçim yapılmış



c) Farklı anatomik yapılar için elde edilen sinyallerin çok benzer olmasından dolayı gerçek menisküsün dışındaki alanda seçilmiş



d) Doku kaybı olan bir görüntüde hatalı bölütleme



e) Menisküsün gövde kısmında yer alan yırtığın büyüklüğünden dolayı hatalı bölütleme

Şekil 4. 30 Hatalı bölütlemelerin olduğu 5 farklı örnek

Çalışmamızda ortaya çıkan bir diğer hata türü ise ileri seviye doku kaybı olan görüntülerde oluşmaktadır. Şekil 4.30-d incelendiğinde bu tip hataya bir örnek görülmektedir. Görüntüde ön boynuz başarılı bir şekilde bölütlenirken arka boynuzda doku kaybından kaynaklanan sinyal farklılığından dolayı arka boynuz bölütlenememiştir. Çalışmada elde edilen en hatalı bölütleme sonuçlarından bir örneğe Şekil 4.30-e seçeneğinde yer verilmiştir. Burada sistem gerçek menisküsün belli bir bölgesini yakalayamamıştır. Buradaki hatanın sebebi menisküsün gövde kısmında yer alan ve menisküsün orta kısmının tamamında uzanmış olan derin yırtıktır. Yırtıktan dolayı gövde bölümündeki sinyal değerinde farklılıklar oluşmuştur. Bu farklılıkta ne yazık ki mevcut

sistem tarafından yakalanamamıştır. Bu tip hatalı bölütleme genellikle ileri seviye yırtıklarda ve menisküsün gövde bölümlerinin yer aldığı kesitlerde görülmektedir.

Sadece iç menisküsler üzerinde bölütleme işlemleri gerçekleştirmesini, yüksek seviye görüntülerden oluşan tek bir uyarım dizisi ile elde edilmiş veri seti üzerinde değerlendirmeler yapmasını çalışmamızın geliştirilmesi gereken yönleri olarak değerlendirmemiz mümkündür.

BÖLÜM 5

MANYETİK REZONANS GÖRÜNTÜLERİNDE YER ALAN MENİSKÜS YIRTIKLARININ BİLGİSAYAR DESTEKLİ OTOMATİK TEŞHİSİ İÇİN YENİ BİR YÖNTEM

Görüntüleme cihazlarındaki teknolojik ilerlemeler tıbbi görüntülemedeki anatomik yapıların otomatik olarak bölütlenmesini yaygınlaştırmıştır. Özellikle bilgisayarlı tomografi ve manyetik rezonans görüntüleme sıklıkla tercih edilen görüntüleme yöntemleridir. Bu görüntüleme tekniklerini farklı dokulardaki normal olmayan durumları tespit etmek için uygulamak mümkündür. Bu tez çalışmasının konusu olan diz eklemi MR görüntülerindeki menisküs dokularının bölütlenmesi ve bu dokularda oluşabilecek yırtıkların tespit edilmesi de uygulandığı önemli alanlardandır.

Menisküs yırtıkları, diz ekleminde sıklıkla kıkırdak ve kemik bozulmasına neden olur. Menisküsün önemli görevlerinden birisi eklem kıkırdağını korumaktır. Ana işlevi, tibiofemoral eklem içindeki temas alanını maksimize etmek ve temas stresini en aza indirmektir. Bu eklemin temas mekaniği, menisküs yırtıkları nedeniyle kolayca değişebilir. Dahası, artiküler kıkırdak metabolizmasının yapısı bozulabilir ve bu da dizi erken osteoartrite için risk altına sokar [160]. Menisküs yırtıkları özellikle genç yaşlardaki sporcularda ortaya çıkan bir rahatsızlıktır. Çoğunlukla ani dönme hareketi olarak bilinen hareket sonucunda menisküs yırtıkları oluşmaktadır. Menisküs yırtıklarının teşhisi radyoloji uzmanları tarafından konulmaktadır. Radyoloji uzmanları tarafından MR görüntülerinde menisküslerin bölütlenmesi işlemi yaklaşık 30-35 dakika sürmektedir [161]. Teşhisin konulabilmesi için diz ekleminin bilgisayarlı tomografi ve manyetik rezonans görüntüleme gibi görüntüleme teknikleri ile görüntülenmesi gerekmektedir.

Menisküs yırtıklarının erken teşhis edilmesi, osteoartrite gibi rahatsızlıkların oluşmasını engeller ve ilerlemeden tedavi edilmesine olanak sağlar [162].

Tez çalışmamızın bu bölümünde, radyoloji uzmanlarına destek vermek için menisküs yırtıklarının otomatik bir şekilde sınıflandırılmasını gerçekleştiren bilgisayar destekli bir teşhis sistemi (CAD) oluşturmak amacıyla weDESS standardında sagittal düzlemde elde edilmiş manyetik rezonans görüntüleri kullanılmıştır. Literatürde şu ana kadar yapılmış olan çalışmalarda sadece menisküslerin yırtık olup olmadığı ortaya konmuştur. Bizim çalışmamızda yırtıkların tespiti ile ilgili iki bölüm bulunmaktadır. Birinci bölümde menisküsün yırtık olup olmadığı, ikinci bölümde ise yırtığın menisküsün hangi bölgesinde (Ön boynuz (Anterior), Gövde (Body), Arka boynuz (Posterior)) ve hangi türde (yatay yırtık, dikey yırtık gibi) olduğu belirlenmiştir. Bu tarafı ile çalışmanın özgün olduğunu söylemek yanlış olmayacaktır.

Çalışmada OAI girişimi tarafından sağlanmış 29 farklı katılımcıya ait MR görüntüsü yer almaktadır [1]. Çalışma hem iç hem de dış menisküsler için yırtık teşhisi yapabilmektedir. Öncelikle MR kesit görüntüleri üzerinden menisküslerin yer aldığı dikdörtgen pencereler elde edilmiştir. Literatürdeki çalışmaların bir bölümünde menisküslerin yer aldığı bu pencerelerin elde edilmesi için radyoloji uzmanlarından destek alınmıştır. Bizim çalışmamızda bu kısım da otomatik bir şekilde gerçekleştirilmiştir. Bu işlemin ardından elde edilen bu pencerelere kümeleme yöntemleri ile bölütleme işlemi uygulanmıştır. Kümeleme yöntemlerinden Bulanık C-Ortalamlar (BCO), Mekansal Bulanık C-Ortalamlar (MBCO) ve Güçlendirilmiş Mekansal Bulanık C-Ortalamlar (GMBCO) yöntemleri kullanılmıştır. Bölütlenmiş görüntüler üzerinde sınıflandırma işlemi için k-En Yakın Komşuluğu (k-Nearest Neighbor (kNN)), Aşırı Öğrenme Makineleri (Extreme Learning Machines (ELM)) ve Destek Vektör Makineleri (Support Vector Machines (SVM)) sınıflandırıcıları kullanılmıştır. Devam eden bölümde bu çalışmanın gerçekleşmesi için kullanılan materyal ve yöntemlerden, ardından elde edilen deneysel sonuçlardan bahsedilmektedir.

5.1 Materyal ve Yöntem

Menisküs dokularında görülen bozulmalar ve yırtılmalar yaş ilerledikçe artış göstermektedir [163]. Bunun yanı sıra, yapılmış olan çalışmalar menisküs dokularının

zarar görmesinin hem kırıkta hem de kemiklere zarar vererek osteoartrite rahatsızlığını tetiklediğini göstermektedir [164], [165]. Bu yüzden menisküs dokularındaki bozulmaların erken teşhis edilmesi farklı rahatsızlıkların ortaya çıkmasına engel olmaktadır. MR görüntülerindeki farklılıklardan dolayı radyoloji uzmanları da kimi zaman yeterli ve gerekli bilgiyi çıkarmakta zorlanabilmektedir. Ayrıca radyoloji uzmanlarının tecrübesi ile doğru orantılı olarak yanlış teşhisler de konulabilmektedir. Bu amaçlar doğrultusunda gerçekleştirdiğimiz bilgisayar destekli teşhis sisteminde (computer aided diagnosis (CAD)) menisküs dokularında yer alan yırtıkların otomatik olarak tespit edilebilmesi amaçlanmaktadır.

Çalışmamızda osteoartrite girişimi (osteoarthritis initiative (OAI)) tarafından halka erişimi açık olan veri setleri kullanılmıştır [1]. Toplamda 29 farklı katılımcının verilerinden faydalanılmıştır. Dördüncü bölümde gerçekleştirdiğimiz çalışmamız elle bölütlenmiş 88 MR görüntüsünde gerçekleştirilmiştir. Bu bölümde gerçekleştirdiğimiz çalışmamızda 29 MR görüntüsü kullanmamızın sebebi elle bölütlenmiş 88 MR görüntüsü içerisinde 29 MR görüntüsüne ait yırtık etiketlerinin bulunmasıdır.

Çizelge 5.1’de katılımcıların cinsiyetleri, vücut kitle indeksleri (VKİ) ve Kellgren Lawrence dereceleri görülmektedir. Katılımcıların %55’i erkek, %45’i kadın katılımcılardan oluşmaktadır. Çizelge 5.1’den de görüldüğü gibi çalışmamızda kullandığımız verilerin büyük bölümü K-L derecesi 2 ve 3 olan katılımcılardan oluşmaktadır.

Çizelge 5. 1 Veri setindeki katılımcıların demografik bilgileri

Cinsiyet, %	Erkek, 55%, Kadın, 45%
VKİ, ortalama $\pm$ standart sapma, kg/m²	28.70 $\pm$ 4.80
Kellgren-Lawrence derecesi, % (n)	1: 7% (2)
	2: 41% (12)
	3: 52% (15)

Kullanılan veri seti içerisindeki menisküs dokularının morfolojik yapıları Boston Core Imaging Lab’da Hunter ve ekibi tarafından skorlanmıştır [166]. Hunter ve ekibi yırtıkları skorlamak için menisküsü ön boynuz (anterior), arka boynuz (Posterior) ve gövde (body) olmak üzere üç bölüme ayırmıştır. Ayrıca yaptıkları çalışmada hem dış hem de iç menisküs için değerlendirmeler yer almaktadır. Yapılan skorlama aşağıdaki gibidir [166];

1. Normal menisküs (Tamamıyla sağlıklı)
2. Menisküs yırtığı olarak düşünölemeyecek kadar şiddetli olmayan sinyal anormalliğı (Signal abnormality)
3. Radyal yırtık (Radial tear)
4. Yatay yırtık (Horizontal tear)
5. Dikey yırtık (Vertical tear)
6. Komple yırtık (Complete tear)
7. Kısmi maserasyon (Partial maceration)
8. İlerleyici kısmi maserasyon (Progressive partial maceration)
9. Komple maserasyon (Complete maceration)

Yukarıdaki skörlara göre 29 katılımcı ile yapmış olduğumuz çalışmamızın hem dış hem de iç menisküs için ön boynuz, gövde ve arka boynuz bölgelerine göre dağılımları Çizelge 5.2 ve 5.3'te görölmektedir.

Çizelge 5. 2 İç Menisküste Yırtıkların Bölgelere Göre Dağılımı

İç Menisküs Anormalliğı, % (n)	Ön Boynuz (Anterior)	Gövde (Body)	Arka Boynuz (Posterior)
Normal	%76 (22)	%17 (5)	(0)
Sinyal Anormalliğı	%17 (5)	%31 (9)	%28 (8)
Yatay Yırtık	(0)	%14 (4)	(0)
Dikey Yırtık	(0)	(0)	%24 (7)
Komple Yırtık	(0)	(0)	%7 (2)
Kısmi Maserasyon	%7 (2)	%38 (11)	%41 (12)
Toplam	%100 (29)	%100 (29)	%100 (29)

Çizelge 5.2 ve 5.3 incelendiğinde kullanılan veri seti içerisinde yırtıkların büyük bölümünün iç menisküsler içerisinde yer aldığı görölmektedir. Daha öncede söylenildiğı gibi iç menisküsler dış menisküslere göre daha az hareketli olduğu için yırtılmaların büyük bölümü iç menisküslerde oluşmaktadır. Bu çizelgede bu durumu doğrular niteliktedir. İç menisküsler içerisinde de yırtılmaların çoğunlukla arka boynuz ve gövde bölümlerinde gerçekleştiğı görölmektedir.

Çizelge 5. 3 Dış Menisküste Yırtıkların Bölgelere Göre Dağılımı


Dış Menisküs Anormalliği, % (n)	Ön Boynuz (Anterior)	Gövde (Body)	Arka Boynuz (Posterior)
Normal	%86 (25)	%83 (24)	%83 (24)
Sinyal Anormalliği	%3 (1)	%10 (3)	%7 (2)
Yatay Yırtık	%7 (2)	%7 (2)	%3 (1)
Dikey Yırtık	%3 (1)	(0)	%7 (2)
Komple Yırtık	(0)	(0)	(0)
Kısmi Maserasyon	(0)	(0)	(0)
Toplam	%100 (29)	%100 (29)	%100 (29)

Çizelge 5.4 29 katılımcıdan elde edilen MR görüntülerindeki menisküs dokularının sağlıklı ve yırtık olarak kategorize edilmesi ile oluşturulmuştur. En yoğun yırtılmaların ya da doku kayıplarının iç menisküslerin gövde ve arka boynuzlarında olduğu bu çizelgeden de görülmektedir.

Çizelge 5. 4 İç ve dış menisküsler için yırtık ve sağlıklı menisküs sayıları


	Ön Boynuz (Anterior Horn)		Gövde (Body)		Arka Boynuz (Posterior Horn)	
	Sağlıklı	Yırtık	Sağlıklı	Yırtık	Sağlıklı	Yırtık
İç Menisküs	27	2	14	15	8	21
Dış Menisküs	26	3	27	2	26	3

Şekil 5.1’de veri setinde yer alan örnek bir MR kesiti üzerinde uyluk ve kaval kemikleri arasındaki bir menisküs üzerinde yer alan ön boynuz ve arka boynuzları görmek mümkündür.



Şekil 5. 1 Örnek bir MR kesit görüntüsü ve menisküs yapılarının konumları


Çalışmamız Şekil 5.2’de görüldüğü gibi bütünsel sınırlayıcı kutuların bulunması, özellik çıkarımı ve indirgenmesi, regresyon, bölütleme ve sınıflandırma olmak üzere beş temel adımdan ve bu adımların alt işlemlerinden oluşmaktadır. Her bir işlem adımı detaylı olarak devam eden bölümlerde ele alınacaktır.



Şekil 5. 2 Sistem genel akış diyagramı

5.2 Bütünsel Sınırlayıcı Kutular Üzerinden Özellik Çıkarımı ve İndirgenmesi

Bu aşamada gerçekleştirilen işlemlerin ilki dördüncü bölümde anlatılan bütünsel sınırlayıcı kutuların bulunması işlemidir (bkz. Bölüm 4.2). Dördüncü bölümden farklı olarak burada elde edilen bütünsel sınırlayıcı kutu veri setinde yer alan 29 farklı MR görüntüsü üzerinde gerçekleştirilmiştir. Her bir MR görüntüsü içerisinden referans gerçeklik verilerinden faydalanan menisküslerin yer alma ihtimallerinin bulunduğu minimum ve maksimum x-y koordinatları belirlenmiştir. Bu işlem veri setinde yer alan bütün MR görüntüleri için uygulanmış, ilave olarak satır ve sütunda +5 piksel dolgu (padding) eklenerek bütünsel minimum ve bütünsel maksimum noktaları elde edilmiştir. Bu sayede Şekil 5.3’teki gibi bir bütünsel sınırlayıcı kutu elde edilmiştir.




Şekil 5. 3 Bütünsel sınırlayıcı kutu ve elle bölütlenmiş örnek MR görüntüsü

Elde edilen bütünsel sınırlayıcı kutu 188 x 115 piksel boyutundadır. Böylece görüntünün tamamında (384x384) menisküs aramak yerine daha küçük bir alanda arama yapılmıştır. Bu işlem mevcut arama oranını %80 azaltmıştır. Bu işlemin ardından elde edilen bütünsel sınırlayıcı kutu içerisinde menisküslerin yer aldığı pencerelerin bulunması işlemine geçilmiştir. Özellik çıkarma işleminde öncelikle 50x160 büyüklüğünde pencereler ile bütünsel sınırlayıcı kutu içerisinde 2 piksel kaydırarak gezdirme işlemi yapılmış ve pencere büyüklüğü kadarlık bölgenin özellikleri Yönelimli Gradyan Histogramları (Histogram of Oriented Gradients (HOG)) yöntemi ile çıkartılmıştır.

HOG için farklı hücre büyüklükleri denenmiş ve en uygun büyüklük 10 olarak belirlenmiştir. Çalışmamızda önceki bölümde de dile getirildiği üzere HOG-UoCTTI türevi kullanılmıştır. Bu türevde her bir hücre için 31 boyutlu özellik elde edilmektedir. 50x160 boyutunda her bir pencere için 5x16x31 boyutunda özellik elde edilmektedir. 50x160 boyutundaki bütünsel sınırlayıcı kutu içerisinde 595 tane pencere yer almaktadır. Böylece tek bir kesit görüntüsü için 595x2480 boyutunda özellik elde edilmiştir. Her bir MR görüntüsünde menisküslerin yer aldığı yaklaşık 45 kesit görüntüsü yer almaktadır. Bu sebeple her bir MR görüntüsünde yaklaşık 26775x2480 boyutunda özellik vektörü elde edilmiştir. Özellik vektörünün boyutunun büyük olması sebebiyle sistemin zamansal maliyeti yüksek olmaktadır. Bu yüzden bu vektöre rastgele alt örnekleme (random subsampling) işlemi uygulanarak özellik vektörü yaklaşık olarak 6000x2480 boyutuna indirgenmiştir (rastgele alt örnekleme detayları için bkz. Bölüm 4.3.3). Ardından en ayırt edici özellik vektörünü elde edebilmek için PCA yöntemi ile özellik seçimi yapılmış ve en yüksek öz değere sahip 200 özellik seçilmiştir (PCA detayları için bkz. Bölüm 4.3.4).


Kullanılacak özelliklerin belirlenmesinin ardından rastgele ormanlar (random forest (RF)) yöntemi ile regresyon yöntemi uygulanmıştır.

Çalışmada regresyon işleminde hedef değişken olarak Şekil 4.5'te de görüldüğü üzere referans gerçeklik verileri ile elde edilmiş gerçek menisküs pencereleri ile bütünsel sınırlayıcı kutu içerisinde gezdirilen tahmin pencerelerinin alansal örtüşmesi kullanılmaktadır. Bu işlemin ardından HOG yöntemi ile özellikler çıkartılmış ve RF yöntemi ile regresyon işlemine tabi tutulmuştur. Böylece Şekil 5.4'te görüldüğü gibi her bir kesit görüntüsü için en iyi örtüşmeyi sağlayan ve menisküsleri içeren pencereler belirlenmiştir.



Şekil 5. 4 Dikdörtgensel pencerelerin elde edilmesi

Şekil 5.5'de uygulanan sistemin tüm detaylarının görülebildiği bir akış şeması yer almaktadır.



Şekil 5. 5 Menisküs yırtıklarının sınıflandırılması için akış şeması

5.3 Bölütleme İşlemleri

Bulanık c-ortalamlar (BCO) kümeleme yöntemi tıbbi görüntüleme, hedef tanıma ve görüntü bölütleme gibi alanlarda, kümeleme ve sınıflandırıcı tasarımlarına başarılı bir şekilde uygulanan denetimsiz bir tekniktir [167].

Bir görüntü, çeşitli özellik uzaylarında gösterilebilir ve BCO algoritması, benzer özellik noktasındaki veri noktalarını gruplayarak görüntüyü sınıflandırır. Bu kümeleme, özellik alanındaki piksellerin küme merkezlerine olan uzaklığına bağlı olarak bir maliyet fonksiyonunu tekrar tekrar asgariye indirgeyerek elde edilir. $X=(x_1, x_2, \dots, x_N)$ şeklinde N pikselden oluşan ve c kümeye ayrılmak istenen bir görüntü olsun. Burada x_i görüntünün çok boyutlu özelliklerini ifade etmektedir. Algoritmanın amacı 5.1'deki J amaç fonksiyonunu iteratif bir işlemle minimize etmektir:

$$J = \sum_{j=1}^N \sum_{i=1}^c u_{ij}^m \|x_j - v_i\|^2 \quad (5.1)$$

Burada u_{ij} , x_j pikselinin i'nci kümedeki üyelik değerini, v_i i'nci küme merkezini, $\| \cdot \|$ norm metriğini ve m değeri de bulanıklaştırma sabitini ifade etmektedir. Çalışmamızda m değeri 2 olarak belirlenmiştir. Piksel değerinin en yakın olduğu kümede maliyet fonksiyonunun değeri minimum olurken üyelik fonksiyonunun değeri maksimum olmaktadır. Üyelik fonksiyonu, bir pikselin belirli bir kümeye ait olma ihtimalini temsil eder. Bir piksele ait üyelik değerlerinin toplamı her zaman 1'e eşittir. BCO algoritmasında olasılık, yalnızca piksel ile özellik alanındaki her bir küme merkezi arasındaki mesafeye bağlıdır. Üyelik değerleri ve küme merkezleri 5.2 ve 5.3'e göre hesaplanmaktadır;

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{\|x_j - v_i\|}{\|x_j - v_k\|} \right)^{2/(m-1)}} \quad (5.2)$$

$$v_i = \frac{\sum_{j=1}^N u_{ij}^m x_j}{\sum_{j=1}^N u_{ij}^m} \quad (5.3)$$

BCO her bir küme merkezi için başlangıçta tahmini değerlerle başlar ve sonlandırma kriteri olarak da iki ardışık yineleme adımında üyelik fonksiyonundaki veya küme merkezindeki değişiklikleri karşılaştırır.

Bir görüntünün üzerindeki pikseller yüksek derecede ilintiye sahiptir; diğer bir deyişle, yakın çevredeki pikseller, neredeyse aynı özellik verisine sahiptir. Bu nedenle, komşu piksellerin mekansal ilişkisi, görüntü bölütlemeye yardımcı olabilecek önemli bir

özelliktir. Genel sınır tespit teknikleri, görüntü bölütlemesi için bu mekansal bilgiden faydalanmıştır. Bununla birlikte, konvansiyonel BCO algoritması bu uzamsal bilgiyi tam olarak kullanmamaktadır. Standart bir BCO tekniğinde, gürültülü bir piksel, anormal özellik verisi nedeniyle yanlış bir şekilde sınıflandırılır. Mekansal BCO'da (MBCO) ise komşu piksellerin küme dağılımı değerlendirildikten sonra her kümenin üyelik ağırlıkları değiştirilmektedir [28]. Bu durum, gürültünün etkisini büyük ölçüde azaltır ve algoritmayı homojen kümelenmeye yönlendirir. MBCO'da mekansal bilgiden faydalanmak için mekansal işlev 5.4'e göre tanımlanır;

$$h_{ij} = \sum_{k \in NB(x_j)} u_{ik} \quad (5.4)$$


Burada $NB(x_j)$, merkezi x_j pikseli olan bir kare pencereyi temsil eder. Çalışmamızda 5x5 piksel boyutunda bir kare pencere kullanılmıştır. Üyelik fonksiyonu gibi mekansal fonksiyon h_{ij} , x_j pikselinin i 'inci kümeye ait olma ihtimalini temsil eder. Bir pikselin bir kümedeki mekansal fonksiyonu, komşularının çoğunluğu aynı kümelere aitse büyüktür. Mekansal fonksiyon üyelik fonksiyonuna şu şekilde dahil edilmiştir:

$$u'_{ij} = \frac{u_{ij}^p h_{ij}^q}{\sum_{k=1}^c u_{kj}^p h_{kj}^q}, \quad (5.5)$$

Burada p ve q , her iki fonksiyonun (üyelik ve mekansal) görece önemini kontrol etmek için kullanılan parametrelerdir. Homojen bir bölgede, mekansal fonksiyonlar orijinal üyeliği güçlendirir ve kümeleme sonucu değişmeden kalır. Bununla birlikte, gürültülü bir piksel için, bu formül, gürültülü bir kümenin, komşu piksellerin etiketleriyle ağırlığını azaltır. Sonuç olarak, gürültülü bölgelerdeki yanlış sınıflandırılmış pikseller kolayca düzeltilebilir.

Bölütleme işleminden önce her bir MR görüntüsünün kesitleri için belirlenmiş olan pencerelerin belirli bir eşik değerine göre elimine edilmesi işlemi yapılmıştır. Elimine etmek için regresyon analizi sonucunda gerçek menisküs pencereleri ile kayan pencerelerin ne oranda örtüştüğü bilgisinden faydalanılmıştır. Burada amaç bölütleme başarısını olumsuz etkileyebilecek düşük başarıya sahip kesitlerin çıkartılmasıdır. Farklı eşik değerleri denenmiş ve en uygun eşik değerinin 0.72 olduğuna karar verilmiştir. Yani gerçek menisküslerle olan benzerliği 0.72'den küçük olan pencereye sahip kesitler devre dışı bırakılmıştır.


Çalışmamızda BCO ve MBCO yöntemleri kullanılarak menisküs bölgelerinin bölütlenmesi amaçlanmıştır. Bu yöntemlerin yanı sıra bulanık kümeleme yöntemlerinde başlangıç üyelik değerleri ne kadar doğru atanırsa elde edilen sonuçlar o kadar iyi olmaktadır. Bu sebeple BCO yöntemi ile elde edilmiş üyelik değerleri, MBCO yönteminde başlangıç üyelik değeri olarak kullanılmış ve sistemin başarısının artırılması hedeflenmiştir. Çalışmamız içerisinde biz bu yaklaşımımıza güçlendirilmiş mekansal bulanık c-ortalamlar (GMBCO) diyeceğiz. Menisküslerin yer aldığı pencerelerin elde edilmesinin ardından, anlatmış olduğumuz bu kümeleme yaklaşımlarının kullanılarak menisküs bölgelerinin bölütlenmesi işlemine geçilmiştir. Bölütlenecek pencerelere öncelikle ortanca filtresi uygulanmıştır. Bu sayede resim üzerindeki gürültüler nispeten de olsa elimine edilmiştir. Gürültülerin giderilmesinin ardından, menisküs dokularını daha belirgin hale getirmek için piksel değerleri [0.2, 0.85] aralığına çekilmiştir. Bu işlemin ardından bölütlenmiş kümeler içerisinde küme merkezleri yardımıyla menisküs içeren küme seçilmiştir. Bahsi geçen bu işlemlerin sonuçları Şekil 5.6'dan görülebilmektedir.



Şekil 5. 6 Bulanık kümeleme yöntemleri ile bölütleme işlem adımları

Veri setini almış olduğumuz çalışma grubu menisküs dokularının skorlanması için her menisküsü (iç ve dış) üç alt bölgeye ayırmıştır: ön boynuz, meniskal gövde ve arka boynuz [166]. Menisküs yırtıklarının varlığı ve tipi, bu alt bölgelerin her biri için ayrı ayrı skorlanmış şekilde veri seti içinde yer almaktadır. Bu sebeple çalışmamızda bu yapıların

ayrı ayrı sınıflandırılmasının uygun olacağı kanaatine varılmıştır. Şekil 5.7’de bölütlenmiş menisküs dokularının gövde, ön boynuz ve arka boynuz bölümlerini görmek mümkündür.



Şekil 5. 7 Menisküs dokularının bölgelere göre ayrılması

Sınıflandırma aşamasında Şekil 5.7’de görülen a, b ve c şıklarındaki görüntülerin her biri için ayrı ayrı özellikler çıkartılmış ve ayrı ayrı sınıflandırma işlemi yapılmıştır.

5.3.1 Geçerlilik İndeksleri


Literatürde farklı kümeleme yöntemlerinin birbirlerine olan üstünlüklerinin ve en uygun küme sayılarının belirlenmesinde geçerlilik indekslerinden faydalanılmaktadır. Çalışmamızda farklı kümeleme yaklaşımlarının karşılaştırılması ve en başarılı küme sayısının belirlenmesi için iki farklı geçerlilik indeksi kullanılmıştır. Bunlar Bezdek tarafından geliştirilmiş bölümlendirme katsayısı (PC) [168] ve sınıflandırma entropisi (CE) yöntemleridir [168], [169]. Bu indeksler Eşitlik 5.6 ve 5.7’deki gibi tanımlanmaktadır:

$$V_{pc} = \frac{\sum_j^N \sum_i^c u_{ij}^2}{N} \quad (5.6)$$

$$V_{ce} = \frac{-\sum_j^N \sum_i^c [u_{ij}^2 \log u_{ij}]}{N} \quad (5.7)$$

Burada N örnek sayısını, c küme sayısını, u_{ij} ise j’nci örneğin i’nci kümeye olan üyelik değerini temsil etmektedir. Bu geçerlilik fonksiyonlarının ana fikri, daha az bulanıklığa sahip bölümün daha iyi bir performans anlamına geldiği yönündedir. Sonuç olarak, en iyi kümeleme, V_{PC} değeri maksimal veya V_{CE} değeri minimal olduğunda elde edilir. Bu iki

yöntemin dezavantajları, yalnızca bulanık bölünmeyi ölçmesi ve özellik değerleriyle doğrudan bağlantılı olmamasıdır. Şekil 5.8’de farklı küme sayılarına göre PC ve CE değerlerinin GMBCO için sonuçları görülmektedir. Grafikten de görüldüğü üzere optimal küme sayısı 2’dir. Çalışmada da küme sayısı bu sebeple 2 seçilmiştir.



Şekil 5. 8 Küme sayılarına göre GMBCO geçerlilik değerleri

Çizelge 5.5’te çalışmada kullanılan bulanık kümeleme yaklaşımlarının üç farklı küme sayısına göre indeks sonuçlarını görmek mümkündür. PC ve CE sonuçlarına göre GMBCO’nin sonuçlarının kullanılan bulanık yaklaşımlar arasında en optimal sonuçlar olduğu görülmektedir.

Çizelge 5. 5 Kümeleme yöntemlerinin geçerlilik indeks sonuçları

	PC			CE		
	c=2	c=3	c=4	c=2	c=3	c=4
BCO	0.78	0.68	0.62	0.31	0.42	0.49
MBCO	0.91	0.89	0.81	0.14	0.16	0.26
GMBCO	0.93	0.91	0.90	0.13	0.16	0.19

5.4 Sınıflandırma

Medikal görüntü işlemede sınıflandırma, tanı koymada oldukça önemli bir yere sahiptir. Bu amaçla hem renkli hem de gri seviye görüntüler üzerine uygulanabilecek birçok sınıflandırma tekniği mevcuttur. Çalışmamızda bölütleme sonuçları ile elde edilen

görüntüler üzerinde HOG yöntemi uygulanarak özellikler çıkartılmıştır. HOG için farklı hücre boyutları denenmiş ve en uygun büyüklüğün 10 olduğu belirlenmiştir. Özelliklerin çıkarılmasının ardından üç farklı sınıflandırıcı ile sınıflandırma işlemi gerçekleştirilmiştir. Bu yöntemler en yakın k-komşuluğu (kNN), destek vektör makineleri (SVM) ve aşırı öğrenme makineleridir (ELM, bkz. Bölüm 4.4.1). Hangi sınıflandırma yönteminin seçileceğine karar verme aşamasında literatürde tıbbi görüntü işlemede başarılı sonuçlar veren ve kullanılan verilerin anatomik yapılarına uygun yöntemler seçilmiştir. Başlangıçta karar ağaçları ve bayes yöntemi de sınıflandırma için kullanılmış ancak elde edilen başarımların kullandığımız diğer üç yöntemden daha düşük olması sebebiyle değerlendirme dışı bırakılmıştır. Devam eden bölümde kullanmış olduğumuz üç farklı sınıflandırma yönteminin teorik altyapısı verilecektir.

5.4.1 En Yakın k-Komşuluğu (k-Nearest Neighboring (kNN)),

Parametrik olmayan bir sınıflandırma yöntemidir ve birçok sınıflandırma probleminde uygulanmıştır [170]. Yeni bir örnek için tahmin işlemi en yakın komşuluklarına bakılarak, en benzer olduğu kümeye atanarak gerçekleştirilir. KNN sınıflandırıcısı öncelikle eğitim örneklerinin özellik vektörlerini ve etiketlerini üretir ve sınıfları bilinmeyen test örneği için aynı özellikler hesaplanır. Veri noktaları arasındaki uzaklıklar hesaplanır ve en yakın k örnek seçilir. Seçilen bu k örneğin çoğunluğu hangi sınıfa mensupsa yeni örnekte o sınıfla etiketlenir. Çalışmamızda farklı k sayıları için değerlendirme sonuçları incelenmiş ve en uygun k sayısı 2 olarak belirlenmiştir. Uzaklık ölçümü yapılacak bir sorgu noktası $(X_1, X_2)_{\text{sorgu}(s)}$ ve eğitim örneklerinden bir veride $(X_1, X_2)_{\text{eğitim}(e)}$ olmak üzere öklit uzaklığı şu şekilde hesaplanır;

$$uzaklık_{se} = \sqrt{(X_1^s - X_1^e)^2 + (X_2^s - X_2^e)^2} \quad (5.8)$$

5.4.2 Destek Vektör Makineleri (Support Vector Machines (SVM))

İstatistiksel öğrenme kuramına dayalı denetimli bir sınıflandırma tekniğidir. Yöntem önceleri sadece doğrusal olarak ayrılabilen iki sınıfı birbirinden ayırt etmek için ortaya atılmıştır. İlerleyen dönemlerde çok sınıflı problemler için de başarılı bir şekilde uyarlanmıştır. SVM’de temel olarak yapılan işlem iki sınıfı birbirinden ayırabilen en

uygun karar fonksiyonun tahmin edilmesi ya da iki sınıfı birbirinden en uygun şekilde ayırabilen hiper-düzlemin elde edilmesidir [171].

$(x_i, y_i)_{1 \leq i \leq N}$ eğitim örneklerini göstermek üzere, her bir örnek $x_i \in R^d$, d özellik uzayının boyutunu, $y_i \in \{-1, 1\}$ olmak üzere sınıf etiketlerini göstermektedir. SVM'in amacı aynı etikete sahip örneklerin aynı tarafta kalacağı, verileri birbirinden ayıran bir hiper düzlem bulmaktır. Bunun için (5.9)'daki gibi bir doğru denklemi tanımlanmaktadır.

$$y_i(w \cdot x_i + b) > 0, i=1, \dots, N \quad (5.9)$$

Eğer (5.9)'daki bir hiper düzlem var ise bu verilerin lineer olarak ayrılabilir olduğunu göstermektedir. Verilerin dağılımı lineer olarak ayrılmaya uygun değilse yani non-lineer bir dağılımı varsa eğer özellik uzayı yüksek boyutlu bir özellik uzayına taşınarak lineer olarak ayrılmaları sağlanabilir [172]. Bu sayede SVM için gerekli olan hiper düzlem elde edilebilir. SVM kernel tabanlı bir sınıflandırıcıdır. Literatürde radyal, polinomial ve lineer kernel fonksiyonları en sık kullanılanlarıdır. Çalışmamızda (5.10)'da görülen radyal kernel kullanılmıştır [173]. x ve x' isimli iki örnek için elde edilmiş özellik vektörü girdi uzayında radyal kernelle şu şekilde temsil edilir;

$$K(x, x') = \exp\left(-\frac{\|x-x'\|^2}{2\sigma^2}\right) \quad (5.10)$$


Burada $\|x - x'\|^2$ iki özellik vektörü arasındaki karesel öklit uzaklığını, σ serbest parametre değişkenini göstermektedir.

SVM ikili sınıflandırma için tasarlanmış bir sınıflandırıcıdır. SVM'in çok sınıflı problemleri çözmek için geliştirilmiş bire karşı bir (one against one) ve bire karşı tüm (one against all) olmak üzere en sık kullanılan iki yaklaşımı bulunmaktadır. Çalışmamızda hem iki sınıflı hem de çok sınıflı SVM kullanılmıştır [174], [175]. Çok sınıflı SVM için bire karşı tüm yaklaşımı kullanılmıştır [174].

5.5 Deneysel Sonuçlar

Çalışmamızda şu ana kadarki bölümlerde anlatıldığı üzere üç farklı bölütleme yöntemi ile elde edilmiş sonuçlar üç farklı sınıflandırıcı ile sınıflandırılmıştır. Birden fazla sınıflandırıcının farklı bölütleme yöntemleri üzerindeki etkilerini bu sayede görmek mümkün olmaktadır. Şekil 5.9'da örnek bir MR kesiti üzerinde gerçekleştirilen işlemlerin

tamamını görmek mümkündür. Şekilde, giriş görüntüsünden sınıflandırma için kullanılacak görüntülere ulaşıncaya kadar yapılan işlemler görülmektedir.



Şekil 5. 9 Örnek bir MR kesiti üzerinde işlem adımları

Şekil 5.9'da görülen işlemler sonucunda elde edilen görüntülere bir önceki bölümde anlatılan sınıflandırma yöntemleri uygulanmıştır. Sınıflandırma başarılarının karşılaştırılması için aşağıda formülleri verilen doğruluk (accuracy), duyarlılık (sensitivity, bkz. (4.18)) ve özgüllük (specificity) ölçümleri yapılmıştır.

$$\text{Doğruluk} = \frac{TP+TN}{(TP+TN+FP+FN)} * 100 \quad (5.11)$$

$$\text{Özgüllük} = \frac{TN}{(FP+TN)} * 100 \quad (5.12)$$

Yapılan çalışmada sınıflandırma işlemi iki ayrı şekilde uygulanmıştır. Birincisinde sadece menisküs dokularının yırtık olup olmadığını tespit ettiğimiz ikili sınıflandırma yer almaktadır. Diğer sınıflandırma işleminde ise menisküs yırtıklarının tiplerinin ne olduğuna karar verdiğimiz çoklu sınıflandırma işlemi yer almaktadır. Geçerlilik indeksleri kullanılarak elde edilen sonuçlara göre en iyi bölütleme yaklaşımının GMBCO olduğu belirlenmiştir. Bu sebeple sınıflandırma işlem sonuçlarında da bu yaklaşım ile elde edilmiş sonuçlar verilecektir. Çizelge 5.6 GMBCO yöntemi ile bölütlenmiş görüntülerin sınıflandırılması ile elde edilmiş doğruluk, duyarlılık ve özgüllük değerlerini göstermektedir. Çizelgede ön boynuz için AH, arka boynuz için PH ve gövde içinde BODY kısaltmaları kullanılmıştır.

Çizelgeden hem ikili hem de çoklu sınıflandırma sonuçlarını menisküsün farklı bölgelerine göre görmek mümkündür. Değerlendirmeler ağırlıklı olarak menisküs yırtık çeşitliliğinin yoğun olduğu iç menisküslerin gövde (BODY) ve arka boynuzları (PH) üzerinden yapılacaktır. Çünkü Çizelge 5.4 incelendiğinde dış menisküsün tüm bölgelerinde ve iç menisküsün ön boynuz (AH) bölgesinde çeşitliliğin çok düşük olduğu ve genellikle sağlıklı menisküslerin olduğu görülmektedir. Bu sebeple değerlendirmelerin iç menisküsün BODY ve PH'ı üzerinde yapılmasının doğru olacağı düşünülmüştür.


Çizelge 5. 6 İç ve dış menisküsler için ikili ve çoklu sınıflandırma sonuçları

		İç Menisküs için İkili Sınıflandırma			Dış Menisküs için İkili Sınıflandırma			İç Menisküs için Çoklu Sınıflandırma			Dış Menisküs için Çoklu Sınıflandırma		
		AH	BODY	PH	AH	BODY	PH	AH	BODY	PH	AH	BODY	PH
kNN	Doğ. (%)	90.19	82.05	82.01	91.21	85.31	89.69	72.69	76.96	80.96	86.19	83.37	84.34
	Özg. (%)	97.45	79.12	71.22	98.36	91.73	96.85	74.58	76.58	70.12	93.45	90.79	91.82
	Duy. (%)	50.37	86.15	86.14	51.58	44.86	49.77	48.85	78.42	89.70	46.37	42.64	48.76
ELM	Doğ. (%)	93.51	85.35	85.25	91.96	89.72	92.91	77.51	84.96	84.97	89.51	88.31	88.94
	Özg. (%)	100	81.42	74.54	99.82	99.16	99.56	80.84	86.09	82.77	96.05	97.25	98.71
	Duy. (%)	54.63	89.48	89.15	55.39	54.34	55.13	52.66	94.77	94.81	50.63	53.74	52.39
SVM	Doğ. (%)	90.05	80.01	80.58	92.71	83.25	88.55	71.01	75.98	83.65	86.05	81.99	83.78
	Özg. (%)	97.21	77.08	69.98	98.24	90.98	96.91	75.35	74.22	73.85	93.21	89.55	92.93
	Duy. (%)	49.78	84.18	84.65	50.26	42.47	45.88	47.52	82.20	92.27	45.78	40.65	44.65

Çizelge 5.6'da doğruluk için 'Doğ.', duyarlılık için 'Duy.' ve özgüllük içinde 'Özg.' kısaltmaları kullanılmıştır. Çizelge 5.6 incelendiğinde yırtık sayısının az olduğu dış menisküslerin doğruluk ve duyarlılık başarı yüzdelerinin hem ikili hem de çoklu sınıflandırma için oldukça yüksek olduğu görülmektedir. Fakat yırtık menisküsleri tespit edebilme kabiliyeti olarak değerlendirilen duyarlılık sonuçlarının dış menisküs için oldukça düşük olduğu görülmektedir. Çünkü veri seti içerisinde bu menisküs türünde yırtık menisküs içeren MR görüntüsü çok azdır. Öte yandan çizelgeden en başarılı sınıflandırıcının ELM olduğunu görmek mümkündür. SVM ise kNN ve ELM yöntemlerinden kısmen daha az başarılı sonuçlar elde etmiştir. Yırtık sayısının fazla olduğu iç menisküsün BODY ve PH bölgeleri için elde edilen en yüksek başarı oranları sırasıyla %84.96 ve %84.97'dir.

Çizelge 5.6'nın okunabilirliğini artırmak adına Şekil 5.10'da görülen kutu grafiği (box-plot) oluşturulmuştur. Şekil 5.10 incelendiğinde her bir sınıflayıcının farklı performans

metriklerine göre sonuçlarını değerlendirmek mümkündür. Şekil 5.10'dan da görüldüğü üzere menisküs yırtıklarının sınıflandırma başarıları kutu grafiğinde bölgelerine (AH, PH, BODY) göre değil, bir bütün olarak verilmiştir.



Şekil 5. 10 Farklı performans değerlendiricileri için kutu grafiği (box plot)

Şekil 5.10'dan her bir yöntemin sınıflandırma için elde edilen doğruluk, duyarlılık ve özgüllük değerlerini ayrı ayrı görmek mümkündür. Aynı zamanda Şekil 5.10'dan en başarılı yöntemin ELM olduğunu ve SVM ile kNN yöntemlerinin başarılarının da birbirine yakın olduğu görülmektedir.

Çizelge 5.7 ve 5.8, çok boyutlu ve ikili sınıflandırıcılar için karışıklık matrislerini göstermektedir. Çizelgelerde toplam 29 MR görüntüsünden elde edilen 1031 MR kesiti için doğru ve yanlış sınıflandırma sayılarını görmek mümkündür. Karışıklık matrisi sonuçları, veri setinin çeşitliliğinin en fazla olduğu iç menisküsün BODY ve PH bölgeleri için verilmiştir.

Çizelge 5.7'den sinyal anormalliği olan görüntüler ile kısmi Maserasyon içeren görüntüler ve sağlıklı görüntüler birbirine diğerlerinden daha fazla karıştırılmıştır. Çünkü sinyal anormalliği olan görüntüler de menisküs yırtığı olmayan görüntülerdir. Bu sebeple sağlıklı görüntüler ile karıştırılma oranı daha yüksek olmaktadır. Ayrıca kısmi maserasyon diye tabir edilen görüntülerde hem kıkırdakta hem de menisküste doku kayıpları olabilmektedir. Bu tür görüntülerde kimi kesitlerde menisküslerde herhangi bir yırtık

olmama durumu da olduğu için sinyal anormalliği olan görüntülerle ve sağlıklı görüntülerle sistem tarafından karıştırıldığı anlaşılmaktadır.

Çizelge 5. 7 Çoklu sınıflandırma için karışıklık matrisi

		Gerçek Sınıf				
		Sinyal Anormalliği	Yatay Yırtık	Kısmi Maserasyon	Sağlıklı Menisküs	
Tahmin Edilen Sınıf	Sinyal Anormalliği	270	3	20	18	İç Menisküs Body
	Yatay Yırtık	9	104	12	3	
	Kısmi Maserasyon	27	3	337	15	
	Sağlıklı Menisküs	20	1	24	165	
		Sinyal Anormalliği	Yatay Yırtık	Komple Yırtık	Kısmi Maserasyon	İç Menisküs Arka Boynuz
	Sinyal Anormalliği	215	10	4	14	
	Yatay Yırtık	23	224	10	18	
	Komple Yırtık	7	12	69	13	
	Kısmi Maserasyon	30	4	10	368	

İkili sınıflandırma için karışıklık matrisi Çizelge 5.8’de görülmektedir.

Çizelge 5. 8 İkili sınıflandırma için karışıklık matrisi

		Gerçek Sınıf		
		Sağlıklı + Sinyal An.	Yırtık	
Tahmin Edilen Sınıf	Sağlıklı + Sinyal An.	429	53	İç Menisküs Body
	Yırtık	98	451	
		Sağlıklı + Sinyal An.	Yırtık	İç Menisküs Arka Boynuz
	Sağlıklı + Sinyal An.	205	82	
	Yırtık	70	674	

5.6 Hesaplama Zamanları

4 çekirdekli 2.4 GHz hızında işlemciye ve 24 GB RAM’e sahip bir sunucu üzerinde MATLAB 2015b uygulaması ile gerçekleştirilen uygulamaya ait hesaplama süreleri Çizelge 5.9’da gösterilmektedir. Burada gösterilen süreler 29 MR görüntüsüne ait özelliklerin çıkartılması ve birini-dışarda-bırak (leave-one-out) çapraz geçerlilik (cross validation (CV)) yöntemine göre bu özelliklerle sistemin eğitilmesini ve tek bir MR görüntüsünün test edilmesi için geçen süreyi ifade etmektedir. Birini-dışarda-bırak (leave-one-out)

çapraz geçerlilik yöntemi kullanıldığından dolayı her bir MR görüntüsü ayrı ayrı test için kullanılırken kalan MR görüntüleri de eğitim için kullanılmıştır. Yaklaşık 3-4 dakika içinde tüm bu işlemler gerçekleştirilmiştir.

Çizelge 5. 9 Farklı sınıflayıcılara göre sistemin gerçekleştirme zamanı

		İkili Sınıflandırma (s)	Çoklu Sınıflandırma (s)
Süre (s)	kNN	179.18	182.86
	ELM	214.89	218.57
	SVM	184.44	188.12

Çizelge 5.9'dan en hızlı sınıflandırıcının kNN olduğu görülmektedir.

5.7 Tartışma

Bu çalışmada menisküs yırtıklarının tespitini, menisküslerin konumuna ve tipine göre gerçekleştirebilen yeni bir sistem önerilmiştir. Çizelge 5.10, 5.11 ve 5.12’te literatürde gerçekleştirilen benzer çalışmalarla ilgili çeşitli karşılaştırmalar yer almaktadır. Çizelge 5.10’da çalışmaların kullandıkları yöntemler, MR tarayıcıların manyetikleme yetenekleri, görüntülerin elde edildiği uyarım dizileri ve düzlemleri görülmektedir. Çizelge 5.11’de ise katılımcıların sağlık durumları ve çalışmalarda gerçekleştirilen işlemler karşılaştırılmaktadır. Çizelge 5.12’de de bu çalışmaların elde ettikleri başarı oranları, uygulandıkları menisküs tipleri ve kullanılan veri setlerinin boyutları görülmektedir. Bu üç tablodaki verilerden faydalanılarak çalışmamızın tablodaki diğer çalışmalarla karşılaştırılması sağlanacak, artı ve eksi yönleri üzerinde durulmaya çalışılacaktır.

İlk çalışma Boniatis vd.’nin 2008 yılında gerçekleştirdikleri çalışmadır. Boniatis yaptıkları çalışmada normal ve bozulmuş menisküsler arasındaki ayrımı ortaya koymayı amaçladıklarını belirtmişlerdir. Çalışmada 55 farklı MR görüntüsü kullanılmıştır. Katılımcıların menisküs yapıları 15’i sağlıklı (seviye 0), 20’si seviye 1 ve 20’si seviye 2 olarak iki farklı radyoloji uzmanı yardımıyla belirlenmiştir. Çalışmada 55 farklı MR görüntüsü üzerinde değerlendirme yapılmış gibi bir algı oluşmakta ancak menisküslerin arka boynuzlarının yer aldığı 55 farklı kesit görüntüsü üzerinde sınıflandırma yapılmaktadır. Bizim çalışmamızda 29 MR görüntüsü ve her bir MR görüntüsü üzerinde de 160 kesit görüntüsü olduğu düşünüldüğünde yapılan işlemin seviyesi anlaşılabilir. Boniatis’n çalışmasında bölge büyütme ile bölütlenmiş görüntüler

Bayes yöntemi ile sınıflandırılmış ve Çizelge 5.12’de de görüldüğü gibi %89.1’lik bir başarı elde edilmiştir. Elde edilen başarı yüksek gibi görünse de 55 kesit görüntüsünde bu başarıyı elde etmesi, yapılan işlemin genelleme performansının sorgulanmasına yol açmaktadır.

Çizelge 5. 10 Literatürde yer alan ve menisküs yırtık tespiti yapan çalışmaların kullanmış oldukları veri setlerinin boyutları ve katılımcıların sağlık durumları

Yazar(lar) ve Yılı	Yöntem	Uyarım Dizisi	Düzlem	Manyetikleme Yeteneği
Boniastis vd. 2008	Bölge büyütme ile bölütleme Bayes ile sınıflama	T1	Sagital	1.5
Köse vd. 2009	Histogram temelli yaklaşım, İstatiksel bölütleme yaklaşımı	Belirtilmemiş	Sagital	Belirtilmemiş
Ramakrishna vd. 2009	İlgi bölgelerinin seçimi, eşikleme, alan ve yüzey kısıtlamaları, görünüş maskelerinin uygulanması	T1	Sagital	1.5
Fu vd. 2013	Düzy kümeleri ile aktif çevre modeli, eş oluşum matrisi, SVM	Belirtilmemiş	Sagital	Belirtilmemiş
Zarandi vd. 2016	BCO ve Olasılıksal-BCO Algılayıcı sinir ağı	Proton ağırlıklı	Sagital	Belirtilmemiş
Bu Çalışma 2017	BCO, MBCO, GMBCO kNN, ELM ve SVM	weDESS	Sagital	3.0

Çizelge 5. 11 Literatürde yer alan ve menisküs yırtık tespiti yapan çalışmaların kullanmış oldukları veri setlerinin boyutları ve katılımcıların sağlık durumları

Yazar(lar) ve Yılı	Yapılan İşlem	Sağlıklı / OA
Boniastis vd. 2008	Normal ve bozulmuş menisküsler arasındaki ayrımın otomatik tespiti	Karışık
Köse vd. 2009	Menisküs yırtıkları için otomatik teşhis sistemi	Karışık
Ramakrishna vd. 2009	Menisküs yırtıkları için bilgisayar destekli otomatik teşhis sistemi	OA
Fu vd. 2013	MR görüntülerinde menisküs yırtıklarının bilgisayar destekli teşhisi	Karışık
Zarandi vd. 2016	Menisküs yırtıklarının tespiti	Karışık
Bu Çalışma 2017	Menisküs yırtıkların türlerine ve bölgelerine göre sınıflandırılması	Karışık

Köse vd. yaptıkları çalışmada menisküs yırtıkları için MR görüntüleri üzerinde otomatik teşhis sistemi oluşturmuşlardır. Çalışmada yırtık menisküsler için %88.3, sağlıklı

görüntüler için ise %95.7 gibi oldukça yüksek başarılar elde edilmiştir. Ancak çalışmada çok fazla belirsiz alan bulunmaktadır. Öncelikle çalışma Boniatis'in çalışmasındaki gibi MR görüntüleri içerisinde elle belirlenmiş kesitler üzerinde gerçekleştirilmiştir. Yani 3-B MR görüntüleri ile değil de iki boyutlu kesitlerde çalışılmıştır. Çünkü 30 farklı hastadan elde edilmiş 500 görüntüden bahsedilmekte ve bu 500 görüntünün de tamamı kullanılmamaktadır. Yırtık menisküsleri teşhis etme başarısının 30 görüntü üzerinden, sağlıklı menisküslerin ise 70 görüntü üzerinden gerçekleştirildiği belirtilmektedir. MR kesitlerinin nasıl belirlendiğine dair bir değerlendirme bulunmamaktadır. Bu sebeple bu çalışmada da elde edilen başarının çalışmamızda elde edilen başarı ile karşılaştırılması çokta anlamlı olmamaktadır.

Çizelge 5. 12 Literatürde yer alan ve menisküs yırtık tespiti yapan çalışmaların elde ettiği başarı oranları (İM: iç menisküs, DM: dış menisküs)

Yazar(lar) ve Yılı	Menisküs Tipi	Veri seti ve Boyutu	Başarı oranı (%)
Boniatis vd. 2008	İM-Arka Boynuz	Farklı 55 MR	Doğruluk: 89.1 Duyarlılık: 92.5 Özgüllük: 80.0
Köse vd. 2009	Belirtilmemiş	Farklı 30 hastaya ait 500 görüntü	Hastalıklı görüntü için doğruluk: 88.3 Sağlıklı görüntü için doğruluk: 95.7
Ramakrishna vd. 2009	İM- Ön ve Arka Boynuz DM- Ön ve Arka Boynuz	Farklı 40 MR	Duyarlılık: 83.87 Özgüllük: 75.19
Fu vd. 2013	Belirtilmemiş	Farklı 166 MR	Duyarlılık: 0.727
Zarandi vd. 2016	İM- Ön ve Arka Boynuz DM- Ön ve Arka Boynuz	Farklı 50 MR	Hassaslık: %88.82-92.13
Bu Çalışma 2017	İM- Ön Boynuz, Arka Boynuz ve Gövde DM- Ön Boynuz, Arka Boynuz ve Gövde	OAI 29 MR	Doğruluk: 84.97 Özgüllük: 86.09 Duyarlılık: 94.77

Ramakrishna vd. yaptıkları çalışmada düşük alan tarayıcılarla elde edilmiş T1 uyarım dizisine sahip MR görüntüleri için bilgisayar destekli otomatik bir teşhis sistemi sunmuşlardır. Menisküs yırtıklarının farklı seviyelerine sahip 40 katılımcıya uyguladıkları çalışmalarının sonucunda Çizelge 5.12'de de görüldüğü gibi %83.87 duyarlılık ve %75.19 özgüllük değeri elde etmişlerdir. Çalışmada bizim çalışmamızla karşılaştırdığımızda çok fazla ön bilgi kullanılmıştır. Örneğin kesit seçiminde uzman bilgileri neticesinde belli kesit

aralıkları elle belirlenmiştir. Uyguladıkları sistem kullandıkları veri setine aşırı bağımlı bir sistem olmuştur. Bu sistemin farklı bir veri setine uygulanma ihtimali çok düşüktür.

Fu vd. düzey kümelerini kullanarak aktif çevre modeli yaklaşımı ile bölütleme işlemi yapmışlar, ardından eş oluşum matrisleri ile özellikleri çıkarıp, destek vektör makinaları ile sınıflandırarak menisküs yırtıklarını teşhis eden bir sistem ortaya koymuşlardır. Çalışmada 166 MR görüntüsü kullanarak 29 MR görüntüsünden oluşan bizim çalışmamızın çok üzerinde bir veri seti ile değerlendirme yapmışlardır. %72.7'lik duyarlılık değeri çalışmamızın oldukça gerisinde kalmıştır. Yine çalışmanın başlangıç çerçevelerinin kullanıcı tarafından belirleniyor olması yarı otomatik bir yaklaşım olduğunu göstermektedir. Çalışmanın en büyük artısı tek bir görüntü için yırtık tespiti 5.5 saniyede gerçekleştiriyor olmasıdır.

Zarandi vd.'nin 2016 yılında yaptıkları çalışma, incelediğimiz çalışmalar içerisinde en başarılı sonuçlara sahip çalışmadır. Kullandıkları yöntemler itibariyle de çalışmamıza benzerlik göstermektedir. Bulanık kümeleme yaklaşımlarını kullanarak bölütleme işlemini gerçekleştirmişler ve algılayıcı sinir ağları ile de sınıflandırma gerçekleştirmişlerdir. Sağlıklı ve bozulmuş menisküslere sahip 50 katılımcının görüntülerine uygulanan çalışmada Çizelge 5.12'de görüldüğü gibi menisküslerin tiplerine ve bölgelerine göre %88.82-92.13 aralığında hassaslık (precision) değeri elde etmişlerdir. Çalışmanın elde ettiği başarı sonuçları nispeten bizim çalışmamızdan daha yüksektir. Bizim çalışmamızın bu çalışmaya karşı artı yönü ise menisküs yırtık tiplerinin de sınıflandırılmış olmasıdır. Çalışmada proton ağırlıklı uyarım dizisi kullanmanın menisküs yırtıklarının tespitinde T1 ve T2 uyarım dizilerinden daha iyi sonuçlar elde edildiği belirtilmiştir. Çalışmada kullanılan görüntüler analiz edildiğinde proton ağırlıklı görüntüler üzerinde menisküs yırtık tespitinin bizim kullandığımız weDESS uyarım dizisine göre de daha iyi sonuçlar verebileceği kanısı oluşmuştur.

Yaptığımız çalışmanın literatürdeki diğer çalışmalarla karşılaştırıldığında en büyük artısı menisküs yırtık tiplerine göre bir sınıflandırma yapmış olmasıdır. Ancak kullandığımız veri seti içerisinde dış menisküsler için yırtık sayısının çok düşük olması bu tip menisküsler için genelleme yapmamızın önünde bir kısıt olmuştur. Öte yandan Hunter ve ekibinin gerçekleştirdikleri yırtık türlerini kullandığımız çalışmamızın 29 MR görüntüsünden oluşan veri seti içerisinde bazı yırtık tiplerinin hiç yer almaması da bir başka kısıttır. Hem

iç hem de dış menisküsler için daha geniş kapsamlı ve her türden yırtık tipinin olduğu bir veri setinde değerlendirmeler yapmanın elde edilen başarımın genellenmesinde önemli olacağı düşünülmektedir. Öte yandan incelenen çalışmalar neticesinde menisküs yırtık sinyallerinin daha belirgin olduğu farklı uyarım dizilerinde (Proton ağırlıklı gibi) daha iyi sonuçlar elde edilebileceği öngörülmektedir. Menisküs yırtıkları üzerine gerçekleştirilen çalışmaların tamamında sagittal düzlem MR görüntüleri kullanılmış olsa bile koronol ve aksiyal düzlemde de değerlendirmeler yapmanın farklı bakış açıları kazandırabileceği de yine öngörüler arasındadır.

5.8 Önerilen Yaklaşımların Karşılaştırılması

Yapmış olduğumuz çalışmalarda diz ekleminde yer alan menisküs yapılarının bölütlenmesi ve menisküs yırtıklarının sınıflandırılması için farklı yaklaşımlar önerilmiştir. Önerilen bütün bu yaklaşımların birbirleri ile karşılaştırılması için yırtık tespitinde kullanmış olduğumuz 29 farklı MR görüntüsünde, iç menisküslerin gövde bölümlerinin menisküs yırtık tiplerine göre sınıflandırılması işleminde uygulanması ve uygulama sonuçlarının karşılaştırılması işlemi gerçekleştirilmiştir (İç menisküslerin gövde bölümü, sağlıklı ve yırtık menisküs dağılımının dengeli olması sebebiyle seçilmiştir). Bu karşılaştırma işleminde yapmış olduğumuz çalışmaların başarılarının daha iyi anlaşılabilmesi için birde elle bölütlenmiş veriler ile aynı sınıflandırma işlemi gerçekleştirilmiştir.

Çalışmamızda kullandığımız 29 farklı MR görüntüsü için dördüncü bölümde gerçekleştirdiğimiz bölütleme, BCO yöntemi ile bölütleme, GMBCO ile bölütleme ve elle bölütlenmiş referans gerçeklik görüntüleri ile bölütleme işlemi sonucunda yırtık menisküs ve sağlıklı menisküs dağılımının en dengeli olduğu iç menisküslerin gövde bölümü için gerçekleştirilen yırtık tiplerinin sınıflandırılmasına dair karşılaştırılmalı sonuçlar Çizelge 5.13'te görülmektedir. Çizelge incelendiğinde en iyi sınıflandırma sonuçlarının elle bölütlenmiş referans gerçeklik görüntülerini kullanarak elde ettiğimiz bölütleme işleminin sonucunda elde edilen verilere uygulanması ile ortaya çıktığı görülmektedir. Elle bölütlenmiş görüntüler için en iyi sınıflandırmanın doğruluk değeri %93.89 olarak elde edilmiştir.

Mekansal bulanık c-ortalamalar yönteminin bulanık c-ortalamalar yöntemi ile elde edilen bölütleme işlemini iyileştirdiği Çizelge 5.13'teki sonuçlardan görülmektedir. Burada BCO yöntemine mekansal bilginin eklenmesinin ve başlangıç küme merkezlerinin belirlenmesinde kullanmış olduğumuz stratejilerin işe yaradığını görmek mümkündür. Dördüncü bölümde uyguladığımız morfolojik işlemlerle elde edilen bölütleme işleminin sonuçları ile gerçekleştirilen sınıflandırma işleminin başarı oranlarının, BCO yöntemi ile yapılmış bölütleme ile elde edilen başarı oranları ile benzerlik gösterdiği ancak küçük farklarla geride kaldığını Çizelge 5.13'ten görmekteyiz. Burada dördüncü bölümde morfolojik işlemlerle gerçekleştirdiğimiz bölütleme yaklaşımının menisküslerin yırtık seviyelerine göre sınıflandırılmasında istenilen seviyelerde sonuçlar üretememesi bu yaklaşımın iyileştirilmeye ihtiyacı olduğunu göstermektedir.

Çizelge 5. 13 İç menisküslerin gövde bölümü için farklı bölütleme yaklaşımları ile bölütlenmiş görüntülerin menisküs yırtık tipleri sınıflandırma sonuçları

		Morfolojik İşlemlerle Bölütleme	BCO ile Bölütleme	GMBCO ile Bölütleme	Elle Bölütleme
KNN	Doğruluk (%)	74.08	74.49	76.96	93.89
	Özgüllük (%)	72.79	74.54	76.58	98.27
	Duyarlılık (%)	70.51	76.74	78.42	96.05
ELM	Doğruluk (%)	81.91	82.39	84.96	92.09
	Özgüllük (%)	82.78	84.78	86.09	96.53
	Duyarlılık (%)	90.27	90.43	94.77	95.07
SVM	Doğruluk (%)	72.59	74.43	75.98	89.39
	Özgüllük (%)	71.13	71.79	74.22	95.30
	Duyarlılık (%)	80.28	79.76	82.20	90.13

Kümeleme yöntemlerinin bölütleme işlemlerinde kullanılması sonucunda elde edilen bölütlenmiş görüntüler ile yapılan sınıflandırma işleminin literatüre ve bilime katkı sağlayacak nitelikte sonuçlar üretildiği görülmektedir. Ancak elle bölütlenmiş görüntüler için elde edilen sonuçlarla karşılaştırıldığında mevcut yöntemlerde geliştirmeler yapılabileceği anlaşılmaktadır.

SONUÇ VE ÖNERİLER

Diz eklemindeki en önemli yapılardan birisi kıkırdak diğeri menisküs yapılarıdır. Menisküsün zarar görmesi kıkırdak yapılarına zarar verebilmektedir. Bu da osteoartrite denilen rahatsızlığa sebep olmaktadır. Ayrıca menisküsün zarar görmesi hareket yeteneğinin sınırlandırılması anlamına gelmektedir. Bu sebeple menisküs dokularında erken tanı, tetkiklerin düzenli, hızlı ve hata oranı düşük bir şekilde gerçekleştirilmesi önem arz etmektedir.

Diz ekleminde yer alan kıkırdak ve menisküs gibi dokular belirgin bir şekle sahip olmayan analiz etmesi zor yapılardır. Radyoloji uzmanları da bu dokuları el ile incelerken hatalar yapabilmekte ve hata yapmasa bile çok büyük zaman kaybı yaşanmaktadır. Öte yandan bu alanda yapılmış kimi çalışmalar sadece sağlıklı insanların verilerine uygulanmıştır. Böyle bir durum radyoloji uzmanlarına fayda sağlamak hususunda çokta anlamlı olmamaktadır. Bu nedenle, bu çalışmada kullanılan veri kümesi hastalıklı ve sağlıklı katılımcılardan oluşturulmuştur.

Tez çalışması boyunca iki farklı uygulama yapılmıştır. Birinci uygulamada menisküs dokularının bölütlenmesi işlemi gerçekleştirilmiştir. Standart şekli olmayan menisküsün otomatik bölütlenmesi hem önemli hem de zor bir süreçtir. Birinci çalışmada diz MR görüntülerinde menisküsün otomatik bölütlenmesini sağlayan yeni bir yaklaşım önerilmiştir. Çalışma iki ana kısma ayrılmıştır. İlk aşamada, menisküsü çevreleyen en küçük dikdörtgen sınırlayıcı kutu içerisinde menisküslerin yer aldığı pencerelerin tahmin edilmesi amaçlanmıştır. Pencerelerin belirlenmesi işlemi HOG yöntemi ile elde edilen özelliklerin RF yöntemi ile modellenmesi sonucunda %91 başarı oranı ile gerçekleştirilmiştir. İkinci aşamada ise elde edilen bu pencereler içerisinde menisküs

sınırlarının çıkartılması sağlanmıştır. Tüm işlemler sonrasında, Dice benzerlik ölçümü ile menisküs çıkarma başarı oranı %82.73 olarak ölçülmüştür. Farklı yöntemlerin kararlarının birleştirilmesinin böyle yüksek bir başarı oranı elde etmede faydalı olduğu görülmüştür. Ayrıca herhangi bir ön işleme tabi tutulmadan (kemik bölütlemesi vb.) menisküslerin başarıyla tespit edilebileceği gösterilmiştir. Elde edilen yüksek başarının bir diğer nedeni, sistemin iki temel parçaya bölünmesi ve birinci bölümde menisküsün bulunduğu en ufak pencerelerin çıkartılmasıdır. İlk bölümde elde edilen sonuçlar, menisküslerin yer almadığı ve radyologlar tarafından değerlendirilemeyen çok küçük boyutlarda menisküslü kesitleri ortadan kaldırmak için ikinci bölümde kullanılmıştır. Yapılan bu işlemin sistem başarısını önemli ölçüde arttırdığı görülmektedir. Performansı geliştiren bir diğer önemli faktör, ilk bölümde, farklı boyutlardaki pencerelerin kullanılması ve bu pencereler için ayrı ayrı özellik çıkarımıdır.

Tez kapsamında gerçekleştirilen ikinci uygulamada bulanık kümeleme yaklaşımları ile menisküsler bölütlenerek yırtıkların otomatik olarak sınıflandırılması işlemi gerçekleştirilmiştir. Diğer bir ifadeyle menisküs yırtıklarının saptanması için otomatik bir CAD sistemi sunulmuştur. Aynı zamanda radyologlara menisküs yırtıklarının tespit edilmesi aşamasında yardımcı olacak bir karar destek sistemi oluşturulmuştur. Önerilen CAD sistemi bütünsel sınırlayıcı kutuların bulunması, özellik çıkarımı ve indirgenmesi, regresyon, bölütleme ve sınıflandırma olmak üzere temelde beş adımdan oluşmaktadır. İlk adımda menisküslerin yer aldığı minimum pencerelerin elde edilmesi işlemi gelmektedir. Sonrasında bölütleme işlemi gerçekleştirilmiştir. Bu aşamada ise farklı bulanık kümeleme yaklaşımları ile menisküs yapıları bölütlenmiştir. Son adımda ise bölütlenmiş görüntüler üzerinde menisküs yırtıklarının sınıflandırılması işlemi gerçekleştirilmiştir. Yapılan sınıflandırma işleminin sonucunda hem dış hem de iç menisküslerin ön ve arka boynuzları ile gövde bölümlerinde yer alan yırtıklar ve normal olmayan durumlar otomatik bir şekilde tespit edilmiştir.

Yapmış olduğumuz çalışma sadece menisküs yırtık ya da değil sorusuna cevap vermemekte bunun yanı sıra menisküsün hangi bölgesinde yırtık olduğu ve yırtığın türünün ne olduğu tespit edilmektedir. Aynı zamanda radyologlar menisküs yırtıklarını tespit edebilmek için tek bir MR görüntüsü üzerinde 30-35 dakika civarında bir zaman harcamaktadır. Mevcut sistemde bu işlem 3-4 dakika gibi kısa bir sürede

gerçekleştirilmektedir. Önermiş olduğumuz yöntemin her bir adımında başarıyı etkileyebilecek bütün etmenler tek tek analiz edilmiş ve başarıyı arttırabilmek için bütün elemanlar üzerinde çalışılmıştır.

Gerçekleştirilen her iki uygulamada çeşitli zorluklarla da karşılaşmıştır. Her şeyden önce kullanmış olduğumuz weDESS standardındaki görüntülerin temel oluşturulma amacı kırıldak dokularının analiz edilmesidir. Bu sebeple veri seti içerisinde yer alan kimi görüntülerde menisküs yapılarının çözünürlüklerinin düşük olduğu tespit edilmiştir. Bu durumda hatalı bölütleme işlemlerine sebep olabilmektedir. Bu tip menisküs yapılarının bölütlenmesi sonucunda oluşan hataları ortadan kaldırabilmek adına farklı görüntü işleme teknikleri ile iyileştirmeler yapılmaya çalışılmıştır. Ayrıca, veri setinin yüksek bellek maliyeti sebebiyle tüm verilerin hafızaya alınması olanaksızdır. Bu sorunun üstesinden gelmek için alt örnekleme, örnek azaltma gibi stratejiler uygulanmıştır. Bir diğer zorluk, menisküs dokularının standartlaşmış bir modelinin bulunmamasıdır. Bu durum, tüm görüntüler için ortak bir yöntem sunmayı oldukça zor bir duruma sokmaktadır.

Diz eklemi gibi düşük çözünürlükteki medikal görüntülerle işlem yaparken görüntülerin en baştan iyi analiz edilmesi ve gürültü giderimi, hafızanın kapasitesinin tespiti gibi işlemlerin önceden çok iyi hesap edilmesi sürecin ilerleyen kısımlarında zorluklarla karşılaşılmasını engelleyecek faydalı bir işlemdir. Ayrıca süreci başlatmadan önce tıpkı bir radyoloji uzmanı gibi MR görüntülerindeki kesitlerin tek tek detaylı bir şekilde analiz edilmesi, görüntülerdeki anatomik yapıların değerlendirilmesi de bilgisayar destekli otomatik yaklaşımların oluşturulmasında çok faydalı olacaktır. Yine güçlü bir donanımlara sahip bilgisayarlarla çalışmakta işleri oldukça kolaylaştıracaktır.

KAYNAKLAR

- [1] Nevitt, M. Felson, D. ve Lester, G., (2009 <http://oai.epi-ucsf.org/datarelease/docs/StudyDesignProtocol.pdf>). The osteoarthritis initiative, ed. Protocol for the Cohort Study.
- [2] Corso, J.J. Sharon, E. Dube, S. El-Saden, S. Sinha, U. ve Yuille, A., (2008). "Efficient Multilevel Brain Tumor Segmentation With Integrated Bayesian Model Classification", IEEE Transactions on Medical Imaging, 27: 629-640.
- [3] Havaei, M. Davy, A. Warde-Farley, D. Biard, A. Courville, A. Bengio, Y. Pal, C. Jodoin, P.-M. ve Larochelle, H., (2017). "Brain tumor segmentation with Deep Neural Networks", Medical Image Analysis, 35: 18-31.
- [4] Khotanlou, H. Colliot, O. Atif, J. ve Bloch, I., (2009). "3D brain tumor segmentation in MRI using fuzzy classification, symmetry analysis and spatially constrained deformable models", Fuzzy Sets and Systems, 160: 1457-1473.
- [5] Menze, B.H. van Leemput, K. Lashkari, D. Weber, M.-A. Ayache, N. ve Golland, P., (2010). A Generative Model for Brain Tumor Segmentation in Multi-Modal Images, T. Jiang Navab, N. Pluim, J.P.W. ve Viergever, M.A., ed. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2010: 13th International Conference, Beijing, China, September 20-24, 2010, Proceedings, Part II. Berlin, Heidelberg: Springer Berlin Heidelberg, 151-159.
- [6] Pereira, S. Pinto, A. Alves, V. ve Silva, C.A., (2016). "Brain Tumor Segmentation Using Convolutional Neural Networks in MRI Images", IEEE Transactions on Medical Imaging, 35: 1240-1251.
- [7] Prastawa, M. Bullitt, E. Ho, S. ve Gerig, G., (2004). "A brain tumor segmentation framework based on outlier detection", Medical Image Analysis, 8: 275-283.
- [8] Prastawa, M. Bullitt, E. Moon, N. Van Leemput, K. ve Gerig, G., (2003). "Automatic brain tumor segmentation by subject specific modification of atlas priors1", Academic Radiology, 10: 1341-1348.
- [9] Sehgal, A. Goel, S. Mangipudi, P. Mehra, A. ve Tyagi, D., (2016). "Automatic brain tumor segmentation and extraction in MR images".
- [10] Bernardi, D. Macaskill, P. Pellegrini, M. Valentini, M. Fantò, C. Ostillo, L. Tuttobene, P. Luparia, A. ve Houssami, N., (2016). "Breast cancer screening with

- tomosynthesis (3D mammography) with acquired or synthetic 2D mammography compared with 2D mammography alone (STORM-2): a population-based prospective study", *The Lancet Oncology*, 17: 1105-1113.
- [11] Gur, D. Sumkin, J.H. Rockette, H.E. Ganott, M. Hakim, C. Hardesty, L. Poller, W.R. Shah, R. ve Wallace, L., (2004). "Changes in Breast Cancer Detection and Mammography Recall Rates After the Introduction of a Computer-Aided Detection System", *JNCI: Journal of the National Cancer Institute*, 96: 185-190.
 - [12] Houssami, N. Bernardi, D. Pellegrini, M. Valentini, M. Fantò, C. Ostillio, L. Tuttobene, P. Luparia, A. ve Macaskill, P., (2017). "Breast cancer detection using single-reading of breast tomosynthesis (3D-mammography) compared to double-reading of 2D-mammography: Evidence from a population-based trial", *Cancer Epidemiology*, 47: 94-99.
 - [13] Krammer, J. Pinker-Domenig, K. Robson, M.E. Gönen, M. Bernard-Davila, B. Morris, E.A. Mangino, D.A. ve Jochelson, M.S., (2017). "Breast cancer detection and tumor characteristics in BRCA1 and BRCA2 mutation carriers", *Breast cancer research and treatment*: 1-7.
 - [14] Kriege, M. Brekelmans, C.T. Boetes, C. Besnard, P.E. Zonderland, H.M. Obdeijn, I.M. Manoliu, R.A. Kok, T. Peterse, H. ve Tilanus-Linthorst, M.M., (2004). "Efficacy of MRI and mammography for breast-cancer screening in women with a familial or genetic predisposition", *New England Journal of Medicine*, 351: 427-437.
 - [15] Tabár, L. Gad, A. Holmberg, L.H. Ljungquist, U. Fagerberg, C.J.G. Baldetorp, L. Gröntoft, O. Lundström, B. Månson, J.C. Eklund, G. Day, N.E. ve Pettersson, F., (1985). "REDUCTION IN MORTALITY FROM BREAST CANCER AFTER MASS SCREENING WITH MAMMOGRAPHY", *The Lancet*, 325: 829-832.
 - [16] Kim, C. Yoon, J. ve Lee, Y.-J., (2016). "Medical Image Segmentation by More Sensitive Adaptive Thresholding": IEEE.
 - [17] Li, Y. Bai, X. Jiao, L. ve Xue, Y., (2017). "Partitioned-cooperative quantum-behaved particle swarm optimization based on multilevel thresholding applied to medical image segmentation", *Applied Soft Computing*, 56: 345-356.
 - [18] Lim, Y.W. ve Lee, S.U., (1990). "On the color image segmentation algorithm based on the thresholding and the fuzzy c-means techniques", *Pattern recognition*, 23: 935-952.
 - [19] Polakowski, W.E. Cournoyer, D.A. Rogers, S.K. DeSimio, M.P. Ruck, D.W. Hoffmeister, J.W. ve Raines, R.A., (1997). "Computer-aided breast cancer detection and diagnosis of masses using difference of Gaussians and derivative-based feature saliency", *IEEE Transactions on Medical Imaging*, 16: 811-819.
 - [20] Yadav, A.K. Roy, R. ve Somwanshi, D., (2016). "Thresholding and morphological based segmentation techniques for medical images": IEEE.
 - [21] Duan, H.-H. Gong, J. ve Nie, S.-D., (2016). "Two-pass region growing combined morphology algorithm for segmenting airway tree from CT chest scans": IEEE.

- [22] Hojjatoleslami, S. ve Kittler, J., (1998). "Region growing: a new approach", IEEE Transactions on Image processing, 7: 1079-1084.
- [23] Pan, Z. ve Lu, J., (2007). "A Bayes-based region-growing algorithm for medical image segmentation", Computing in Science & Engineering, 9: 32-38.
- [24] Pohle, R. ve Toennies, K.D., (2001). "Segmentation of medical images using adaptive region growing".
- [25] Pourghassem, H. ve Ghassemian, H., (2008). "Content-based medical image classification using a new hierarchical merging scheme", Computerized Medical Imaging and Graphics, 32: 651-661.
- [26] Tallapragada, V.S. Reddy, D.M. Kiran, P.S. ve Reddy, D.V., (2016). "A Novel Medical Image Segmentation and Classification using Combined Feature Set and Decision Tree Classifier", International Journal of Research in Engineering and Technology, 4: 83-86.
- [27] Wells, W.M. Grimson, W.E.L. Kikinis, R. ve Jolesz, F.A., (1996). "Adaptive segmentation of MRI data", IEEE Transactions on Medical Imaging, 15: 429-442.
- [28] Chuang, K.-S. Tzeng, H.-L. Chen, S. Wu, J. ve Chen, T.-J., (2006). "Fuzzy c-means clustering with spatial information for image segmentation", Computerized Medical Imaging and Graphics, 30: 9-15.
- [29] Ng, H. Ong, S. Foong, K. Goh, P. ve Nowinski, W., (2006). "Medical image segmentation using k-means clustering and improved watershed algorithm": IEEE.
- [30] Tuan, T.M., (2016). "A cooperative semi-supervised fuzzy clustering framework for dental X-ray image segmentation", Expert Systems with Applications, 46: 380-393.
- [31] Dong, X. Shen, J. Shao, L. ve Van Gool, L., (2016). "Sub-Markov random walk for image segmentation", IEEE Transactions on Image processing, 25: 516-527.
- [32] Held, K. Kops, E.R. Krause, B.J. Wells, W.M. Kikinis, R. ve Muller-Gartner, H.-W., (1997). "Markov random field segmentation of brain MR images", IEEE Transactions on Medical Imaging, 16: 878-886.
- [33] Li, H.-D. Kallergi, M. Clarke, L.P. Jain, V.K. ve Clark, R.A., (1995). "Markov random field for tumor detection in digital mammography", IEEE Transactions on Medical Imaging, 14: 565-576.
- [34] Ward, P.G. Ferris, N.J. Raniga, P. Ng, A.C. Barnes, D.G. Dowe, D.L. ve Egan, G.F., (2017). "Vein segmentation using shape-based Markov Random Fields": IEEE.
- [35] Zhang, Y. Brady, M. ve Smith, S., (2001). "Segmentation of brain MR images through a hidden Markov random field model and the expectation-maximization algorithm", IEEE Transactions on Medical Imaging, 20: 45-57.
- [36] Jiang, J. Trundle, P. ve Ren, J., (2010). "Medical image analysis with artificial neural networks", Computerized Medical Imaging and Graphics, 34: 617-631.

- [37] Reddick, W.E. Glass, J.O. Cook, E.N. Elkin, T.D. ve Deaton, R.J., (1997). "Automated segmentation and classification of multispectral magnetic resonance images of brain using artificial neural networks", *IEEE Transactions on Medical Imaging*, 16: 911-918.
- [38] Roth, H.R. Lu, L. Liu, J. Yao, J. Seff, A. Cherry, K. Kim, L. ve Summers, R.M., (2016). "Improving computer-aided detection using convolutional neural networks and random view aggregation", *IEEE Transactions on Medical Imaging*, 35: 1170-1181.
- [39] Avendi, M. Kheradvar, A. ve Jafarkhani, H., (2016). "A combined deep-learning and deformable-model approach to fully automatic segmentation of the left ventricle in cardiac MRI", *Medical Image Analysis*, 30: 108-119.
- [40] Heimann, T. ve Meinzer, H.-P., (2009). "Statistical shape models for 3D medical image segmentation: a review", *Medical Image Analysis*, 13: 543-563.
- [41] McInerney, T. ve Terzopoulos, D., (1996). "Deformable models in medical image analysis: a survey", *Medical Image Analysis*, 1: 91-108.
- [42] Phellan, R. Falcão, A.X. ve Udupa, J.K., (2016). "Medical image segmentation via atlases and fuzzy object models: Improving efficacy through optimum object search and fewer models", *Medical physics*, 43: 401-410.
- [43] Weese, J. Kaus, M. Lorenz, C. Lobregt, S. Truyen, R. ve Pekar, V., (2001). "Shape constrained deformable models for 3D medical image segmentation": Springer.
- [44] Akselrod-Ballin, A. Galun, M. Gomori, M.J. Basri, R. ve Brandt, A., (2006). "Atlas guided identification of brain structures by combining 3D segmentation and SVM classification": Springer.
- [45] Artaechevarria, X. Munoz-Barrutia, A. ve Ortiz-de-Solórzano, C., (2009). "Combination strategies in multi-atlas image segmentation: Application to brain MR data", *IEEE Transactions on Medical Imaging*, 28: 1266-1277.
- [46] Karasawa, K.i. Oda, M. Kitasaka, T. Misawa, K. Fujiwara, M. Chu, C. Zheng, G. Rueckert, D. ve Mori, K., (2017). "Multi-atlas pancreas segmentation: Atlas selection based on vessel structure", *Medical Image Analysis*, 39: 18-28.
- [47] Hinton, G. Deng, L. Yu, D. Dahl, G.E. Mohamed, A.-r. Jaitly, N. Senior, A. Vanhoucke, V. Nguyen, P. ve Sainath, T.N., (2012). "Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups", *IEEE Signal Processing Magazine*, 29: 82-97.
- [48] Lawrence, S. Giles, C.L. Tsoi, A.C. ve Back, A.D., (1997). "Face recognition: A convolutional neural-network approach", *IEEE transactions on neural networks*, 8: 98-113.
- [49] MIT, "MIT Technology Review", <https://www.technologyreview.com/>, 25 Kasım 2017.
- [50] Prasoon, A. Petersen, K. Igel, C. Lauze, F. Dam, E. ve Nielsen, M., (2013). "Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network": Springer.

- [51] Liu, F. Zhou, Z. Jang, H. Samsonov, A. Zhao, G. ve Kijowski, R., (2017). "Deep convolutional neural network and 3D deformable approach for tissue segmentation in musculoskeletal magnetic resonance imaging", *Magnetic Resonance in Medicine*.
- [52] Heimann, T. Morrison, B. Warfield, S. Styner, M. ve Niethammer, M., "Segmentation of Knee Images 2010", <http://www.ski10.org/>, 25 Kasım 2017.
- [53] Aldrin, F., (2017). Automated Segmentation of the Meniscus, Master Thesis, ed^eds. STOCKHOLM, SVERIGE.
- [54] Dice, L.R., (1945). "Measures of the amount of ecologic association between species", *Ecology*, 26: 297-302.
- [55] Seim, H. Kainmueller, D. Lamecker, H. Bindernagel, M. Malinowski, J. ve Zachow, S., (2010). "Model-based auto-segmentation of knee bones and cartilage in MRI data", *Medical Image Analysis for the Clinic: A Grand Challenge*, Beijing.
- [56] Yang, Z. Fripp, J. Chandra, S.S. Neubert, A. Xia, Y. Strudwick, M. Paproki, A. Engstrom, C. ve Crozier, S., (2015). "Automatic bone segmentation and bone-cartilage interface extraction for the shoulder joint from magnetic resonance images", *Physics in medicine and biology*, 60: 1441.
- [57] Lorigo, L. Faugeras, O. Grimson, W. Keriven, R. ve Kikinis, R., (1998). "Segmentation of bone in clinical knee MRI using texture-based geodesic active contours", *Medical Image Computing and Computer-Assisted Intervention—MICCAI'98*: 1195-1204.
- [58] Schmid, J. ve Magnenat-Thalmann, N., (2008). "MRI bone segmentation using deformable models and shape priors": Springer.
- [59] Cheong, J. Suter, D. ve Cicuttini, F., (2005). "Development of semi-automatic segmentation methods for measuring tibial cartilage volume": IEEE.
- [60] Dama, E.B. Folkesson, J. Pettersen, P.C. ve Christiansen, C., (2006). "Semi-automatic knee cartilage segmentation".
- [61] Bui, T. Ahn, C. Lee, Y.-w. ve Shin, J., (2014). "Fully automatic segmentation based on localizing active contour method": ACM.
- [62] Folkesson, J. Dam, E.B. Olsen, O.F. Pettersen, P.C. ve Christiansen, C., (2007). "Segmenting articular cartilage automatically using a voxel classification approach", *IEEE Transactions on Medical Imaging*, 26: 106-115.
- [63] Fripp, J. Crozier, S. Warfield, S.K. ve Ourselin, S., (2010). "Automatic segmentation and quantitative analysis of the articular cartilages from magnetic resonance images of the knee", *IEEE Transactions on Medical Imaging*, 29: 55-64.
- [64] Öztürk, C.N. ve Albayrak, S., (2016). "Automatic segmentation of cartilage in high-field magnetic resonance images of the knee joint with an improved voxel-classification-driven region-growing algorithm using vicinity-correlated subsampling", *Computers in biology and medicine*, 72: 90-107.

- [65] Shan, L. Zach, C. Charles, C. ve Niethammer, M., (2014). "Automatic atlas-based three-label cartilage segmentation from MR knee images", *Medical Image Analysis*, 18: 1233-1246.
- [66] Dam, E.B. Lillholm, M. Marques, J. ve Nielsen, M., (2015). "Automatic segmentation of high-and low-field knee MRIs using knee image quantification with data from the osteoarthritis initiative", *Journal of Medical imaging*, 2: 024001-024001.
- [67] Fripp, J. Bourgeat, P. Engstrom, C. Ourselin, S. Crozier, S. ve Salvado, O., (2009). "Automated segmentation of the menisci from MR images": IEEE.
- [68] Paproki, A. Engstrom, C. Chandra, S.S. Neubert, A. Fripp, J. ve Crozier, S., (2014). "Automated segmentation and analysis of normal and osteoarthritic knee menisci from magnetic resonance images—data from the Osteoarthritis Initiative", *Osteoarthritis and Cartilage*, 22: 1259-1270.
- [69] Swanson, M. Prescott, J. Best, T. Powell, K. Jackson, R. Haq, F. ve Gurcan, M., (2010). "Semi-automated segmentation to assess the lateral meniscus in normal and osteoarthritic knees", *Osteoarthritis and Cartilage*, 18: 344-353.
- [70] Zhang, K. Lu, W. ve Marziliano, P., (2013). "The unified extreme learning machines and discriminative random fields for automatic knee cartilage and meniscus segmentation from multi-contrast MR images", *Machine vision and applications*, 24: 1459-1472.
- [71] Kim, M.-J. Yoo, J.-H. ve Hong, H., (2010). "Automatic Segmentation of the meniscus based on Active Shape Model in MR Images through Interpolated Shape Information", *Journal of KIISE: Computing Practices and Letters*, 16: 1096-1100.
- [72] Saki, T. Hataa, Y. Andob, Y. Ishikawa, M. ve Ishikawac, H., (1999). "Fuzzy rule based approach to segment the menisci region from MR images".
- [73] Yin, Y. Anderson, D. Williams, R. ve Sonka, M., (2011). "Fully Automated, Fast, and Robust Segmentation of the Meniscus from MR Images", Long Beach, CA, United States.
- [74] Nedmark, F., (2004). *Automatic Segmentation of Menisci in MR Images Using Pattern Recognition and Graph Cuts*, ed[^]eds. Dept. of Mathematics. Lund Institute of Technology.
- [75] Kohut, P. Holak, K. ve Obuchowicz, R., (2017). "Image processing in detection of knee joints injuries based on MRI images", *Journal of Vibroengineering*, 19.
- [76] Hata, Y. Kobashi, S. Tokimoto, Y. Ishikawa, M. ve Ishikawa, H., (2001). "Computer aided diagnosis system of meniscal tears with T1 and T2 weighted MR images based on fuzzy inference", *Lecture notes in computer science*: 55-58.
- [77] Boniatis, I. Panayiotakis, G. ve Panagiotopoulos, E., (2008). "A computer-based system for the discrimination between normal and degenerated menisci from magnetic resonance images": IEEE.

- [78] Köse, C. Gençalioglu, O. ve Şevik, U., (2009). "An automatic diagnosis method for the knee meniscus tears in MR images", Expert Systems with Applications, 36: 1208-1216.
- [79] Ramakrishna, B. Liu, W. Saiprasad, G. Safdar, N. Chang, C.-I. Siddiqui, K. Kim, W. Siegel, E. Chai, J.-W. ve Chen, C.C.-C., (2009). "An automatic computer-aided detection system for meniscal tears on magnetic resonance images", IEEE Transactions on Medical Imaging, 28: 1308-1316.
- [80] Swamy, M.M. ve Holi, M., (2012). "Knee joint menisci visualization and detection of tears by image processing": IEEE.
- [81] Fu, J.-C. Lin, C.-C. Wang, C.-N. ve Ou, Y.-K., (2013). "Computer-aided diagnosis for knee meniscus tears in magnetic resonance imaging", Journal of Industrial and Production Engineering, 30: 67-77.
- [82] Patel, J. Modi, H. ve Patel, H., (2016). "Measurement of Cartilage Thickness in Osteoarthritis and Visualization of Meniscus Tear of Knee MRI Image Processing", International Journal of Computer Science and Mobile Computing, 5: 39-52.
- [83] Zarandi, M.F. Khadangi, A. Karimi, F. ve Turksen, I., (2016). "A Computer-Aided Type-II Fuzzy Image Processing for Diagnosis of Meniscus Tear", Journal of digital imaging, 29: 677-695.
- [84] Bloecker, K. Guermazi, A. Wirth, W. Kwok, C.K. Resch, H. Hunter, D.J. ve Eckstein, F., (2014). "Correlation of semiquantitative vs quantitative MRI meniscus measures in osteoarthritic knees: results from the Osteoarthritis Initiative", Skeletal Radiology, 43: 227-232.
- [85] Taylor, T., "Knee Joint", <http://www.innerbody.com/image/skel16.html#full-description>., 07 Haziran 2017.
- [86] Uysal, Ö., "Ön çapraz Bağ Yaralanmaları", http://www.drozguruysal.com/?page_id=2958., 5 Mart 2016.
- [87] Schmidler, C., "Knee Joint Anatomy, Function and Problems", <https://www.healthpages.org/anatomy-function/knee-joint-structure-function-problems/>., 07 Haziran 2017.
- [88] Mysid, H., (2017). "Diz Eklemini Oluşturan Yapılar", <http://www.wikizero.org/index.php?q=aHR0cHM6Ly90ci53aWtpcGVkaWEub3JnL3dpa2kvRG9zeWE6S25lZV9kaWFncmFtX3RyLnN2ZWw>., 20.11.2017.
- [89] Hoffman, M., "Picture of the Knee, Human Anatomy", <http://www.webmd.com/pain-management/knee-pain/picture-of-the-knee#1>., 01 Mayıs 2017.
- [90] Ltd., W.H., "Knee Joint Anatomy", <http://www.knee-pain-explained.com/knee-joint-anatomy.html>., 03 Mayıs 2017.
- [91] Meyler, Z., "Knee Anatomy", <https://www.arthritis-health.com/types/joint-anatomy/knee-anatomy>., 15 Mayıs 2017.
- [92] Ghosh, P. ve Taylor, T.K., (1987). "The Knee Joint Meniscus: A Fibrocartilage of Some Distinction", Clinical orthopaedics and related research, 224: 52-63.

- [93] Seedhom, B. Dowson, D. ve Wright, V., (1974). "Proceedings: Functions of the menisci. A preliminary study", Annals of the rheumatic diseases, 33: 111.
- [94] De Smet, A.A. Norris, M. Yandow, D. Quintana, F. Graf, B. ve Keene, J., (1993). "MR diagnosis of meniscal tears of the knee: importance of high signal in the meniscus that extends to the surface", AJR. American journal of roentgenology, 161: 101-107.
- [95] Foundation, A., "What is Osteoarthritis ?", <http://www.arthritis.org/about-arthritis/types/osteoarthritis/what-is-osteoarthritis.php>., 17 Mayıs 2017.
- [96] UK, A.R., "Osteoarthritis of the knee", <https://www.arthritisresearchuk.org/>., 15 Mayıs 2017.
- [97] Stoller, D.W. Martin, C. Crues 3rd, J. Kaplan, L. ve Mink, J.H., (1987). "Meniscal tears: pathologic correlation with MR imaging", Radiology, 163: 731-735.
- [98] Crues 3rd, J. Mink, J. Levy, T. Lotysch, M. ve Stoller, D., (1987). "Meniscal tears of the knee: accuracy of MR imaging", Radiology, 164: 445-448.
- [99] Crues, J.V. ve Stoller, D.W., (1993). "The menisci", MRI of the Knee, 2: 91-140.
- [100] Lefevre, N. Naouri, J.F. Herman, S. Gerometta, A. Klouche, S. ve Bohu, Y., (2016). "A current review of the meniscus imaging: proposition of a useful tool for its radiologic analysis", Radiology research and practice, 2016.
- [101] WebMD, "Knee Injury and Meniscus Tear", <http://www.webmd.com/fitness-exercise/tc/meniscus-tear-topic-overview#1>., 16 Mayıs 2017.
- [102] Surgeons, A.A.o.O., "Meniscus Tears", <http://orthoinfo.aaos.org/topic.cfm?topic=a00358>., 20 Aralık 2016.
- [103] Gökay, S., "Menisküs Zedelenmeleri", www.selimgokay.com/files/doc/meniskus.pdf., 15 Mayıs 2017.
- [104] Hansen, J.T., (2014). Netter's Clinical Anatomy E-Book: Elsevier Health Sciences.
- [105] Birkfellner, W., (2015). Applied medical image processing: a basic course: CRC Press.
- [106] Sclerosis, I.o.M., "Basic Plane Mathematics of MRI", https://my-ms.org/mri_planes.htm., 15 Mayıs 2017.
- [107] Demirkaya, O. Asyali, M.H. ve Sahoo, P.K., (2008). Image processing with MATLAB: applications in medicine and biology: CRC Press.
- [108] Liang, Z.-P. ve Lauterbur, P.C., (2000). Principles of magnetic resonance imaging: a signal processing perspective: SPIE Optical Engineering Press.
- [109] Prince, J.L. ve Links, J.M., (2006). Medical imaging signals and systems: Pearson Prentice Hall Upper Saddle River, New Jersey.
- [110] Derneği, T.R., "Manyetik Rezonans", http://www.tumrad.net/FileUpload/ds58732/File/manyetik_rezonans_goruntu_leme_mrg.pdf., 01.12.2017.

- [111] Moriya, S. Miki, Y. Yokobayashi, T. ve Ishikawa, M., (2009). "Three-dimensional double-echo steady-state (3D-DESS) magnetic resonance imaging of the knee: contrast optimization by adjusting flip angle", *Acta Radiologica*, 50: 507-511.
- [112] Beaufils, P. ve Verdonk, R., (2010). *The meniscus*: Springer Science & Business Media.
- [113] Khanna, A.J. Cosgarea, A.J. Mont, M.A. Andres, B.M. Domb, B.G. Evans, P.J. Bluemke, D.A. ve Frassica, F.J., (2001). "Magnetic resonance imaging of the knee: Current techniques and spectrum of disease", *JBJS*, 83: S128-141.
- [114] Morrison, W.A., "Knee MRI Scan", <http://www.healthline.com/health/knee-mri-scan#overview1>, 15 Haziran 2017.
- [115] Niitsu, M., (2012). *Magnetic resonance imaging of the knee*: Springer Science & Business Media.
- [116] RadiologyInfo, "Magnetic Resonance Imaging (MRI)- Knee", <https://www.radiologyinfo.org/en/info.cfm?pg=kneemr>, 15 Haziran 2017.
- [117] Eckstein, F. Cicuttini, F. Raynauld, J.-P. Waterton, J. ve Peterfy, C., (2006). "Magnetic resonance imaging (MRI) of articular cartilage in knee osteoarthritis (OA): morphological assessment", *Osteoarthritis and Cartilage*, 14: 46-75.
- [118] Tarhan, N.C. Chung, C.B. Mohana-Borges, A.V.R. Hughes, T. ve Resnick, D., (2004). "Meniscal tears: role of axial MRI alone and in combination with other imaging planes", *American Journal of Roentgenology*, 183: 9-15.
- [119] Philip, T., "Knee MRI Sequences", http://www.freitasrad.net/pages/Basic_MSK_MRI/Knee.htm#, 02.12.2017.
- [120] Jah, A.E. Keyhani, S. Zarei, R. ve Moghaddam, A.K., (2005). "Accuracy of MRI in comparison with clinical and arthroscopic findings in ligamentous and meniscal injuries of the knee", *Acta Orthop Belg*, 71: 189-196.
- [121] Us, A.K., "Diz Menisküs Yaralanmaları", <http://www.artroskopi.us/dizmeniskusyaralanma.htm>, 22 ağustos 2016.
- [122] Tandoğan, R. ve Kayaalp, A., "Menisküs Yırtıklarında Tedavi Seçenekleri", <http://www.ortoklinik.com/hastalar-icin/meniskus-yirtiklari>, 22 Ağustos 2015.
- [123] Ordu, S. Bayram, E. Çetinus, E. Kaya, İ. ve Yılmaz, M., "Elli Yaş Altındaki Hastalarda Menisküs Yırtık Tiplerinin Ön Çapraz Bağ ve Osteokondral Lezyonlarla İlişkisi", *Haseki Tıp Bülteni*, 52: 177–180.
- [124] Kellgren, J.H. ve Lawrence, J.S., (1957). "Radiological Assessment of Osteo-Arthrosis", *Annals of the rheumatic diseases*, 16: 494-502.
- [125] Dalal, N. ve Triggs, B., (2005). "Histograms of oriented gradients for human detection".
- [126] Ojala, T. Pietikäinen, M. ve Harwood, D., (1996). "A comparative study of texture measures with classification based on featured distributions", *Pattern recognition*, 29: 51-59.

- [127] Ojala, T. Pietikainen, M. ve Harwood, D., (1994). "Performance evaluation of texture measures with classification based on Kullback discrimination of distributions": IEEE.
- [128] Rastgoo, M. Garcia, R. Morel, O. ve Marzani, F., (2015). "Automatic differentiation of melanoma from dysplastic nevi", *Computerized Medical Imaging and Graphics*, 43: 44-52.
- [129] Agarwal, D. Shriram, K.S. ve Subramanian, N., (2013). "Automatic view classification of echocardiograms using Histogram of Oriented Gradients".
- [130] Oppedal, K. Eftestøl, T. Engan, K. Beyer, M.K. ve Aarsland, D., (2015). "Classifying dementia using local binary patterns from different regions in magnetic resonance images", *Journal of Biomedical Imaging*, 2015: 5.
- [131] Nanni, L. ve Lumini, A., (2008). "Local binary patterns for a hybrid fingerprint matcher", *Pattern recognition*, 41: 3461-3466.
- [132] Gottschlich, C. Marasco, E. Yang, A.Y. ve Cukic, B., (2014). "Fingerprint liveness detection based on histograms of invariant gradients".
- [133] Wang, X. Han, T.X. ve Yan, S., (2009). "An HOG-LBP human detector with partial occlusion handling": IEEE.
- [134] Felzenszwalb, P.F. Girshick, R.B. McAllester, D. ve Ramanan, D., (2010). "Object detection with discriminatively trained part-based models", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32: 1627-1645.
- [135] Rahim, M.A. Azam, M.S. Hossain, N. ve Islam, M.R., (2013). "Face recognition using local binary patterns (LBP)", *Global Journal of Computer Science and Technology*.
- [136] Ahonen, T. Hadid, A. ve Pietikainen, M., (2006). "Face description with local binary patterns: Application to face recognition", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28: 2037-2041.
- [137] Liu, C. ve Wechsler, H., (2002). "Gabor feature based classification using the enhanced fisher linear discriminant model for face recognition", *IEEE Transactions on Image processing*, 11: 467-476.
- [138] Gabor, D., (1946). "Theory of communication. Part 1: The analysis of information", *Journal of the Institution of Electrical Engineers-Part III: Radio and Communication Engineering*, 93: 429-441.
- [139] Zhang, F. Song, Y. Cai, W. Lee, M.-Z. Zhou, Y. Huang, H. Shan, S. Fulham, M.J. ve Feng, D.D., (2014). "Lung nodule classification with multilevel patch-based context analysis", *IEEE Transactions on Biomedical Engineering*, 61: 1155-1166.
- [140] Bay, H. Tuytelaars, T. ve Van Gool, L., (2006). "Surf: Speeded up robust features", *Computer vision—ECCV 2006*: 404-417.
- [141] Haralick, R.M. ve Shanmugam, K., (1973). "Textural features for image classification", *IEEE Transactions on systems, man, and cybernetics*: 610-621.

- [142] Tan, X. ve Triggs, B., (2010). "Enhanced local texture feature sets for face recognition under difficult lighting conditions", *IEEE Transactions on Image processing*, 19: 1635-1650.
- [143] Tan, X. ve Triggs, B., (2007). "Fusing Gabor and LBP feature sets for kernel-based face recognition": Springer.
- [144] Conde, C. Moctezuma, D. De Diego, I.M. ve Cabello, E., (2013). "HoGG: Gabor and HoG-based human detection for surveillance in non-controlled environments", *Neurocomputing*, 100: 19-30.
- [145] Vedaldi, A. ve Fulkerson, B., (2010). Vlfeat: an open and portable library of computer vision algorithms, eds. *Proceedings of the 18th ACM international conference on Multimedia*. Firenze, Italy: ACM, 1469-1472.
- [146] Lowe, D.G., (1999). "Object recognition from local scale-invariant features": IEEE.
- [147] Ojala, T. Pietikäinen, M. ve Mäenpää, T., (2000). Gray Scale and Rotation Invariant Texture Classification with Local Binary Patterns, ed. *Computer Vision - ECCV 2000: 6th European Conference on Computer Vision Dublin, Ireland, June 26 – July 1, 2000 Proceedings, Part I*. Berlin, Heidelberg: Springer Berlin Heidelberg, 404-420.
- [148] Huang, D. Shan, C. Ardabilian, M. Wang, Y. ve Chen, L., (2011). "Local binary patterns and its application to facial image analysis: a survey", *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 41: 765-781.
- [149] Pietikäinen, M. Hadid, A. Zhao, G. ve Ahonen, T., (2011). Local binary patterns for still images, ed. *Computer vision using local binary patterns*. Springer, 13-47.
- [150] Ojala, T. Pietikainen, M. ve Maenpaa, T., (2002). "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24: 971-987.
- [151] Pearson, K., (1901). "LIII. On lines and planes of closest fit to systems of points in space", *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 2: 559-572.
- [152] Jolliffe, I.T., (1986). *Principal Component Analysis and Factor Analysis*, ed. *Principal component analysis*. Springer, 115-128.
- [153] Huang, G.-B. Zhu, Q.-Y. ve Siew, C.-K., (2006). "Extreme learning machine: Theory and applications", *Neurocomputing*, 70: 489-501.
- [154] Huang, G.-B. Zhu, Q.-Y. ve Siew, C.-K., (2004). "Extreme learning machine: a new learning scheme of feedforward neural networks": IEEE.
- [155] Huang, G.-B. Zhou, H. Ding, X. ve Zhang, R., (2012). "Extreme learning machine for regression and multiclass classification", *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42: 513-529.
- [156] Breiman, L., (2001). "Random Forests", *Machine Learning*, 45: 5-32.
- [157] Ho, T.K., (1995). "Random decision forests": IEEE.

- [158] Ho, T.K., (1998). "The random subspace method for constructing decision forests", IEEE Transactions on Pattern Analysis and Machine Intelligence, 20: 832-844.
- [159] Otsu, N., (1979). "A threshold selection method from gray-level histograms", IEEE Transactions on systems, man, and cybernetics, 9: 62-66.
- [160] De Smet, A.A. Norris, M.A. Yandow, D.R. Quintana, F.A. Graf, B.K. ve Keene, J.S., (1993). "MR diagnosis of meniscal tears of the knee: importance of high signal in the meniscus that extends to the surface", American Journal of Roentgenology, 161: 101-107.
- [161] Rauscher, I. Stahl, R. Cheng, J. Li, X. Huber, M.B. Luke, A. Majumdar, S. ve Link, T.M., (2008). "Meniscal Measurements of T1 ρ and T2 at MR Imaging in Healthy Subjects and Patients with Osteoarthritis", Radiology, 249: 591-600.
- [162] Bowers, M.E. Tung, G.A. Fleming, B.C. Crisco, J.J. ve Rey, J., (2007). "QUANTIFICATION OF MENISCAL VOLUME BY SEGMENTATION OF 3T MAGNETIC RESONANCE IMAGES", Journal of biomechanics, 40: 2811-2815.
- [163] Englund, M. Guermazi, A. Gale, D. Hunter, D.J. Aliabadi, P. Clancy, M. ve Felson, D.T., (2008). "Incidental meniscal findings on knee MRI in middle-aged and elderly persons", New England Journal of Medicine, 359: 1108-1115.
- [164] Berthiaume, M.-J. Raynauld, J.-P. Martel-Pelletier, J. Labonté, F. Beaudoin, G. Bloch, D.A. Choquette, D. Haraoui, B. Altman, R.D. Hochberg, M. Meyer, J.M. Cline, G.A. ve Pelletier, J.-P., (2005). "Meniscal tear and extrusion are strongly associated with progression of symptomatic knee osteoarthritis as assessed by quantitative magnetic resonance imaging", Annals of the rheumatic diseases, 64: 556-563.
- [165] Hunter, D.J. Zhang, Y.Q. Niu, J.B. Tu, X. Amin, S. Clancy, M. Guermazi, A. Grigorian, M. Gale, D. ve Felson, D.T., (2006). "The association of meniscal pathologic changes with cartilage loss in symptomatic knee osteoarthritis", Arthritis & Rheumatism, 54: 795-801.
- [166] Hunter, D.J. Guermazi, A. Lo, G.H. Grainger, A.J. Conaghan, P.G. Boudreau, R.M. ve Roemer, F.W., (2011). "Evolution of semi-quantitative whole joint assessment of knee OA: MOAKS (MRI Osteoarthritis Knee Score)", Osteoarthritis and Cartilage, 19: 990-1002.
- [167] Bezdek, J.C. Ehrlich, R. ve Full, W., (1984). "FCM: The fuzzy c-means clustering algorithm", Computers & Geosciences, 10: 191-203.
- [168] Bezdek†, J.C., (1973). "Cluster Validity with Fuzzy Sets", Journal of Cybernetics, 3: 58-73.
- [169] Bezdek, J.C., (1974). "Numerical taxonomy with fuzzy sets", Journal of Mathematical Biology, 1: 57-71.
- [170] Arya, S. Mount, D.M. Netanyahu, N.S. Silverman, R. ve Wu, A.Y., (1998). "An optimal algorithm for approximate nearest neighbor searching fixed dimensions", J. ACM, 45: 891-923.

- [171] Vapnik, V., (2013). The nature of statistical learning theory: Springer science & business media.
- [172] Boser, B.E. Guyon, I.M. ve Vapnik, V.N., (1992). A training algorithm for optimal margin classifiers, eds. Proceedings of the fifth annual workshop on Computational learning theory. Pittsburgh, Pennsylvania, USA: ACM, 144-152.
- [173] Vert, J.-P. Tsuda, K. ve Schölkopf, B., (2004). "A primer on kernel methods", Kernel Methods in Computational Biology: 35-70.
- [174] Rifkin, R. ve Klautau, A., (2004). "In defense of one-vs-all classification", Journal of machine learning research, 5: 101-141.
- [175] Weston, J. ve Watkins, C., (1999). "Support vector machines for multi-class pattern recognition".

OSTEOARTRİT GİRİŞİMİ

Bir kamu-özel ortaklığı olan Osteoartrite Girişimi dört klinik merkez ve bir veri koordinasyon merkezi tarafından OA'nın gelişimi ve ilerlemesi için biyokimyasal, genetik ve görüntüleme biyolojik belirteçlerinin bulunmasına yardımcı olma taahhüdü ile yürütülmektedir. OAI, osteoartrite için, klinik değerlendirme verilerini, radyolojik (x-ışını ve manyetik rezonans) görüntüleri ve 45-79 yaş arasındaki 4796 erkek ve kadın Şubat 2004 ile Mayıs 2006 tarihleri arasında kaydedilen veritabanını yürütmektedir. Her klinik merkezde bir adet olmak üzere dört adet 3.0 Tesla MRG tarayıcı, yıllık OAI katılımcılarının dizlerini dört yıl boyunca görüntülemek üzere kullanılmaktadır. Yedi yıllık proje, diz osteoartritesi gelişme riski yüksek olan katılımcılardan oluşmaktadır. Toplanan tüm veriler ve görüntüler, biyolojik belirteç tanımlama, bilimsel araştırmalar ve OA ilaç geliştirme aşamalarını hızlandırmaya yardımcı olmak için dünya çapındaki araştırmacılar tarafından kullanılabilir.

OAI, National Institutes of Health (NIH) sermayesiyle beş sözleşmeden (N01-AR-2-2258; N01-AR-2-2259; N01-AR-2- 2260; N01-AR-2-2261; N01-AR-2-2262) oluşan bir kamu-özel ortaklığıdır. Özel sermaye ortakları arasında Novartis şirketi, Merck Araştırma Laboratuvarları, GlaxoSmithKline ve Pfizer A.Ş. bulunmaktadır. OAI'nin kamu kullanımına açık veri setini kullanarak hazırlanan bu metin OAI araştırmacılarının, NIH'in veya özel sermaye ortaklarının fikir ya da görüşlerini yansıtmamaktadır.

A-1 Görüntü Değerlendirmeleri

Veri setinde yer alan görüntülerin içeriği aşağıdaki gibidir;

- Çalışma Planlama veritabanı için ölçme envanteri (eskiden Çalışma Planlaması için Görüntüleme Envanteri) (4.796 katılımcı) (Aralık 2016)
- Kohort alt kümesi için kemik yardımcı çalışma verileri (629 katılımcı) (Aralık 2016)
- Uzunlamasına dizi X-ışınlarının nicel eklem genişliği (başlangıç, 12 aylık, 24 aylık, 36 aylık, 48 aylık, 72 aylık, 96 aylık; 3,469 katılımcı) (Mart 2016)
- Diz röntgen ışınlarının uzunlamasına gruplarından (başlangıç, 12 aylık, 24 aylık, 36 aylık, 48 aylık, 72 aylık, 96 aylık; 4,492 katılımcıdan) yarı nicel (KL dereceli, IRF'ler) okuma verileri
- Diz X-ışınlarından nicel anatomik eksen hizalaması (femoral-tibial açısı) (başlangıç, 12 aylık, 24 aylık, 36 aylık, 48 aylık, 72 aylık, 96 aylık; 3.435 katılımcı) (Mart 2016)
- Tam ekstremiteler röntgen filmlerinden nicel diz dizilişi ve alt ekstremiteler geometrisi (12 aylık, 24 aylık, 36 aylık, 48 aylık, 1.432 katılımcı) (Mart 2016)
- Boyuna kırık ve MR görüntülerinin kemik morfolojisi (başlangıç, 12 aylık, 24 aylık; 600 katılımcı) (Haziran 2015)
- Uzunlamasına MRG setlerinden (başlangıç, 12 aylık, 24 aylık, 600 katılımcıdan) MOAKS kullanarak SQ okumaları (Haziran 2015)
- Diz MRG'lerinin uzunlamasına dizilerinden (başlangıç, 24 aylık, 48 aylık; 300 katılımcı) T2 ölçümleri (Şubat 2015)
- Boyuna diz MRG'lerinden (başlangıç, 24 ay, 48 ay; 300 katılımcının) SQ modifiye WORMS okumaları (Şubat 2015)
- Boyuna diz altı röntgen ışınlarının nicel eklem genişliği için güvenilirlik değerleri (başlangıç, 12 ay, 24 ay, 36 ay; 136 katılımcı) (Nisan 2012)
- Uzun süreli diz X-ışınlarından (başlangıç, 12 aylık, 24 aylık, 36 aylık, 48 aylık, 149 katılımcıdan) yarı nicel (K-L derece, IRF'ler) okuma için güvenilirlik değerleri (Nisan 2012)
- Boyuna kırık ve MRG'lerin kemik morfolojisi (başlangıç, 12 aylık, 24 aylık, 48 aylık; tüm kohortun alt kümesi) (Nisan 2012)

- WORMS ve BLOKS (başlangıç, 24 aylık, progresyon kohortunun alt kümesi) kullanılarak SQ tüm organ skoru (Haziran 2011)
- Elle kıkırdak bölütlemeleri (başlangıç, 12 ay; progresyon kohortunun alt kümesi) (Haziran 2011)

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Ahmet SAYGILI
Doğum Tarihi ve Yeri : 20.10.1985/Şereflikoçhisar
Yabancı Dili : İngilizce
E-posta : ahmetsygl@gmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Yüksek Lisans	Bilgisayar Mühendisliği	Yıldız Teknik Üniversitesi	2013
Lisans	Bilgisayar Mühendisliği	Çukurova Üniversitesi	2009
Lise	Fen Bilimleri	Hazım Kulak Anadolu Lisesi	2004

İş Tecrübesi

Yıl	Firma/Kurum	Görevi
2010 - Devam ediyor	Namık Kemal Üniversitesi Bilgisayar Mühendisliği Bölümü	Araştırma Görevlisi

YAYINLARI

Makale

1. Saygılı A., Albayrak S., A new computer-based approach for fully automated segmentation of knee meniscus from magnetic resonance images, Biocybernetics and Biomedical Engineering, vol. 37, pp. 432-442, 2017.
2. Uzun E., Erdoğan C., Saygılı A., Hiyerarşik kümeleme modeli kullanan web tabanlı bir ödev değerlendirme sistemi, Ejovoc, Vol. 6, 2016.

Bildiri

1. Saygılı A., Albayrak S., Meniscus segmentation and tear detection in the knee MR images by fuzzy c-means method, 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (15.05.2017-18.05.2017).
2. Saygılı A., Albayrak S., Analysis of factors affecting students success in school of engineering with data mining, International Conference on Computer Science and Engineering (20.10.2016-23.10.2016).
3. Saygılı A., Kaya H., Albayrak S., Automatic detection of meniscal area in the knee MR images, 2016 24th Signal Processing and Communication Application Conference (SIU) (16.05.2016-19.05.2016).
4. Saygılı A., Uysal G., Bilgin G., Comparative analysis of codeword representation by clustering methods for the classification of histological tissue types, Eighth International Conference on Machine Vision (ICMV 2015) (19.11.2015-21.11.2015).
5. Saygılı A., Albayrak S., Faculty of engineering students success analysis with clustering methods, 2013 21st Signal Processing and Communications Applications Conference (SIU) (24.04.2013-26.04.2013).