



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE
GELİŞİMSEL KALÇA DİSPLAZİSİ TEŞHİSİ

Kerim Kürşat ÇEVİK

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Haziran-2016
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

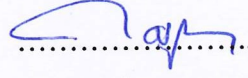
Kerim Kürşat ÇEVİK tarafından hazırlanan “Görüntü İşleme Teknikleri ile Gelişimsel Kalça Displazisi Teşhisi” adlı tez çalışması 30/06/2016 tarihinde aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Halis ALTUN



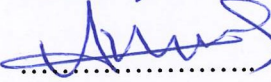
Danışman

Yrd. Doç. Dr. Hasan Erdiñç KOÇER



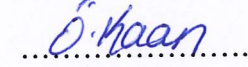
Üye

Doç. Dr. Adem Alpaslan ALTUN



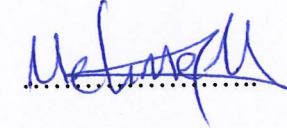
Üye

Yrd. Doç. Dr. Ömer Kaan BAYKAN

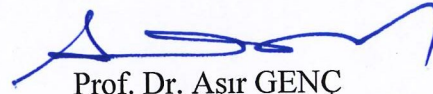


Üye

Yrd. Doç. Dr. Mehmet HACIBEYOĞLU



Yukarıdaki sonucu onaylarım.



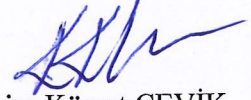
Prof. Dr. Aşır GENÇ
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.



Kerim Kürşat ÇEVİK

Tarih: 11-07-2016

ÖZET

DOKTORA TEZİ

GÖRÜNTÜ İŞLEME TEKNİKLERİ İLE GELİŞİMSEL KALÇA DİSPLAZİSİ TEŞHİSİ

Kerim Kürşat ÇEVİK

**Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Yrd. Doç. Dr. Hasan Erdinç KOÇER

2016, 144 Sayfa

Jüri

Yrd. Doç. Dr. Hasan Erdinç KOÇER

Prof. Dr. Halis ALTUN

Doç. Dr. Adem Alpaslan ALTUN

Yrd. Doç. Dr. Ömer Kaan BAYKAN

Yrd. Doç. Dr. Mehmet HACİBEYOĞLU

Gelişimsel kalça displazisi (GKD) veya halk dilinde kalça çıkığı; femur (uyluk) başı ile asetabulum (çukurluk) arasındaki uyumsuzluk sonucu meydana gelen yapısal bir bozukluktur. GKD erken tanı ile başarılı bir şekilde tedavi edilebilir. Tanıda ve tedavide gecikme, ekstremitelerde (uzuv) kısalığı, topallama ve fonksiyonel özrürlük gibi kısıtlı hareket bozukluklarına neden olabilir.

GKD'nin tıbbi açıdan kontrolü çoğunlukla bebeklik döneminde (0-3 ay) uzman doktor tarafından yapılmaktadır. Bu kontrol fiziksel muayene ve ultrason (US) çekimi sonrası kontrol olmak üzere iki farklı teknikte yapılmaktadır. Uzmanlar, fiziksel muayenede teşhis zorluğundan dolayı US görüntüleme tekniğine yönelmektedir. Bu yöntemde, US görüntüleri üzerinden uzmanın manuel olarak belirlediği referans noktalarına göre uzaklık ve açı ölçümleri yapılmakta ve teşhis konulmaktadır. Ölçümler sırasında uzmandan, görüntülemeyen ve ölçmeden kaynaklanan hatalar ortaya çıkabilmektedir. Bu sebepten dolayı bilgisayar destekli ölçüm ve teşhis sistemine ihtiyaç duyulmaktadır.

Bu çalışmada GKD hastalığının, US görüntüleri üzerinde bilgisayar yardımıyla otomatik teşhisine yönelik bir sistem gerçekleştirilmiştir. Çalışma sayesinde hastalığın erken teşhis ve dolayısıyla tedavisine katkı sağlanması amaçlanmaktadır. Ayrıca teşhis işleminde uzman hatasının en aza indirilmesi de hedeflenmiştir. Hastalığın yeni doğan ve bebeklik dönemlerinde herhangi bir anda ortaya çıkabileceği düşünüldüğünde, uygulamada oluşacak zorlukların önüne geçilmiş olunacaktır. Otomatik teşhis sistemi ile hastalığın erken teşhisi ve tedavi başarısını artırmak hedeflenmektedir.

Çalışmada ilk olarak; görüntülere yaygın olarak bilinen ve US görüntülerindeki gürültüleri azaltıp, görüntü kalitesini artıran filtreler uygulanmıştır (Ortalama, Ortanca, Perona Malik, Wiener, Gaussian, Lee ve Frost). Ardından, Aktif Kontur Model ve Dairesel Hough Dönüşümü yöntemleri kullanılarak ilium ve femur bölgelerinin tespiti yapılmıştır. Bir sonraki aşamada, GKD teşhisinde kullanılan ve literatürde kabul görmüş Graf yönteminin uygulanabilmesi için gerekli olan alfa ve beta açıları; görüntü üzerinde çeşitli morfolojik görüntü işleme algoritmaları kullanılarak belirlenmiştir (İnceltme, İskelet Çıkarım, Budama ve Dal Noktası Belirleme). Son aşamada ise, alfa ve beta açıları kullanılarak Graf yöntemi tiplendirilmesi yapılmış ve uzman bilgileri ile karşılaştırılarak sistemin başarısı ölçülmüştür. Ayrıca Graf yöntemine alternatif olarak, sistemden elde edilen alfa ve beta açıları ile bu çalışmada GKD teşhisine yeni bir yaklaşım olan temel çizgi/femur oranı özelliği değerleri yapay zekâ teknikleri kullanılarak sınıflandırma yapılmıştır. Bu yöntemden alınan sonuçlar, Graf yöntemi ile karşılaştırılmıştır.

Anahtar Kelimeler: Gelişimsel Kalça Displazisi, Ultrason, Aktif Kontur Modeli, Dairesel Hough Dönüşümü, Yapay Sinir Ağları, Bulanık Mantık

ABSTRACT

Ph.D. THESIS

DIAGNOSIS OF DEVELOPMENTAL HIP DYSPLASIA WITH IMAGE PROCESSING

Kerim Kürşat ÇEVİK

**The Graduate School of Natural and Applied Science of Selçuk University
The Degree of Doctor of Philosophy in Computer Engineering**

Advisor: Asst. Prof. Dr. Hasan Erdiñç KOÇER

2016, 144 Pages

Jury

Asst. Prof. Dr. Hasan Erdiñç KOÇER

Prof. Dr. Halis ALTUN

Assoc. Prof. Dr. Adem Alpaslan ALTUN

Asst. Prof. Dr. Ömer Kaan BAYKAN

Asst. Prof. Dr. Mehmet HACIBEYOĞLU

Developmental Dysplasia of the Hip (DDH) or dislocation of the hip is a structural defect which results in incompatibility between the femoral head and the acetabulum. DDH can be treated easily at its early stage. Delay in diagnosis and treatment can cause the extremities (limbs) to shorten, claudication and restricted movement disorders leading to functional disabilities.

Medical control of the DDH is carried out by specialist doctors especially during the infancy period (0-3 months). This control is accomplished using two different techniques; the physical examination and the control after ultrasound (US) capture respectively. Specialists are adopting the US imaging technique because of the difficulty in diagnosing DDH based on the physical examination solely. In this method, distances and angles are measured on US images according to the reference points set manually by the specialist and then a diagnosis is carried out. Measurement errors may occur due to specialist or the quality of US image or techniques used. Therefore, computer-aided measurement and diagnostic systems is needed.

In this study, a computer aided self-diagnosis system was realized to diagnose the DDH disease on ultrasound images. The objective of the study is to alleviate the problems related to early diagnosis. Also, one of the goals is to minimize human error or specialist error in the diagnosis. As the disease may occur at any time in the newborn stage and in the infancy, the system could prevent difficulties that may occur in practice. The aim is to increase treatment success rate of the disease by contributing to early diagnosis using the implementation of the self-diagnosis system.

As a first step the widely known filters are applied to images in order to improve the image quality. The type of filters used are the Mean, Median, Gaussian, Wiener, Perona & Malik, Lee, Frost, namely. Then, Active Contour Models and Circular Hough Transform Method were applied to determine the iliac and femoral regions. In the next stage, alpha and beta angles were required for the implementation of the Graf method, which is widely acknowledged in the literature and used in the DDH diagnosis. These alpha and beta angles were determined by applying a variety of morphological image processing algorithms on the images (Thinning, Skeletonization, Pruning and Branchpoints). In the final stage, typing was performed with the Graf method using alpha and beta angles, and the performance of the system was measured by comparing the types to the specialist's results. In addition, as an alternative method to Graf, alpha and beta angles and as a new approximation to the GKD diagnosis, base line/femoral ratio feature values obtained from the system were classified using artificial intelligence techniques. Results from this method are compared to the Graf method.

Keywords: Developmental Hip Dysplasia, Ultrasound, Active Contour, Circular Hough Transform, Neural Networks, Fuzzy Logic

ÖNSÖZ

Tez çalışmasına verdiği destekten dolayı tez danışmanım Yrd. Doç. Dr. Hasan Erdinç KOÇER 'e, tez süresince belirttikleri değerli görüş ve önerilerle tezin yönlendirilmesine yardımcı olan Tez İzleme Komitesi üyeleri Prof. Dr. Halis ALTUN ve Yrd. Doç. Dr. Ömer Kaan BAYKAN 'a, Ultrason görüntülerinin kaydedilmesi, incelenmesi ve yorumlanması aşamalarında bana destek veren Selçuklu Tıp Fakültesi Radyoloji Bölümü öğretim üyelerinden Doç. Dr. Mustafa KOPLAY ve Bağcılar Eğitim Araştırma Hastanesi Radyoloji bölümünde görevli Uzman Dr. Şeyda ANDAÇ 'a teşekkürlerimi ve şükranlarımı sunarım.

Son olarak eğitim sürecim boyunca bana inanan, emek harcayan aileme ve bıkmadan usanmadan her daim yanımda olan eşime ve oğluma teşekkür ederim.

Kerim Kürşat ÇEVİK
KONYA-2016

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	x
1. GİRİŞ	1
1.1. Tezin Amacı, Önemi ve Literatüre Katkısı.....	2
1.2. Kaynak Araştırması	2
1.3. Tezin Organizasyonu	5
2. GELİŞİMSEL KALÇA DİSPLAZİSİ	7
2.1. Kalça Yapısı.....	9
2.1.1. Asetabulum Yapısı.....	10
2.1.2. Femur Yapısı.....	13
2.2. GKD Tipleri	15
2.2.1. Oluşumsal Çıkık	15
2.2.2. Tipik Çıkık.....	15
2.3. Ultrasonografi	16
2.4. GKD Teşhisinin Graf Yöntemi ile Yapılması	18
2.4.1. Tip I Kalça	21
2.4.2. Tip II Kalça	22
2.4.3. Tip III Kalça.....	22
2.4.4. Tip IV Kalça	23
3. MATERYAL VE YÖNTEM.....	24
3.1. Kullanılan Medikal Veriler	24
3.2. Çalışmanın Aşamaları.....	26
3.3. Kullanılan Yazılım Altyapısı	27
4. GÖRÜNTÜLERİN FİLTRELENMESİ.....	29
4.1. Gürültü	30
4.1.1. Gürültü Modeli	31
4.1.2. Benek Gürültü.....	31
4.1.3. Tuz ve Biber Gürültü	32
4.1.4. Gaussian Gürültü	33
4.2. Literatürde Sık Kullanılan Filtreleme Yöntemleri	33
4.2.1. Ortalama Filtresi	36
4.2.2. Ortanca Filtresi	37
4.2.3. Perona Malik Filtresi	37

4.2.4. Wiener Filtresi	38
4.2.5. Gaussian Filtresi	39
4.2.6. Lee Filtresi	39
4.2.7. Frost Filtresi	40
4.3. Ön İşlem Yöntemlerinin Değerlendirilmesi	40
4.3.1. Gözlemci Hassasiyeti ile Değerlendirme	41
4.3.2. Görüntü Kalitesi İstatistiksel Ölçümü	45
4.3.3. Görüntü Segmentasyon Testi	48
5. SEGMENTASYON	53
5.1. Aktif Kontur Modeli (Active Contour Model)	53
5.1.1. Yılan Modeli (Snake Model)	54
5.1.2. Düzey kümeleri Modeli (Level Sets Model)	56
5.2. Hough Dönüşümü (Hough Transform)	58
5.2.1. Dairesel Hough Dönüşümü (Circular Hough Transform)	59
5.3. Segmente Edilecek Bölgeler	61
5.4. İlium Bölgesi Tespiti	62
5.5. Asetabular Çatı (İliak) Bölgesi Tespiti	66
5.6. Labrum Bölgesi Tespiti	67
5.7. Femur Bölgesi Tespiti	68
6. ÖZELLİK ÇIKARIMI	70
6.1. Alfa Açısının Belirlenmesi	70
6.2. Beta Açısının Belirlenmesi	72
6.3. Temel Çizgi / Femur Oranının Belirlenmesi	73
7. GELİŞİMSEL KALÇA DİSPLAZİSİ SINIFLANDIRMASI	78
7.1. Graf Yöntemi ile Sınıflandırma	78
7.2. Yapay Zekâ Yaklaşımı ile Sınıflandırma	81
7.2.1. Yapay Sınır Ağları (YSA)	82
7.2.2. Bulanık Mantık (BM)	90
7.2.3. Bulanık Sınır Ağları (BSA)	97
7.3. Sınıflandırma Sonuçlarının Değerlendirilmesi	113
8. SONUÇLAR VE ÖNERİLER	115
8.1. Sonuçlar	115
8.2. Öneriler	119
EKLER	121
EK-1 Etik Kurul Kararları	121
EK-2 MATLAB Yazılımı Ekran Görüntüleri	122
EK-3 Alyuda NeuroIntelligence Programı Ekran Görüntüleri	124
EK-4. Görüntü Morfolojisi	125
Ek-4.1. Aşınma (Erosion)	125
Ek-4.2. Genleşme (Dilation)	126
Ek-4.3. Açınım (Opening)	127
Ek-4.4. Kapanım (Closing)	128

Ek-4.5. Rastgele Dönüşümler (Hit and Miss Transforms)	129
Ek-4.6. İskelet Çıkarımı (Skeletonization)	130
Ek-4.7. İnceltme (Thinning)	131
Ek-4.8. Budama (Pruning)	132
Ek-4.9. Kalınlaştırma (Thickening)	134
Ek-4.10. Histogram Eşitleme	134
KAYNAKLAR	136
ÖZGEÇMİŞ	144



SİMGELER VE KISALTMALAR

Kısaltmalar

AK	:	Aktif Kontur
AKM	:	Aktif Kontur Model
ANN	:	Artificial Neural Networks
BM	:	Bulanık Mantık
BSA	:	Bulanık Sinir Ağı
DHD	:	Dairesel Hough Dönüşümü
GKD	:	Gelişimsel Kalça Displazisi
HD	:	Hough Dönüşümü
MSE	:	Mean Squared Error
OYF	:	Olasılık Yoğunluk Fonksiyonu
PSNR	:	Peak Sinal to Noise Ratio
SAR	:	Synthetic Aperture Radar
SİAİ	:	Spina İliaca Anterior Inferior
SİAS	:	Spina İliaca Anterior Superior
SNR	:	Signal Noise Ratio
SS	:	Standart Sapma
US	:	Ultrason
YSA	:	Yapay Sinir Ağları
YZ	:	Yapay Zekâ

1. GİRİŞ

Gelişimsel kalça displazisi (GKD) veya kalça çıkığı, femur (uyluk) başı ile asetabulum (çukurluk) arasındaki uyumsuzluk sonucu meydana gelen yapısal bir bozukluktur. Dünya’da sıklığı 1/3000 olarak saptanan bu hastalığın prevalansı (oluşma riski olan bölge) Japonya ve Akdeniz Havzası’nda daha yüksektir. Ülkemizde de sık görülen GKD gerek hasta, gerekse de toplum sağlığı açısından büyük önem taşımaktadır. Ülkemizde yapılan klinik ve radyolojik taramalarda GKD insidansı (bir hastalığı nüfusa göre görülme oranı) %0.5–1.5 arasında bulunmaktadır (Kutlu, 1984; Doğruel ve ark., 2008).

GKD erken tanı ile başarılı bir şekilde tedavi edilebilir. Tanıda ve tedavide gecikme ekstremiteler (uzuv) kısalığı, topallama ve fonksiyonel özrürlük gibi kısıtlı hareket bozukluklarına neden olabilir. Yeni doğan döneminde tanı konulan ve başarılı şekilde tedavi edilen bebeklerin %96’sında anatomik ve radyolojik olarak normal kalça gelişimi elde edilebilmektedir (Tosun, 2010).

Uzmanların GKD teşhisini verebilmesi için iki yöntem kullanılır. Bunlar fiziksel muayene ve Ultrason (US) görüntüleme ile teşhis işlemleridir. US ile kalça taraması dünyada yaygın olarak kullanılmaktadır. Bazı ülkelerde US ile tarama her yeni doğan bebekte uygulanırken, bazı ülkelerde ise sadece risk faktörü taşıyan bebekler taramaktadır.

Ülkemizde ise henüz rutin tarama programı uygulanmamaktadır. Bunun sebeplerinden bir tanesi yeterli sayıda uzman kişinin bulunamaması, bir diğeri ise yeterli sayıda US cihazının olmaması gösterilebilir (Şenaran ve ark., 2004; Tosun, 2010). Uzmanın US cihazında kalça eklemlerini içeren görüntüyü yakalaması ve dondurulmuş görüntü üzerinde eklemleri işaretleyip açısız ve boyutsal ölçümleri yapması zahmetli bir iştir ve zaman almaktadır. Ayrıca GKD teşhisi sırasında radyoloğun kalça eklemleri üzerinde yaptığı işaretlemelerde ve hesaplamalarda hatalar oluşabilmektedir. Bu hatalar da kalça displazisine sahip bir bebeğin gelişiminde olumsuz etkilerin görülmesi riskini doğurmaktadır. Henüz günümüzde GKD teşhisini yapabilen bilgisayar destekli bir sistem mevcut değildir.

Tüm bu bilgiler ışığında gerçekleştirilen bilgisayar destekli GKD teşhis sistemi sayesinde, hastalığın erken teşhis ve dolayısıyla tedavisine katkı sağlanmaktadır. Hastalığın yeni doğan ve bebeklik dönemlerinde herhangi bir anda ortaya çıkabileceği düşünüldüğünde, uygulamada ve uygulama sıklığında oluşacak zorlukların (uzmanın 0-3

ay bebekleri sürekli kontrol altında tutması) önüne geçilmiş olunacaktır. Bilgisayar destekli teşhis sistemi vasıtası ile hastalığın erken teşhisi ve tedavi başarımı artacaktır.

1.1. Tezin Amacı, Önemi ve Literatüre Katkısı

Gerek ülkemizde gerekse dünya çapında GKD 'nin erken teşhisi ve tedavisi için oldukça fazla çaba sarf edilmektedir. Fakat GKD 'nin teşhisinde, kullanılan yöntemlerin farklılıkları, insan hatalarına bağlı olması ve teknik donanım yetersizliğinden kaynaklanan sorunlar sebebiyle teşhisinin tam olarak yapılamadığı görülmektedir (Külcü ve ark., 2015).

Araştırma kapsamında radyoloji ve ortopedi bölümlerinde çalışan uzmanlarla yapılan görüşmeler ışığında denilebilir ki, GKD teşhisinde doktorların göreceli kararlar vermesi ve teşhis için kullanılacak görüntüler üzerinde yapılan ölçümlerde hata oluşması gibi problemlerle karşılaşılmaktadır. Bu problemlerin azaltılmasına yönelik bilgisayar destekli bir teşhis sisteminin gerekliliği ortaya çıkmaktadır. Bu çalışmada geliştirilen sistem sayesinde; US cihazından alınacak görüntülerde iyileştirme yapılarak ölçümlerin daha doğru yapılması ve dolayısıyla teşhisin daha güvenilir konması sağlanabilecektir.

TUIK verilerine göre 2015 yılında ülkemizde 1.3 milyon canlı doğan bebek vardır (TUIK, 2015). GKD'nin Türkiye'deki görülme sıklığının 1000 canlı doğumda yaklaşık 5 ile 15 arasında olduğu öngörülmektedir. Bu da ülkemizde her yıl tedavi edilmediği takdirde sakat kalma olasılığı olan yaklaşık 14-18 bin yeni doğan ile karşılaşıldığı anlamına gelmektedir (Köse ve ark., 2013). Tasarlanan sistemin her yeni doğana uygulanarak, uzman kişiden ve alınan görüntü kalitesinden kaynaklanan hata oranını %10 bile azalttığı öngörülürse sakat kalma riskine sahip bebeklerden yaklaşık 1800 tanesi sakat kalmaktan kurtulacaktır. Bu sayısal veriler ışığında bilgisayar destekli otomatik GKD teşhis sisteminin önemi bir kez daha ortaya çıkmaktadır.

1.2. Kaynak Araştırması

Yeni doğan kalça taramasında, US ilk defa 1978 yılında Avusturyalı ortopedist Reinhard Graf ve ark. (1983) tarafından kullanılmıştır (Tuncay ve ark., 2005). Bu çalışma ile ilgili ilk yayın 1983 yılında yapılmış ve araştırmacılar tanı kriterlerini açıklamışlardır (Graf, 1983; Smergel ve ark., 2004). 1984 yılında ise ultrasonografik GKD sınıflaması ile ilgili bilimsel sonuçlar yayınlanmıştır (Riad ve ark., 2005).

US ile GKD teşhisi için statik ve dinamik olmak üzere iki temel muayene yöntemi vardır. Statik yöntem Graf tarafından geliştirilmiştir. Kalçanın tek bir görüntüsü ile anatomik özelliklerinin değerlendirilmesine dayalı morfolojik bir yaklaşımdır (Şaşmaz, 2011). Graf yöntemi, kalçanın standart planda görüntülenip, sonogram üzerinde ölçülen açılarla kalça eklemi morfolojisinin tiplendirilmesine dayanmaktadır. Kalçanın ultrasonografik olarak değerlendirme ve tiplendirilmesinde alfa ve beta açıları esastır (Graf, 2006).

Dinamik US görüntüleme 1984 yılında radyolog Theodore Harcke tarafından İngiltere’de popularize edilmiş, koronal ve sagittal planlarda görüntüleme sağlanmış bir yöntemdir (Harcke ve ark., 1984). Bu yöntemde, ultrasonografik inceleme sırasında Ortolani ve Barlow manevraları kullanılıp kalçanın değişik pozisyonlarında görüntüler elde ederek değerlendirme yapılmaktadır. Harcke (2005) ultrasonografik farklı bir yöntem geliştirerek kalça çıkığına 2 planda incelemişler, kalça eklemi 90° fleksiyonda iken koronal planda görüntüler almışlardır.

1985’de Morin ve ark. femur başının asetabulumun kemik kısmıyla örtünmesini yüzde oranlarla veren (lineer parametreler kullanan) bir ölçüm sistemi geliştirmişlerdir. Bu sistemde femoral örtünme kızlarda %54, erkeklerde %56 ve yukarısı olduğunda normal, %33 ve altında olduğunda her iki cinsiyet için anormal ve %33-56 arasında olduğunda sınır çizgisi olarak değerlendirilmiştir (Irha ve ark., 2004). Bu lineer ultrasonografik ölçümler Terjesen tarafından da yapılmıştır. Terjesen 1989’da femur başının örtünmesini ölçmek için koronal planda US ve AP grafikler kullanmıştır. 1–3 aylık bebeklerde femur başı örtünmesinin %58, 4–5 aylık bebeklerde ise %62 olduğunu bildirmiştir (Falliner ve ark., 2002).

Graf ve Terjesen yöntemlerinin karşılaştırılması sonucunda, her iki yöntemin de kalça eklemi ölçümlerinde kesin ve doğru sonuçlar verdiği saptanmış (Falliner ve ark., 2002), ancak Graf’ın açısal ultrasonografik parametrelerinin tanıda ve anormal sınıflandırmada daha uygun, özgül ve fonksiyonel olduğu gözlenmiştir (Irha ve ark., 2004).

Yapılan bu çalışmaların tamamı görüntü üzerinde femur ve ilium bölgelerinin elle tespitine dayanmaktadır. Bu bölgelerin otomatik olarak tanınmaya çalışıldığı ilk çalışma literatürde 1998 yılında görülmektedir.

Overhoff ve ark. (1998), 10 farklı resim üzerinde otomatik femur tespiti üzerine bir çalışma gerçekleştirmişlerdir. Resimler üzerinde femur bölgesinin ölçümleri yapılmış ve istatistiksel analizlerde bulunmuşlardır.

Overhoff ve ark. (1999) ise femur ve ilium bölgelerinin 3 boyutlu tasarımı üzerine bir çalışma yapmışlardır. 26 görüntünün 23 tanesinde 3 boyutlu tasarımında başarılı olmuşlardır.

2004 yılında Hongbing ve ark. GKD tedavisinde kullanılmak üzere hastanın femur ve ilium bölgelerinin 3 boyutlu tasarımına yönelik bir çalışma gerçekleştirmişlerdir. Bu model hastalığın teşhisinde ve tedavisinde kullanılmak üzere MR görüntülerinden 3 boyutlu simülasyon dönüşümüne dayanmaktadır (Hongbing ve ark., 2004).

Luis-Garcia ve Alberola-Lopez (2005), yaptıkları çalışmada 2 boyutlu USG görüntülerinden Dinamik Şekil Önceliği (Dynamic Shape Priority) yöntemi kullanarak femur ve ilium bölgelerinin segmentasyonu üzerinde durmuşlardır. Çalışmada görüntünün segmente edildiği ifade edilmiş ancak başarı oranları verilmemiştir.

Luis-Garcia ve Alberola-Lopez (2006), gerçekleştirdikleri uygulamada 3 boyutlu görüntüler üzerinde Graf yöntemi kullanarak GKD teşhisine yönelik bir çalışma yapmışlardır. 3 Boyutlu 7 adet yeni doğan kalça görüntüsü kullanılan uygulamada sonuçların umut verici olduğu belirtilmiş ancak yöntemin bazı olumsuzluklarının olduğu ifade edilmiştir. Bu olumsuzluklardan ilki görüntü oluşturulurken ortaya çıkabilecek en ufak hasta hareketinin sonucu olumsuz yönde etkilemesidir. İkincisi ise, bazı durumlarda asetabulumun çok değişken yapıya sahip olduklarıdır.

2007 yılında Luis-Garcia ve arkadaşları sundukları bildiriye, femur ve asetabulum bölgelerinin segmentasyonuna yönelik olarak elde edilen farklı doku tiplerinin ayrıştırılması amacıyla k-means sınıflandırma yöntemi kullanmışlardır. Bunun sonrasında bazı morfolojik yöntemler uygulayarak femur ve asetabulum tespiti gerçekleştirmişlerdir. Çalışma sonucunda otomatik segmentasyona geçiş için bu yöntemlerin daha iyi sonuçlar verdiğini belirtmişlerdir (Luis-Garcia ve ark., 2007).

Chen ve arkadaşları (2007) yaptıkları çalışmada GKD hastalığı teşhisi için US görüntülerinin otomatik segmentasyonuna yönelik bir uygulama gerçekleştirmişlerdir. Çalışmalarında ilk olarak klasik segmentasyon yöntemlerini kullanmışlar, fakat US görüntülerinin işlenmesinin zorluğundan dolayı bu yöntemlerin sağlıklı sonuçlar vermediğini belirtmişlerdir. Daha sonra görüntülerin segmentasyonu için mixture-based partial-volume algoritması kullanmışlar ve kayda değer sonuçlar elde ettiklerini belirtmişlerdir. Ayrıca çalışmalarında segmente edilen bölgenin 3 boyutlu analizi ve hastalığın çözümünde yardımcı olacak 3 boyutlu simülasyonunu da gerçekleştirmişlerdir.

Yokota ve arkadaşları (2009) gerçekleştirdikleri çalışmada 3D bilgisayarlı tomografi görüntüleri üzerinde femur ve pevlis boyutunun otomatik segmentasyonu için istatistiksel şekil modeli (Statistical shape models-SSM) yöntemini önermişlerdir. Çalışmalarının sonuç bölümünde SSM yönteminin femur ve pevlis boyutunun segmentasyonunu iyileştirdiğini belirtmişlerdir.

2011 yılında Akiyama ve arkadaşları yayınladıkları makale çalışmasında 40 normal 22 displazili kalça içeren MR görüntüleri üzerinde 3 boyutlu görüntüleme gerçekleştirmişlerdir. Çalışma sonunda 3 boyutlu görüntü dönüşümünde ortalama hatanın 0.172 mm ve 0.193 mm arasında olduğunu bildirmişlerdir (Akiyama ve ark., 2011).

Fukiage ve arkadaşları (2014) GKD teşhisi için 3 boyutlu MR görüntüleri kullanarak kalça eklemi hareketi sırasında asetabulum ve femur arasındaki ilişkiyi kullanmışlardır. 3 boyutlu MR görüntülerinde GKD tanısını koylebilek için bu yöntemin yararlı olduğunu belirtmişlerdir.

2015 yılında Al-Bashir ve arkadaşları röntgen görüntüleri üzerinde Canny kenar bulma, template matching, Hough dönüşümü yöntemlerini kullanarak asetabular açıları otomatik belirlemeye çalışmışlardır. 16 adet görüntü için başarı oranını %85 olarak belirtmişlerdir (Al-Bashir ve ark., 2015).

1.3. Tezin Organizasyonu

Tez çalışması dokuz ana bölümden oluşmaktadır.

Birinci bölümde, tez çalışmasının konusu hakkında genel bir özet bilgi verilmektedir. Tez konusunun tanıtılması, tez konusunun amacı ve önemi konularına değinilmektedir. Ayrıca yine bu bölümde literatürdeki mevcut çalışmalara ve çalışmanın literatüre olan katkısından bahsedilmiştir.

İkinci Bölümde, Gelişimsel Kalça Displazisi hastalığı hakkında bilgi ve radyolojik görüntülenmesi konuları anlatılmıştır.

Üçüncü bölümde, tez çalışmasında kullanılan veriler tanıtılmıştır. Tez çalışmasının aşamaları blok diyagram halinde gösterilmiştir. Ayrıca tez çalışmasının yazılım altyapısı hakkında bilgi verilmiştir.

Dördüncü bölümde, US görüntülerinin filtrelenmesinde kullanılan yöntemler ve bu yöntemlerin verilere uygulanması anlatılmıştır. Filtreleme yöntemlerinin değerlendirilmesi aşamaları hakkında bilgi verilmiştir.

Beşinci bölümde, filtrelerden geçirilen US görüntülerinin segmentasyonu ve özellik çıkarım aşamasında kullanılacak olan referans noktalarının tespitine yönelik yapılan çalışmalar anlatılmıştır.

Altıncı bölümde özellik çıkarımı aşamaları ve sonuçları verilmiştir. Bu bölümde teşhiste önemli bir husus olan alfa ve beta açılarının belirlenmesi yöntemleri ve temel çizgi/femur oranının elde edilmesi aşamaları anlatılmıştır.

Yedinci bölümde, gelişimsel kalça displazisinin sınıflandırılmasına yönelik yapılan çalışmalar anlatılmıştır. Bu bölümde literatürde bulunan ve uzman radyologların sıkça kullandığı Graf yöntemi ile literatürde kullanılmamış olan yapay zekâ yöntemleri ile sınıflandırma yapılmış ve sonuçları karşılaştırılmıştır.

Sekizinci bölümde, sonuçlar ve öneriler tartışılmıştır.

Dokuzuncu ve son bölümde çalışmada kullanılan ekler ve kaynaklar yer almaktadır.

2. GELİŞİMSEL KALÇA DİSPLAZİSİ

Gelişimsel kalça displazisi (GKD), en sık görülen doğumsal kalça hastalığıdır. Hastalık başlangıçta kalça eklemde femur başının, asetabulumdan çıkması ve yer değiştirmesine sebep olan anormal gevşekliliktir. Femur başının yerinden çıkması, zaman içinde asetabulumda kalıcı değişikliklere sebep olur. Tedavi edilmezse, kalıcı sakatlığa ve eklem bozukluğuna yol açar (Külcü ve ark., 2015). GKD'nin Türkiye'deki görülme sıklığının 1000 canlı doğumda yaklaşık 5 ile 15 arasında olduğu öngörülmektedir. Bu da ülkemizde her yıl tedavi edilmediği takdirde sakat kalma olasılığı olan yaklaşık 14-18 bin yeni doğan ile karşılaşıldığı anlamına gelmektedir (Köse ve ark., 2013).

GKD erken tanı ile başarılı bir şekilde tedavi edilebilir. Tanıda ve tedavide gecikme ekstremitelerde (uzuv) kısalığı, topallama ve fonksiyonel özrürlük gibi kısıtlı hareket bozukluklarına neden olabilir. Yeni doğan döneminde tanı konulan ve başarılı şekilde tedavi edilen bebeklerin %96'sında anatomik ve radyolojik olarak normal kalça gelişimi elde edilebilmektedir (Tosun, 2010). Yürüme çağına gelmiş çocuklarda ise, konservatif tedavi şansı kalmamaktadır. Cerrahi tedavi ile de olguların tümünde başarılı sonuçlar almak olanaksızdır (Song ve Lapinsky, 2000). Cerrahi tedavi başarılı olsa da yarattığı olumsuzluklar göz ardı edilemeyecek kadar büyüktür. Nitekim GKD'li olguların %30'unda ileri yaşlarda total kalça artroplastisi gerekli olmaktadır (Uslu ve ark., 2002). Tüm bu olumsuzluklar göz önüne alındığında, erken tanı ve tedavinin ne kadar önemli olduğu ortaya çıkmaktadır.

GKD görülme sıklığını saptamak kalçadaki bu anormal durumun tanımlanmasındaki farklılıklar, kalça muayenesindeki seçilen metot farklılıkları, muayeneyi yapan kişinin bilgi seviyesi ve çalışılan topluluğun özelliklerine bağlı olarak değişiklik göstermektedir. Genel anlamda doğum oranına göre GKD görülme sıklığı % 0.1- 4 arasında değişmektedir. Fiziki muayeneye göre US görüntüleme ile teşhiste daha yüksek görülme sıklıkları bildirilmiştir (Rosendahl ve ark., 1994).

Kalça gelişim bozukluğunun tanımlanması, aşamalandırılması ve tedavinin planlanmasında US görüntüleri üzerinden elde edilen bulgular kullanılır. Bu işlemlerde genellikle Graf, Harcke ve Terjesen yöntemleri uygulanmaktadır. Genel kalça taramalarında dünyada yaygın olarak US görüntüleme kullanılmaktadır. Bazı ülkelerde US ile tarama her yeni doğan bebeğe uygulanırken, bazı ülkelerde ise sadece risk faktörü taşıyan bebekler taranmaktadır (Bache ve ark., 2002; Herring, 2003).

Bu yöntemlerin uygulanabilmesi için US cihazından doğru açı ile doğru görüntünün alınması gerekmektedir. Hastalığın erken teşhisinin yeni doğan ve bebeklik dönemine rastladığı düşünüldüğünde, doğru açı ve doğru görüntü elde etmek oldukça zordur. Yeni doğan döneminde bebeği tam yan olarak stabilize etmek için, vücudu her iki yönden kavrayan, özel bölümleri olan bir masa kullanılır (Şekil 2.1).



Şekil 2.1. US cihazı ve özel tasarlanmış masa (Tosun, 2010)

Yatay pozisyonunda ve kalçası hafif (yaklaşık 10°) içe dönük yatan bebeğin kalça bölgesine dik olarak konulan prob, her iki elle pozisyonu uygunlaştırılır ve standart plandaki uygun görüntü sağlanınca görüntü kaydedilir (Şaşmaz, 2011).

GKD 'nin görülme sıklığında; cins, yaş grubu, ırk ve hatta aynı ülkenin farklı bölgeleri etkili olmaktadır. Tüm yeni doğanlarda genel görülme sıklığı, % 0.5–1.5 olduğu kabul edilir (Gent ve Clarke, 2004). Görülme sıklığındaki farklılıklar ırk ve çevresel etkenlere dayanır. Ayrıca bu farklılıkların US analizi yöntemlerinden etkilendiği de söylenebilir (Herring, 2003). GKD'nin bölgelere göre görülme sıklık dağılımı Çizelge 2.1'de verilmiştir.

Çizelge 2.1. Bazı serilerde GKD sıklığı (Tümer ve Ömeroğlu, 1997)

Yazar	Yıl	Bölge	Sıklık (Binde)
Coleman	1956	ABD (Utah)	20
Stanisavljeviç	1961	ABD (Michigan)	10
Barlow	1962	İngiltere (Salford)	1.5
Von Rosen	1965	İsveç (Malmö)	1.7
Edelstein	1966	Afrika (Bantu)	0
Hierton-James	1968	İsveç (Uppsala)	20
Berkman	1969	Türkiye	4.7
Bayındır	1971	Türkiye	1.4
Walker	1973	Kanada	188.5
Klisic	1975	Yugoslavya	75.1
Peterson	1976	Avustralya	6.2
Haglund	1981	Hong Kong	0.1
Ege	1983	Türkiye	5.8

GKD insidansı muayene şartları, bölgesel farklılıklar, ırk ve diğer etkenlere bağlı olarak değişmektedir. İsveç'te bu oran 1.7/1000, Yugoslavya'da 75.1/1000, Kanada'nın Manitoba bölgesinde 188.5/1000 dir. Hong Kong'daki Çinli çocuklarda 0.1/1000 oranında görülürken, Afrika'daki Bantu kabilesinde GKD'ye hiç rastlanılmamıştır (Herring, 2003). Lehmann ve ark.'nın (2000) yaptığı çalışmada İskandinav ülkeleri için bu oran klinik muayene ile 8.6/1000 iken, US ile yapılan taramalarda 25/1000 olarak bulunmuştur.

Ege (1994) Türkiye için yaptığı tarama çalışmasında sıklığı 5.8/1000 olarak belirtmiştir. Kutlu ve ark., (1992) Konya bölgesinde yaptığı yeni doğan tarama çalışmasında GKD sıklığını %1.34 olarak bulmuştur. Tümer ve Ömeroğlu (1997) gerçekleştirdikleri klinik ya da radyolojik bulgular temelli çalışmada ise, GKD sıklığı %0.5 ile %1.5 arasında olduğunu belirtmişlerdir. Türkiye'de yılda yaklaşık 1.4 milyon canlı doğum olmaktadır (TUIK verilerine göre 2015 yılında ülkemizde 1.3 milyon canlı doğan bebek vardır) ve bebek kalça US değerlendirmesi yapan hekim sayısının yetersiz olduğu düşünüldüğünde, genel bir US kalça tarama programını uygulamanın oldukça zordur (Tosun, 2010).

2.1. Kalça Yapısı

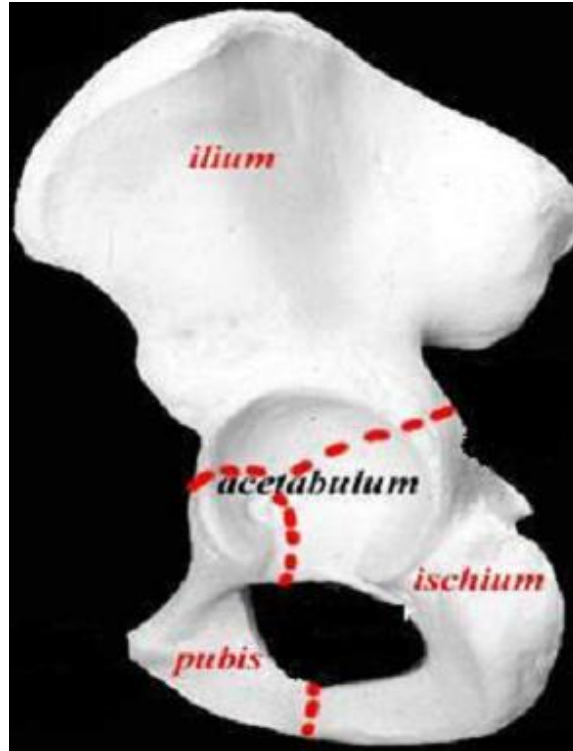
İnsan vücudunun anatomisine bakıldığında, femur üst ucu ile kalça kemiğinin birleşmesiyle kalça eklemi oluşur. Kalça eklemi, gövdeyi alt uzuvlara bağlayan ve her planda harekete izin veren bir eklemdir (Şaşmaz, 2011). Kalça bölgesinde yer alan pelvis kemiğinde asetabulum, ilium, iskiyum ve pubis olarak isimlendirilen kısımlar bulunur.

Bununla birlikte asetabulum çukuruna oturan ve bacak hareketini sağlayan femur başı kalça yapısı içerisinde değerlendirilen kısımlardan biridir.

2.1.1. Asetabulum Yapısı


Asetabulum üç ayrı kemikleşme merkezi tarafından oluşturulur. Bunlar ilium, iskium ve pubis'dir. Femur başına bu üç büyük alanda kemik desteği sağlar. Anterior ve posterior kolonlar asetabuler duvarlara denk gelen pubis ve iskium'dan oluşur. İnce mediyal duvar desteği az olmasına karşılık asetabuler çatı, posterior kolonun anterior kolona karıştığı yerdir ve femur başının direkt olarak üstten kapanmasını sağlar (Ekşioğlu ve ark., 2011). Pelvis bu üç yapının birleşmesiyle oluşan kemiğin genel adıdır (Şekil 2.2).

Asetabular yüzeyin genişliği 2 cm. ve 45 derece aşağı 15 derece öne bakar (Nagao ve ark., 2008). Asetabulum iç yüzeyi tamamen kıkırdakla kaplı değildir. Eklemin asıl dayanağını hyalen kıkırdak ile kaplı "facies lunata" oluşturur. Yarım ay şeklinde olan bu yapının özelliği, kalın kıkırdak yapısı, yağ ve bağ dokusu ile kaplı olmasıdır. Bu yapı ile pelvis kemiklerinden femur başına vücut ağırlığı aktarılır.



Şekil 2.2. Asetabulum yapısı

Asetabulumun ortada kalan kısmına fossa asetabuli denir. Kıkırdağı olmayan, kemik yapısı ince ve içi yağ dokusu ile doludur. Asetabulum kenarları 5–6 mm.'lik fibröz kıkırdaktan (onarıcı bağ dokusu) oluşan bir yapı ile çevrilidir. Bu bölüme labrum asetabulare denir (Şekil 2.3). Labrum asetabulum alt kısmında bulunan incisura asetabuli hariç tüm asetabulum çevresini dolandır. Fibröz kıkırdak yapısındaki bu çerçeve eklem çukurunu artırırken hem femur başının daha iyi kavranmasına hem de etkili bir negatif basıncın oluşmasına katkı sağlar (Şaşmaz, 2011).



Şekil 2.3. Asetabulum iç yapısı ve labrum (Schünke, 2009)

Limbus adı verilen kısım labrum asetabularenin çıkıntı değeri yüksek yeridir. Bu yapı gelişimsel kalça çıkışında asetabulumun dış tarafına doğrudur. Asetabulumun açıklığı laterale, kaudale ve anteriora doğrudur. Asetabuler inlet düzlemi ismi Von Lanz tarafından asetabulumun bu pozisyonuna verilmiştir. Inlet düzleminin eğimi, longitudinal vücut aksı ile asetabulum teğet çizilen çizgi arasındaki açıya eşittir. Gelişimsel kalçalarda bu açının değeri ortalama 42°'dir. Erişkin dönemde ise aradaki kıkırdak kemikleşerek tek bir çukur şekline dönüşmektedir. Erişkinlerdeki asetabulum hemisferik (yarım küreye benzer) bir sokettir ve yarıçapı ortalama 2.7 cm ve eklem yüzey alanı yaklaşık 16 cm²'dir (Şaşmaz, 2011).

2.1.1.1. İlium


Asetabulumu oluşturan kemiklerin en geniş olan ilium asetabulumun yaklaşık 5'te 2'sini kaplamaktadır. İç yüzüne karın kasları ve quadratus lumborum (bel dörtgen kasıdır ve yana eğilmeyi, 12. kaburga kemiğinin çukurlaşmasını ve nefes alma esnasında diyaframa yardımcı olmayı sağlar) yapışır. Crista'nın dış yan kenarına önden arkaya doğru sırasıyla; tensör fascia lata, gluteus medius, gluteus minimus ve gluteus maximus kasları yapışır. Crista iliaca'nın ön çıkıntısına Spina iliaca anterior superior (SİAS) ismi verilir. SİAS, sartorius kası ile inguinal ligamentin başlangıç yeridir (Şekil 2.4). Spina iliaca anterior inferior (SİAİ) ise SİAS'dan aşağı doğru oluşan kavisin bitiminde bulunan yapıdır. SİAİ'ye m.rectus femorisin düz başı yapışır. İliumun dış yüzüne gluteal kaslar (kalça kasları), iç yüzüne ise m.iliacus yapışır. İliak kemiğin arka tarafında iki kısım daha vardır. Bunlar; spina iliaca posterior superior ve inferiorudur. İliak kemiği, os ischii arka kısmı ile birleşerek siyatik sinirin (kalça siniri) geçtiği incisura ishiadica major'u oluşturur. İliumun yapısı genel olarak süngerimsidir ve özellikle crista iliaca ve SİAS bölgesi kemik yamaları için kullanılabilir (Tuhanioğlu, 2008).

2.1.1.2. İskium

Asetabulumun alt bölümünde bulunur (Şekil 2.4). Tuberculum iskiadicum, hamstring kasları bu bölgeye yapışır. Tuberculumun orta kısmına, ligamentum sacrotuberale yapışır. Lateral kenarında ise quadratus femoris kası, femura paralel olacak şekilde atlayarak geçer. Tuberkulum oturma esnasında vücuda destek olur (Tuhanioğlu, 2008).

2.1.1.3. Pubis

Ramus ascenden ile ramus descenden bölümlerinden oluşan pubis cismi orta kısımda yer alır (Şekil 2.4). Symphysis pubis vücudun sağından ve solundan gelen pubis kemiklerinin, birleşmesinden oluşur. Symphysis pubis bir syndesmosdur (bağ doku). İnguinal ligament pubis cisminin lateralinde yer alan tuberculum pubicum'a yapışır. Superior ramus asetabulumun 5'te 1'ini oluşturur ve lateralde geniştir. Kalça adduktorleri ve m.gracilis pubisten orijin alırlar (Tuhanioğlu, 2008).



Şekil 2.4. İlium, ischium, pubis (Tekin, 2011)

2.1.2. Femur Yapısı

Femur üst ucu; femur başı, boynu ve küçük trokanterin (yuvarlak çıkıntı) 5 cm kadar dış kısmını içine alan kemik yapıdır (Şekil 2.5). Femur başı bir kürenin yarısından biraz büyüktür. Femur başı bir küre değil, daha çok sfenoid (kama şeklinde) ve bir kısmı ovoid (yumurta şeklinde) yapıdadır (Aksu ve Işıklar, 2008).




Şekil 2.5. Femur üst uç yapısı (Schünke, 2009)

Femur başının posteroinferiora doğru düzgün yapısı ‘fovea capitis’ ile bozular. Femur başının eğimli yapısı kişiden kişiye farklılık gösterir. Femur başı çanak şeklindeki (cotyloid) asetabulumla eklemleşir. Baş ve boyun önde, kapsül içindedir. Normal bir kalçada femur başı merkezi asetabulumun merkezine oturur (Şaşmaz, 2011).

Femur vücudun en kuvvetli ve sağlam kemiğidir. Genellikle vücut uzunluğunun dörtte biri kadardır. Femur başının büyük bir kısmı eklem kıkırdağı ile örtülü yapıdadır. Femur başını gövdeye bağlayan dar bölüme kollum femuris denir. Femur boyunu yaklaşık 5 cm uzunluğundadır. Femur başı ile boyun arasında 120-130 derecelik bir açı (kollodiafizer açı) bulunur. Çocukluk döneminde oldukça geniş olan bu açı yaş ilerledikçe vücudun yükünün artması ile daralır (Aksu ve Işıklar, 2008).

Femur üst ucunun dış tarafında bulunan büyük çukıntıya Trokanter Major, arka alt tarafında bulunan küçük çukıntıya ise Trokanter Minör denir. Trokanter Major’ün daha küçük olan iç yüzünde ise Fossa Trokanterika denilen bir çukur bulunur. Trokanter Major’ün üstü Kaput Osis Femoris merkezi ile aynı seviyededir. Trokanter Major ve Minör’ü arka tarafta birbirine bağlayan kalın kenara Krista İntertrokanterika, ön taraftan birleştiren ve arkadakine oranla daha az belirgin olan çizgiye ise Linea İntertrokanterika denir (Bayhan, 2007). Asetabulum femur başının herhangi bir kalça pozisyonunda en az %40’ ını kaplar. Femur boynu tamamıyla kalça eklem kapsülü içindedir (Şekil 2.6).



Şekil 2.6. Femur başı yapısı (Schünke, 2009)

Kalça başlangıç durumuna geldiğinde, fovea aetabuler fossanın tam karşısındadır. Abduktor kasların (gluteus medius ve gluteus minimus) yapıştığı trokanter majör femur boynu ile femur başının birleşme noktasındadır. Normal bir femurda trokanter tepesinden dik çizilen çizgi yaklaşık femur başı merkezinden geçer. Posterosuperior bölgesi süperomediale doğru kıvrımlanır (Fabry ve ark., 1973; Jouve ve ark., 2005).

2.2. GKD Tipleri

2.2.1. Oluşumsal Çıkık

Oluşumsal (Teratolojik) formunda bebek kalça çıkığı ile doğar. Henüz anne rahminde iken yumuşak doku kasılmaları ve femur başının yer deęiştirmesi ile seyreder (Ege, 1994; Segal ve ark., 1999). Oluşumsal çıkığın prevalansı yaklaşık olarak 1/25000'di ve tipik çıkığa göre oldukça düşüktür (Cady, 2006). Emriyonun oluşması sürecinde yumuşak dokularda yapısal bozukluk oluşmaktadır. Erken yüksek çıkıklar genellikle teratolojiktir (Kapıcıođlu ve ark., 2006). Yeni doğan döneminde Ortolani manevrası kullanılarak tedavi edilemez (Ege, 1994; Herring, 2003). Bu tip çıkık kalçalarda önleyici tedavi başarılı deęildir, cerrahi tedavi başarı oranları da tipik kalçaya göre düşüktür (Ege, 1994).

2.2.2. Tipik Çıkık

GKD'nin en sık rastlanan tipidir (Thompson, 2001). Doğum öncesi, doğum sırasında veya doğum sonrası dönemde meydana gelebilir (Rosendahl ve ark., 1994). Tipik çıkık görülen bebekler nörolojik olarak normaldir (Thompson, 2001). Tipik çıkık insidansı yaklaşık %0.5 – 1.5 arasındadır (Cady, 2006). Aetabulum genellikle normal derinlikte olup, ileri yaşlar hariç femur başının şekli deęişmemiştir. Kasık bağı oldukça uzamış ve eklem kapsülü anormal gevşemiştir. Femur başının öne doğru eğilmesi artmıştır. Tipik çıkık 3 alt grupta incelenir; instabil (sublukse veya disloke edilebilir kalça), disloke (çıkık kalça) ve aetabular displazi (Şaşmaz, 2011).

İnstabil Kalça: Bu kalça tipinde gözlenebilir bir bağ gevşeklięi vardır. Yarı çıkık kalça (sublukse kalça); uyarıcı uygulamalar ile femur başının belli bir kısmı aetabulum dışına doğru çıkartılması ile oluşur. Bu durumda aetabulum ile femur başı arasındaki bağ

tamamen bozulmaz. Yarı çıkıklık (subluksasyon) hissedilir, fakat “klik” sesi alınamaz. Bu tür kalça prevalansı 14:1000 oranındadır (Henrikus, 1999). Disloke edilebilir kalça; uyarıcı uygulamalar ile femur başının tamamen asetabulum dışına doğru çıkartılması ile oluşur. Kalça gevşek bırakılınca, femur başı kendiliğinden yerine oturur ve “klik” sesi alınır. Disloke edilebilir kalça prevalansı 2.5:1000 oranındadır (Henrikus, 1999). İnstabil kalça tedavi edilmezse sublukse veya disloke olabilir.

Disloke (çıkık) kalça: Bu kalça tipinde femur başı asetabulumun dışındadır ve gittikçe asetabulumun dışına doğru yer değiştirir. Yeni doğan döneminde hafif fleksiyon-abduksiyon manevrası ile kolayca yerine oturtulabilir. Yerine oturtma sırasında “klik” sesinin alınması Ortolani testinin pozitif olduğunu gösterir. Çıkık kalça prevalansı 1.3:1000 civarındadır (Henrikus, 1999).

Asetabuler displazi: Bu kalça tipinde ana sorun asetabulumun sığ (displazik) olmasıdır, femur başı normal konumunda veya yarı çıkık olabilir (Şaşmaz, 2011).

2.3. Ultrasonografi

Ultrasonografi (USG); ultrason (US) kullanılarak görüntü elde edilmesi ve elde edilen görüntülerin genel adıdır. Bir hastalığı önlemenin en önemli yolu erken teşhistir. Erken teşhis ise hastalığın genel tarama programında uygulanması ile olur. GKD 'de ultrasonografik taramanın faydası klinik olarak tespit edilemeyen olguların saptanmasıdır. Önlenebilir ve zamanında tedavi ile tamamen düzelebilecek olan bu hastalık, yaşamın ilk aylarında gözden kaçarsa ileri yaşlarda çok ciddi bir sağlık problemi olarak karşımıza çıkmaktadır. GKD erken dönemde saptandığında konservatif yöntemler ile başarılı olarak tedavi edilebilmekte iken, geç kalınmış olgularda cerrahi girişimler zorunlu hale gelmektedir. Doğum sonrası ilk üç aylık dönemde asetabulum ve femur başının kıkırdak yapıda olması, bu dönemde GKD tanısında radyografi yerine daha uygun bir tanısal yöntem olan yeni doğan kalça ultrasonografisinin kullanılmasını gerektirmektedir (Şaşmaz, 2011).


Kalça USG'sinin en önemli ve olumlu yönleri; hızlı ve kesin tanıya olanak vermesi, x-ışını içermediğinden bebeklere zararlı olmamasıdır. Olumsuz yönleri ise deneyim gerektiren bir yöntem olması ve son derece hassas olduğu için fazladan tedaviye neden olabilmesidir. US GKD'nin erken tanısında, konservatif tedavi sürecindeki takiplerinde ve klinik inceleme programlarında etkin, güvenilir, tekrarlanabilir, özgül,

duyarlı ve kullanışlı bir yöntemdir (Şaşmaz, 2011). Dolayısıyla yeni doğan ve bebeklik döneminde kalça eklemine değerlendirilmesinde US en mantıklı yöntemdir.

US bazı bölgelerde rutin tarama yöntemi olarak kullanılmaktadır. Ülkemizde ise henüz rutin tarama programı uygulanmamaktadır. Öte yandan birçok araştırmacı da uygulamanın zorluğu nedeniyle, seçici tarama kullanımı daha uygun bulmaktadır (Tosun, 2010).

US cihazı ses dalgalarının değişik yoğunlukta dokular içinde farklı hızlarda ilerlemesi ve yansımaları prensibine dayanan bir mekanizma ile çalışır. US sırasında dokuya gönderilen ses dalgasının tutulması, yansımaları ve geçişinden kaynaklanan görüntü farkları ekranda görüntülenir. Ses dalgası kemik dokusuna çarptığında yansyarak geri döner ve monitörde beyaz renkle karakterize görüntü oluşturur.

GKD tanısı için yeni doğan kalçasından alından US görüntüsünde iliak kanat, labrum, epifiz hattı, intermusküler septumlar, kapsül ve femur boynu-perikondrium birleşme yeri görüntülenir. Ses dalgası kemik dokusunun ardına geçemediğinden, monitörde bu alanlar ultrasonik dalgaların yansımamasından dolayı siyah görünür. Bu özelliğe akustik gölge veya ultrasonik yarı gölge adı verilir. Trokanter majör, femur başı, asetabulum kırıkta tavanı ve kırıktağından ses dalgaları geçer fakat belli bir kısmı da yansıma yaparak ekranda saydam bir görüntü oluşturur. Bu sonografik şeffaflık özelliği ses boşluğu olarak adlandırılır (Şekil 2.7) (Graf, 2006).



Şekil 2.7. İnfantil kalça ultrasonografisi. 1. Femur 2. Trokanter majör 3. Femur boynu 4. Femur başı 5. Proksimal femur fizis hattı 6. Kapsül 7. Labrum 8. Perikondrium 9. Perikondrial boşluk 10. Periosteum 11. Asetabulum 12. İliumun osifiye ucu 13. İlium (Tuncay, 2004)


Kalça US ilk defa Graf tarafından 1978 yılında kullanılmıştır (Graf, 1983). Daha sonraları Novick, Harcke yenidoğan kalça muayenesinde ultrasonografik muayene

yöntemlerini tanımladılar (Novick ve ark., 1983; Harcke ve ark., 1984). Günümüzde US ile GKD teşhisi için iki temel muayene yöntemi kullanılmaktadır. Statik yöntem Graf tarafından geliştirilmiştir. Kalçanın tek bir görüntüsü ile yapısal özelliklerinin değerlendirilmesine dayalı bir yaklaşımdır (Graf, 2006). Dinamik US görüntüleme Theodore Harcke tarafından İngiltere’de ortaya çıkartılmış, koronal ve sagittal planlarda görüntüleme sağlanarak değerlendirme yapılan bir yöntemdir (Harcke ve ark., 1984; Harcke, 2005). Diğer yöntemlere göre Graf yöntemi kolay öğrenilen, basit bir yöntemdir ve dünya çapında en popüler kalça US yöntemidir. Avrupa’da uzun süredir yeni doğan kalçalarının incelenmesinde kullanılmaktadır (Tuncay ve ark., 2005).

2.4. GKD Teşhisinin Graf Yöntemi ile Yapılması

Graf yönteminde kalça eklemi sınıflandırması yapılırken, bebek yan yatırılarak vücut aksına paralel konulan US ucu ile belirli anatomik noktalar standart planda görüntülenir ve açılar belirlenir.

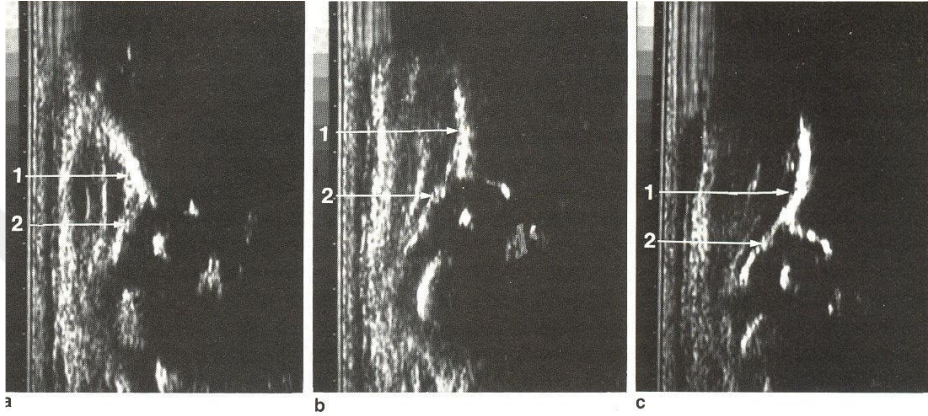
Yeni doğan döneminde bebeği tam yan olarak düz konumda tutmak için, vücudu her iki yönden kavrayan özel bölümleri olan bir masa kullanılır. Yatay pozisyonunda ve kalçası hafif (yaklaşık 10°) içe dönük yatan bebeğin kalça bölgesine dik olarak konulan prob, her iki elle pozisyonu uygunlaştırılır ve standart plandaki uygun görüntü sağlanınca görüntü kaydedilir (Şekil 2.8) (Graf, 2006).



Şekil 2.8. Standart sonogramda kalça eklemi yapıları. 1. subkutan yağ dokusu, 2. gluteal kaslar, 3. intermusküler septum, 4. eklem kapsülü, 5. sinovyal katlantı, 6. femur boynu kıkırdak bölümü, 7. osteokondral bileşke, 8. labrum, 9. asetabulum kıkırdak tavanı, 10. femur başı epifiz merkezi, 11. osteokondral bileşke akustik devamlılığı (çit görüntüsü), 12. kemik köşe, 13. iliak kemik, 14. triradiat kıkırdak (asetabuler fossa dokuları)

Standart çekilmiş bir sonogramda: İliak kemik cilde paralel olmalı, Asetabulum içinde iliumun osifiye ucu görülmelidir, Labrum görüntülenmelidir.

Ultrasonografik görüntüde bu üç noktanın görülemediği istisna olan durumlar da vardır. Bunlar Tip III ve Tip IV olarak tanımlanan disloke kalçalardır. Standart bir sonogramdaki kalça eklemi yapıları Şekil 2.8’de görülmektedir (Graf, 2006). Sonogram çekiminde iliak konturda oluşabilecek doğru ve yanlış görüntüleme biçimleri Şekil 2.9’da gösterilmiştir.

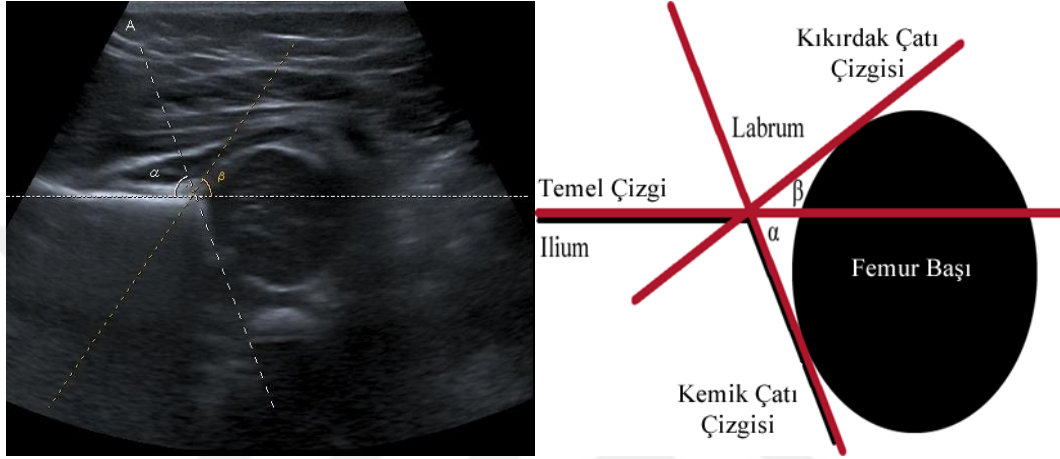


Şekil 2.9. Sonogramda doğru ve yanlış görüntüleme. 1. iliak kemik konturu, 2. asetabuler labrum. a) anterior planda çekim (yanlış), b) standart planda çekim (doğru), c) posterior planda çekim (yanlış) (Şaşmaz, 2011)

Graf yönteminin doğru işletilmesi US görüntülerinde; muhtemel çekim hatalarını en aza indirip, standart planda görüntü alınmasına bağlıdır. Bunun yanında 3 ve 4. Tip çıkık kalçalarda standart planda görüntü elde edilemez. Değerlendirmenin doğru yapılabilmesi için standart planda görüntü doğru bir biçimde elde edilmeli ve sınıflandırmaların yapılabilmesi için açısız ölçüm yapılmalıdır. Yanlış tanı işlemi genelde standart plandaki en bilinen anatomik yapıların yanlış belirlenmesi sonucunda ortaya çıkmaktadır. Yatay görüntü yaklaşımı ile asetabulumdaki tüm bozulmaları göstermek ve standart planda ölçüm yapmak mümkündür. Standart planda üç referans noktasını görüntülemenin bazı zorlukları olmasına rağmen bu noktaların doğru belirlenmesi ile teşhisin doğruluğu orantılıdır. Teşhis işlemi sonrasında tedavi veya takipte oluşabilecek düzelmeler veya bozulmalar yine US tiplendirmesi ile yapılır (Şaşmaz, 2011).

Graf yönteminde kalçanın US olarak değerlendirme ve tiplendirilmesinde standart sonogram üzerinden ölçülen alfa ve beta açıları kullanılır. Elde edilen sonogramda 3 adet çizgi çizilir. İlium kemiği üzerinden iliak kanat kenarını içine alarak çizilen paralel çizgi I. çizgidir ve temel çizgi (base line) olarak isimlendirilir. Asetabuler derin noktayı (lower


limb) kemik köşenin tam kenarına teğet geçerek birleştiren çizgi II. Çizgidir ve kemik çatı çizgisi (roof line) olarak adlandırılır. Bu 2 çizgi arasında oluşan açı alfa açısıdır ve kemik çatı ölçümüdür. III. çizgi labrumun merkezinden asetabulumda konksiteye döndüğü noktaya çizilendir ve kıkırdak çatı çizgisi (inclation line) ismini alır. Temel çizgi ile kıkırdak çatı çizgisinin oluşturduğu açığa beta açısı denir. Beta açısı kıkırdak (labrum) ölçümüdür (Graf, 2006) (Şekil 2.10).



Şekil 2.10. Alfa ve beta açılarının bulunması

Belirlenen bu noktaların yardımıyla kalçalar tiplendirilir. Alfa açısı kemik çatı çizgisi ile bulunduğu için kemik çatı, beta açısı ise kıkırdak çatı çizgisi ile bulunduğu için kıkırdak çatı hakkında bilgi verir. GKD'li kalçalardaki alfa açısı değerlerinin düşük olduğu görülmekte ve klinik incelemelerde alfa açısı düşük kalçalar disloke edilebilir kalça olarak karşımıza çıkmaktadır (Şaşmaz, 2011).


US görüntülerinden GKD teşhisinde kullanılan Graf yönteminde dört farklı türde kalça vardır. Alfa açısı değerleri birincil ve teşhise yönelik gruplandırmada kullanılır. Beta açısı değerleri ikincil tiplendirmede (Tip 1a-1b ve Tip 2c-D ayrımında), bebeğin kaç aylık olduğu (Tip 2a-2b ayrımında), labral dejenerasyonun olup olmaması (Tip 3a-3b ayrımında) ve perikondriumun morfolojisi Tip 3-4 ayrımında kullanılır (Kapıcıoğlu ve ark., 2006) (Şekil 2.11).



Şekil 2.11. Graf sınıflandırmasına göre kalça tipleri (Kapıcıoğlu ve ark., 2006)

2.4.1. Tip I Kalça

Kalça eklemi 3 aylık bir bebek için yeterli kemikleşme oranına sahiptir yani olgundur. Kemik çatı iyi gelişmiştir. Kemik köşe açılı ve hafif künt (körelmiş) yapıdadır. Kıkırdak yapı femur başını tamamiyle sarmıştır (Graf, 2006). Kalça eklemi klinik ve radyolojik olarak normaldir. Takip ve kontrole gerek yoktur (Herring, 2003). Alfa açısı 60° veya üstündedir (Hedequist ve ark., 2003). Beta açısı 55° 'den düşük ise Tip I-A, 55° 'den yüksek ise Tip I-B olarak değerlendirilir (Şekil 2.12) (Kapıcıoğlu ve ark., 2006)




Şekil 2.12. Tip I kalçanın a) şematik ve b) US görüntüleri (Graf, 2006)

2.4.2. Tip II Kalça

Kalçanın kemik çatı gelişimi yetersiz ve merkezden kaymıştır. Kemik köşe hafifçe yuvarlaklaşmış ve asetabular çatı kıkırdakçı orantısız olarak büyümüş, hatta femur başını çevrelemiştir. Bu kapsama sayesinde kemik çatı femur başını sıkıca tutar (Graf, 2006). Üç aydan küçük bebeklerde alfa açısı 50° - 59° ise Tip II-A olarak belirlenir ve gelişmekte olan (immatür) kalça olarak takibe alınır. Üç aydan büyük bebeklerde ise aynı değerler Tip II-B olarak tanımlanır ve tedavi gerektirir (Kapıcıoğlu ve ark., 2006).

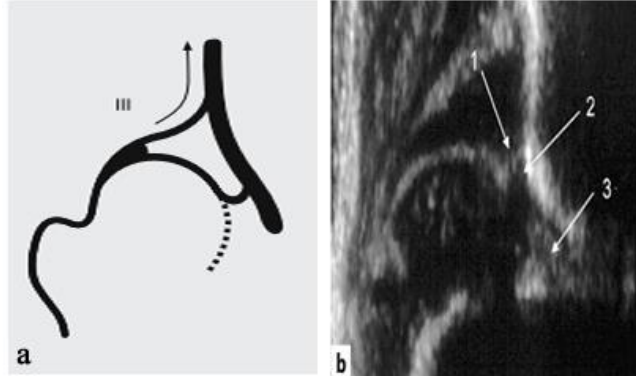
Alfa açısının 43° - 49° olduğu durumlarda Tip II-C ve Tip D ayırımında beta açısı değerleri ölçülür. Tip D kalça çıkık kalçanın ilk aşamasıdır. Tip II-B/C ve Tip D kalçalar, GKD'li kalçalardır. Tedavi altına alınmazlarsa çıkık riski yüksektir (Şekil 2.13) (Kapıcıoğlu ve ark., 2006).



Şekil 2.13. Tip II kalçanın a)şematik ve b) US görüntüleri 1. Labrum, 2. Kıkırdak bağlantı 3, Yerinden oynamış kıkırdak yapısı, 4. Kemik çatı (Graf, 2006)

2.4.3. Tip III Kalça


Kalça çıkıktır. Kemik çatı tam gelişmemiş sığ ve düzdür. Asetabulum femur başı ilişkisi tamamen bozulmuştur. Asetabular kıkırdak çatı çukurluğa doğru itilir, yani yukarı doğru yer değiştirir. Bu yüzden kıkırdakçı tam olarak asetabulum içerisinde kalması beklenemez. Zayıf kemik gelişiminden dolayı femur başı yerinden oynamıştır (Graf, 2006). Alfa açısı 43° 'den küçük ve beta açısı 77° 'nin üzerindedir. Femur başı ve iliak kanat arasında sıkışan kıkırdak çatıda bozulma yoksa (kıkırdak yapısı normal ve zayıf eko verir) Tip III-A olarak adlandırılır. Kıkırdak çatıda bozulma varsa Tip III-B olarak sınıflandırılır. Bu tür kalçalar hemen tedavi altına alınmalıdır (Şekil 2.14) (Kapıcıoğlu ve ark., 2006).



Şekil 2.14. Tip III kalçanın a)şematik ve b)US görünümü 1. Kıkırdak bağlantı, 2. Yerinden oynamış kemik köşe, 3. Boş asetabulumu dolduran yağ doku (Graf, 2006)

2.4.4. Tip IV Kalça

Kalça tamamen yerinden çıkmıştır. Femur başı kıkırdak çatı tarafından itildiği için orijinal asetabulumuna, laterale ve yukarıya doğru yer değiştirmiştir. Tip III ve Tip IV kalçalar çıkık kalçalardır. Tip III ve Tip IV kalçaları birbirinden ayırt etmek için perikardiyum incelenmelidir (Şekil 2.11-2.12). Alfa açısı 43° 'den küçük ve beta açısı 77° 'nin üstündedir. Labrum femur başının süperomedialinde ya da inferomedialinde femur başıyla temas halindedir. Kemik çatı tamamen düzleşmiştir, femur başını örtmez. Tip IV kalçada, yapısal değişiklikler sebebiyle, standart plandaki referans noktaları aynı sonogramda göstermek ve açı ölçümü yapmak çok zordur (Şekil 2.15) (Kapıcıoğlu ve ark., 2006).



Şekil 2.15. Tip IV kalçanın a)şematik ve b)US görünümü 1. Kıkırdak bağlantı, 2. Yerinden oynamış kemik köşe, 3. Boş asetabulumu dolduran yağ doku (Graf, 2006)

3. MATERYAL VE YÖNTEM

Bu bölümde çalışmada kullanılan materyal ve yöntemler hakkında bilgiler verilmiştir. Bu bilgiler kapsamında çalışmada kullanılan medikal veriler, uygulanan yöntemler ve yazılım altyapısından bahsedilmiştir.

3.1. Kullanılan Medikal Veriler

Çalışmada iki farklı bölümden alınan US görüntüleri kullanılmıştır. Bunlardan bir tanesi Selçuk Üniversitesi Tıp Fakültesi Radyoloji A.B.D.'dan alınan görüntüler, diğeri ise Bağcılar Eğitim ve Araştırma Hastanesinden alınan görüntülerdir. Her iki bölümde görüntülerin alınması için kullanılan US cihazı Toshiba Aplio 400 ultrason cihazıdır. Çekim sırasında kullanılan prob, 5-8 Mhz band genişliğine sahiptir. Görüntü kümesi, uzman radyolog doktorun gözetimi altında her bir görüntü kesiti tek tek incelenerek oluşturulmuştur. Standart sonogram formunda çekilmiş görüntülere ait radyoloji raporu kullanılarak görüntülerin doğru bir şekilde etiketlenmesi sağlanmıştır. Alınan ham görüntülerin yanında, uzman radyolog tarafından Graf yöntemine göre teşhis edilmiş görüntüler de bulunmaktadır.


Kalça bölgesi ham US görüntüleri gri seviye olup, 800x600 piksel boyutunda JPEG formatındadır. Görüntülerde hasta ismi, çekim teknik özellikleri gibi ilgisiz arka plan alanlar bulunmaktadır.

Tez çalışmasında kullanılmak üzere elde edilen ham US görüntüleri ve bu görüntünün uzman tarafından Graf yöntemine göre teşhis edilmiş hali için bir örnek Şekil 3.1'de verilmiştir.

Selçuk Üniversitesi Tıp Fakültesi Hastanesi'nden 10 hastaya ait 10 adet görüntü alınmış ve filtreleme aşamasında kullanılmıştır. Bu görüntülerin tümünde hastalar uzman tarafından GKD'siz olarak belirtilmiştir. Bağcılar Eğitim ve Araştırma Hastanesi'nden ise 50 adet görüntü alınmıştır. Bu görüntüler ise GKD teşhisinde kullanılmıştır. Tüm hastaların yaşları 0-3 ay arasında değişmektedir. 50 görüntü içerisinde 17 adedinde hastalar uzman tarafından GKD'li (Tip 2) olarak belirlenmiş, geriye kalan 33 adet hasta ise GKD'siz (Tip 1) olarak belirlenmiştir. Elde edilen görüntülerde cinsiyet ayırımına bakılmamıştır. Standart sonogram içerisinde Tip 1 ve Tip 2 belirlenebildiği için (Tip 3 ve Tip 4 sonogramda görüntülenemez) bu çalışmanın veri kümesinde 2 tür tip kullanılmıştır.



(a)



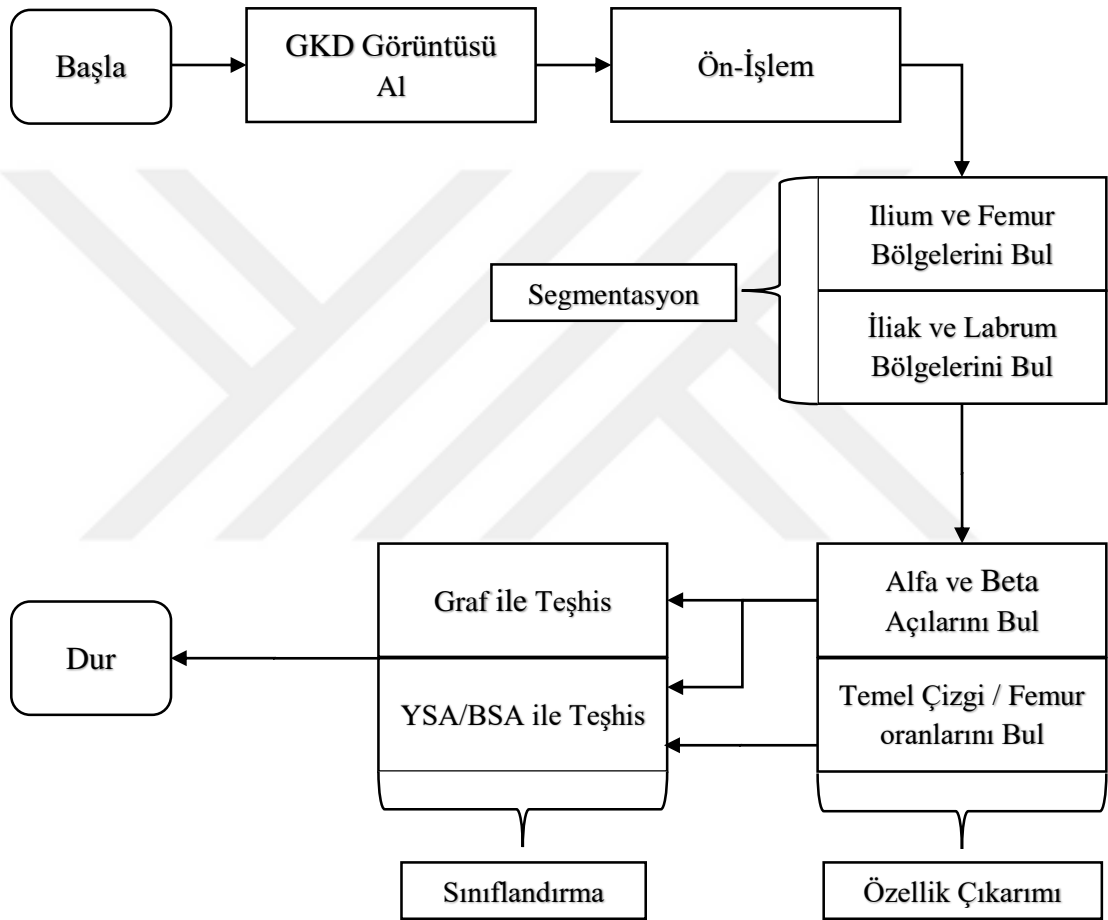
(b)

Şekil 3.1. Tez çalışmasında kullanılan US görüntüleri (Bağcılar Eğitim ve Araştırma Hastanesi)

a) ham görüntü b) teşhis edilmiş görüntü

3.2. Çalışmanın Aşamaları

GKD teşhisine yönelik yapılan tez çalışması beş aşamadan oluşmaktadır. Bunlar sırası ile görüntünün elde edilmesi, ön işlem, segmentasyon (görüntü içerisindeki gerekli bölgelerin belirlenmesi), özellik çıkarımı (belirlenen referans noktalarına göre ölçümlerin yapılması) ve sınıflandırma (GKD teşhisi) aşamalarıdır. Tez çalışmasının aşamalarını gösteren blok diyagram Şekil 3.2’de görülmektedir.



Şekil 3.2. Tez çalışmasının blok diyagram ile gösterimi

Ön işlem aşamasında ham olarak elde edilmiş olan US görüntüler üzerinde, gereksiz alanların atılması, gürültü giderme ve görüntü iyileştirilmesi gibi işlemler yapılmıştır. Bu aşamada literatürde görüntü kalitesinin artırılmasında kullanılan yedi farklı filtre (Frost, Gaussian, Lee, Ortalama, Ortanca, Perona Malik, Wiener) ham görüntülere uygulanmış ve sonuçlar test edilmiştir. Sonuçta GKD için US görüntülerinin

kalitesini artıran yöntemler belirlenmiş ve tezin diğer aşamalarına en çok yardım eden yöntemler kullanılmıştır. Bu sayede daha kaliteli ve temiz US görüntüleri elde edilmiştir.

Segmentasyon aşamasında hastalığın teşhisinde kullanılacak bölgelerin tespiti gerçekleştirilmiştir. Bu aşamada GKD teşhisinde gerekli olan değerleri elde etmek için görüntüde bulunan ilium, femur, asetabular çatı ve labrum bölgeleri belirlenmiştir. İlium, asetabular çatı ve labrum bölgelerinin belirlenmesinde Aktif Kontur Model (Active Contour Model) yöntemi kullanılmıştır. Femur bölgesinin tespiti için ise Dairesel Hough Dönüşümü (Circular Hough Transform) yöntemi kullanılmıştır.

Özellik çıkarımı aşamasında segmentasyon bölümünde bulunan bölgeler üzerinde Graf yönteminde kullanılacak olan alfa ve beta açıları belirlenmiştir. Bu çalışmada GKD teşhisine yeni bir yaklaşım olarak, uzman doktorun da görüşleri doğrultusunda temel çizginin femur dairesi üzerindeki izdüşümüne göre çizginin altında ve üstünde kalan bölgelerin alanlarının oranları yeni bir özellik olarak kullanılmıştır. Bu özellik, alfa ve beta açıları ile birlikte yeni özellik vektörünü oluşturmuş ve Yapay Sinir Ağları (YSA) sınıflandırmasında kullanılmıştır. Alfa ve beta açıları belirlenirken literatürde bilinen çeşitli morfolojik işlemlerden yararlanılmıştır.

Sınıflandırma işlemi iki şekilde yapılmıştır. Bunlardan ilki Graf yöntemi tiplendirmesidir. Graf yönteminde alfa ve beta açılarının değerlerine göre tiplendirme yapılmış ve sonuçlar değerlendirilmiştir. İkinci yöntem ise Graf yöntemine alternatif olarak sunulabilecek YSA sınıflandırma tekniğidir. Bu teknikte alfa, beta ve temel çizgi/femur oranı YSA'ya giriş olarak verilmiş ve ağ, geriye yayılım algoritması ile eğitilmiştir. Daha sonra YSA'nın test sonuçları değerlendirilmiştir. Ayrıca giriş verileri başka bir YZ yöntemi olan Bulanık Mantık ile bulanıklaştırılmış ve YSA ile sınıflandırma performansı test edilmiştir.

Burada bahsi geçen tüm yöntemler ilerleyen bölümlerde detayları ile açıklanmıştır.

3.3. Kullanılan Yazılım Altyapısı

Tez çalışmamızın görüntü işleme ve sınıflandırma aşamalarında Matlab 2014a ve Alyuda NeuroIntelligence paket yazılımlarından yararlanılmıştır. Deneysel çalışmalar 1.8 Ghz, i5 işlemcili ve 8 GB belleğe sahip bir bilgisayar üzerinde yapılmıştır. Matlab platformu üzerinde, tamamen bu çalışma kapsamında kodlanan GUI yazılımında; filtreleme, segmentasyon ve özellik çıkarımı işlemleri, görüntü işleme algoritmaları

kullanılarak gerekleřtirilmiřtir. Ayrıca grntlerin sınıflandırması kısmında yer alan Graf yntemi ile sınıflandırma iřlemi Matlab’da tasarlanan GUI yazılımında gerekleřtirilmiřtir. YSA ve BSA sınıflandırma yntemleri iin Alyuda NeuroIntelligence paket programı kullanılmıřtır. YSA giriřlerinin bulanıklařtırılması ařamasında Matlab Fuzzy Tool’dan yararlanılmıřtır.

alıřmanın her ařamasında iřlemleri gerekleřtiren programlarda, bařarımı artıracak veya sonu retecek bağımsız grnt iřleme kodları tarafımızdan yazılmıřtır.



4. GÖRÜNTÜLERİN FİLTRELENMESİ

Görüntü bir nesnenin görsel olarak sunulmasıdır. Görüntü işleme ise görüntü üzerinde çeşitli teknikler kullanılarak istenilen başka bir görüntü elde etme sürecine verilen addır. Görüntü işleme teknikleri; görüntünün insan veya bilgisayar tarafından anlaşılabilmesi veya yorumlanabilmesini sağlamak için kullanılır (Gonzalez ve Woods, 2002). Görüntü işleme analizi ve bilgisayar görmesi, son on yılda hem teorik hem de uygulama alanında çok büyük gelişmeler sergilemiş ve birçok teknolojik alanda uygulama imkânı bulmuştur. Sayısal haberleşme, internet, tıp, çoklu ortam sistemleri, biyoloji, malzeme bilimi, robotik ve akıllı algılama sistemleri en fazla ilgi gören alanlar olmuştur (Türkoğlu ve ark., 2003).

Ham görüntülerin daha belirgin ve anlaşılır hale getirilerek bir sonraki aşama için kolay işlenebilir hale getirilmesi sürecine ön işlem (pre-processing) denmektedir.

Ön-işleme yöntemlerinden bazıları şunlardır:

- Görüntüyü belirginleştirmek,
- Görüntüde bulunan kirlilikleri (gürültüyü) filtrelemek,
- Görüntü üzerindeki yapısal bozuklukları yok etmek veya minimize etmek.

Ön işleme ile sayısal haldeki görüntü üzerinde teşhisi zorlaştıran gürültü, zıtlık düşüklüğü gibi problemlerin ortadan kaldırılması amaçlanmaktadır. Bu sayede sistemin daha iyi sonuç vermesi sağlanmış olur. Bunun yanında teşhiste işe yaramayan özellikler azaltılır (Ünal, 2015).

Kalça bölgesi ham US görüntüleri gri seviye olup, JPEG formatındadır. Görüntüler 800x600 pikseldir ve görüntülerde ilgisiz arka plan alanlar bulunmaktadır. Tez çalışmasında öncelikle bu ilgisiz arka plan ortadan kaldırılmış ve görüntüler 520x420 piksel boyutunda kesilmiş ve gri seviye JPEG formatında düzenlenmiştir. US cihazından alınan görüntülerin boyut ve yerleşim değerleri sabit olduğu için bu işlem otomatik olarak gerçekleştirilmiştir (Şekil 4.1).

Çalışmada GKD teşhisi için kullanılan görüntüler US görüntüleme tekniği kullanılarak alınmıştır. US görüntüleme tekniği, yüksek frekanslı ses dalgaları prob vasıtasıyla deri üzerinden ölçümü yapılacak ilgili bölgeye gönderilip, yansıyan dalgaların ölçülmesi prensibine dayanmaktadır. Bu görüntüleme yönteminde, görüntü üzerinde çok sayıda ve çeşitte gürültü oluşabilmektedir. Görüntü üzerinde işlemler sırasında engel teşkil edebilecek bu gürültülerin giderilmesi amacıyla filtreleme uygulanmıştır.



(a)



(b)

Şekil 4.1. Tez çalışmasında kullanılan US görüntüleri a) ham görüntü b) ilgisiz alanlar atılmış görüntü

4.1. Gürültü

Gürültü, görüntü kalitesini bozan istenmeyen bilgileri temsil eder. Gürültü alınan görüntünün bir parçası olmayan fakat görüntüyü etkileyen bir süreç olarak tanımlanır. Gürültü modeli için Denklem 4.1'deki gibi bir genel tanım yapılabilir;

$$f(i,j) = s(i,j) + n(i,j) \quad (4.1)$$

Denklem 4.1'de $f(i, j)$ gözlenen görüntüyü, $s(i, j)$ gerçek görüntüyü ve $n(i, j)$ de gürültü bileşenini belirtmektedir. Burada i ve j görüntünün eksen değerlerini belirtmektedir.

Dijital görüntü gürültüsü çeşitli kaynaklardan gelebilir. Dijital görüntü elde edilme süreci, optik sinyallerin elektronik sinyallere dönüştürülmesi aşamasıyla gerçekleşir ve bu aralıkta elektrik sinyallerine bir miktar gürültü de eklenir. Bu dönüşüm sürecinde doğal olaylardan kaynaklanan dalgalanmalar ile her bir adımda rastgele piksel gürültüleri oluşmaktadır (Gonzalez ve Woods, 2002).

4.1.1. Gürültü Modeli

Gürültü orijinal görüntünün olasılık yoğunluk fonksiyonu (OYF) üzerine bindirilen bir histogram ile ya da bir OYF yoluyla modellenmiş olabilir. En yaygın gürültü modelleri olarak, Tuz ve Biber, Gaussian ve Benek görülmektedir (Gonzalez ve Woods, 2002).

Ultrason görüntüleme sistemi, yaygın olarak modern tıbbın kullandığı tanı araçları arasındadır. Kaslar, insan vücudu, büyüklüğü ve iç organların yapısı ve yaralanma gibi durumları görselleştirmek için kullanılır (Sarode ve Deshmukh, 2011). US görüntülemesinde oluşan gürültü modelleri; görüntüleme cihazı, kullanıcı becerisi, görüntüleme ortamı vb. gibi durumlara göre değişmektedir. Ancak genel anlamda bu alanda yapılan bilimsel araştırmalara bakarak denilebilir ki, US görüntülemeye Benek (Speckle), Tuz ve Biber (Salt and Pepper) ve Gaussian gürültüsünün diğerlerine oranla daha fazla oluştuğu gözlenmektedir (Meuwly ve ark., 2003; Bodzioch ve Ogiela, 2009; Narayanan ve Wahidabanu, 2009; Hafizah ve Supriyanto, 2011; Mahmood ve ark., 2011; Ciecholewski ve Chocholowicz, 2013). Bahsi geçen bu gürültülere ilişkin detaylar aşağıda verilmiştir.

4.1.2. Benek Gürültü

Görselleştirme işlemi yaparken bir ultrason görüntülemeye benek parazit varlığını kaçınılmazdır. Benek gürültü bir görüntüde rastgele ve deterministtir. Benek gürültü Ultrason görüntülerinde, manyetik rezonans (MR) görüntülerine göre daha fazladır. Tıbbi literatürde, benek gürültü desen (texture) olarak bilinir (Sarode ve Deshmukh, 2011).

Benek gürültünün genelleştirilmiş modeli Denklem 4.2'deki gibidir; (Thangavel ve ark., 2009)

$$g(n, m) = f(n, m) * u(n, m) + \zeta(n, m) \quad (4.2)$$

Denklem 4.2'de $f(n, m)$ gözlenen görüntüyü, $u(n, m)$ çarpımsal bileşeni ve $\zeta(n, m)$ de benek gürültü bileşenini belirtmektedir. Burada n ve m görüntünün dikey ve yatay eksen değerlerini belirtmektedir.

4.1.3. Tuz ve Biber Gürültü

Bu gürültü modelinde a ve b olarak tanımlanan iki olasılık mevcuttur ve bunların her birini elde etme olasılığı 1'den düşüktür (aksi halde gürültü görüntüyü tamamen kaplayabilir). 8 bit / piksel görüntü için biber gürültü tipik yoğunluk değeri 0'a yakın ve tuz gürültü 255'e yakındır (Şekil 4.2) (Gonzalez ve Woods, 2002).



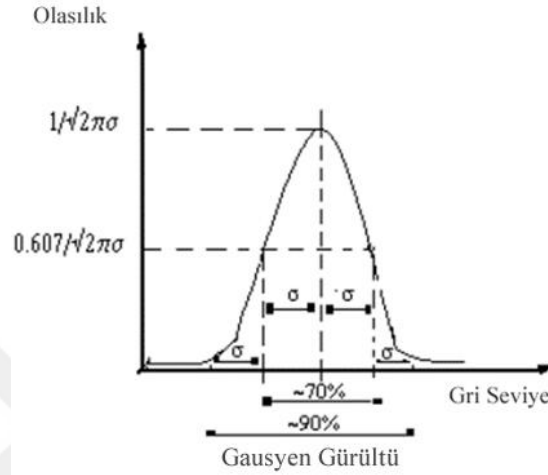
Şekil 4.2. Tuz ve Biber gürültü modeli için olasılık yoğunluk fonksiyonu

$$OYF_{tuz\&biber} = \begin{cases} A \text{ için } g = a(\text{"biber"}) \\ B \text{ için } g = b(\text{"tuz"}) \end{cases} \quad (4.3)$$

Tuz ve Biber gürültü genellikle arızalı kameraların sensor hücrelerinden, hafıza hücresi bozukluklarından veya görüntü aktarımı ve dönüşümü esnasındaki senkronizasyon hatalarından meydana gelmektedir. Ultrason görüntülerinde sıkça karşılaşılan bu gürültü çeşidi vücut içerisindeki dokulardan yansıyan gürültülerdir.

4.1.4. Gaussian Gürültü

Gaussian gürültü, normal Gaussian olasılık yoğunluk fonksiyonuna sahiptir. Bu fonksiyona ilişkin fonksiyon diyagramı Şekil 4.3'te, fonksiyonun matematiksel eşitliği Denklem 4.4'te verilmiştir.



Şekil 4.3. Gaussian gürültü modeli için olasılık yoğunluk fonksiyonu

$$OYF_{\text{Gaussian}} = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(g-\mu)^2}{2\sigma^2}} \quad (4.4)$$

Denklem 4.4'te yer alan g = gri seviye değeri, μ = ortalama ve σ = standart sapmadır. Değerlerin yaklaşık %70'i $\mu \pm \sigma$ aralığında, değerlerin %90 ise $\mu \pm 2\sigma$ dır. Teorik olarak böyle olmasına rağmen OYF, sıfır-hariç $+\infty$ ile $-\infty$ aralığında fonksiyon 0 ile $\mu \pm 3\sigma$ aralığındadır. Gaussian gürültü doğal işlem modellerinde (örneğin radyasyonun neden olduğu gürültü, optik sinyalin elektriksel sinyale dönüştürmekte veya sensör veya sinyal yükseltecinden elektriksel sinyal alırken) oluşabilmektedir (Gonzalez ve Woods, 2002).

4.2. Literatürde Sık Kullanılan Filtreleme Yöntemleri

Ultrason üzerinde görüntü işleme ile ilgili bilimsel araştırmalar incelendiğinde US görüntülerinde oluşan gürültülerin giderilmesine yönelik farklı yaklaşımlarda bulunulduğunu görmekteyiz. Bu yaklaşımlarda görüntü işlemede sıklıkla kullanılan filtrelemeler uygulanmış ve filtrelerin görüntü kalitesini iyileştirmeye olan etkisi

araştırılmıştır. Bu alanda yapılmış çalışmalar ve sonuçlarına ilişkin bilgiler aşağıda sunulmuştur.

Meuwly ve ark. (2003) yaptıkları çalışmada gerçek zamanlı US görüntülerinin kalitesini iyileştirme üzerinde durmuşlardır. Çalışmalarında akan görüntülere öncelikle Alçak Geçiren filtre ve Örnek Azaltımı işlemleri uygulamışlardır. Çıkış görüntüsü oluşturmak için ise Toplama ve Örnek Çoğaltımı işlemleri uygulamışlardır. Bu işlemler sonucunda görüntü kalitesinin arttığı, kenarların belirginleştiği ve gürültünün azaldığını gözlemlemişlerdir.

Bodziocha ve Ogiela (2009) yılında safra kesesi yaralarının US görüntüler ile analizine yönelik bir çalışma gerçekleştirmişlerdir. Çalışmalarının başarıya ulaşmasında gördükleri en büyük engelin görüntü kalitesi olduğunu belirtmişler ve kaliteyi artırmak için çeşitli yöntemler kullanmışlardır. US görüntülerini bir eşik değeri ile ikili (Siyah-Beyaz) görüntüye çevirmişler ve Rank filtresi uygulayarak kenar çıkarımı yapmışlardır. Bunun yanında işlenmemiş resim üzerinde Histogram Analizi ile kenar segmentasyonu yapmışlardır. Bu iki yöntemin kesişim değerlerini alarak, safra kesesinin yerini belirlemişlerdir. Çalışmanın sonuç bölümünde safra kesesi yeri belirlemede 30 örnek görüntü için başarı oranı %78 olarak belirtilmiştir.

Narayanan ve Wahidabanu (2009) yılında yaptıkları çalışmada US görüntülerinde leke temizleme yöntemlerini işlemişlerdir. US görüntülerinin gelişmesi için en önemli rolün görüntü kalitesi ve netliği olduğunu belirtmişlerdir. Yapay gürültülü görüntüler üzerinde Wiener, Ortanca, Adaptif Ortanca, Homomorphic, Lee ve Frost Filtreler, SRAD, Perona Malik, Bayes Eşikleme gibi filtreleme metotlarını kullanmışlardır. Yöntemlerin hangisinin daha uygun olduğunu belirlemek için standart sapma değerlerini kullanmışlardır.

Çizelge 4.1. Çeşitli filtreler uygulanmış US görüntülerinin standart sapma değerleri

Filtre	Standard sapma
Gürültülü Görüntü	0.2708
Wiener	0.2856
Ortanca	0.2812
Adaptif Ortanca	0.2916
Homomorphic	0.4083
Lee	0.2811
Frost	0.2776
Perona Malik	0.2874
SRAD.iterasyon=200	0.3192
SRAD.iterasyon=400	0.2984
Bayes Eşikleme	0.4261

Çizelge 4.1'e bakıldığında en düşük standart sapma değerlerine sahip 3 filtre sırasıyla ve Frost, Lee ve Ortanca olarak belirtilmiştir (Narayanan ve Wahidabanu, 2009).

2011 yılında Hafizah ve Supriyanto tarafından gerçekleştirilen çalışmada böbreğin US görüntülerinden segmente edilebilmesi için hangi tekniğin kullanılması gerektiği belirlenmeye çalışılmıştır. Çalışmalarında beş farklı temel görüntü iyileştirme tekniğini (Uzaysal domen filtreleme, frekans domen filtreleme, histogram eşitleme, morfolojik ve Wavelet filtreleme) kullanmışlardır. Bunların başarımını hesaplamak için ortalama kare hata (MSE) ve tepe sinyal-gürültü oranı (PSNR) değerini kullanmışlardır.

Çizelge 4.2. US böbrek görüntüleri için farklı görüntü iyileştirme teknikleri MSE ve PSNR

Geliştirme Teknikleri	MSE	PSNR[dB]
Doğrusal Olmayan Mekansal Alan Filtreleme		
• Ord filtre	0.0033	48.8461
• Ortanca filtre	0.00007	65.561
Alçak-Geçiren Filtre	0.00097	54.2179
Histogram Eşitleme		
• CLAHE	0.0235	40.3486
• Histeq	0.1003	34.0544
Morfolojik İşlemler	0.00006	66.6566
Wavelet Filtre	0.0801	35.0292

Çalışmada verilen Çizelge 4.2'ye bakılarak Ortanca Filtresinin görüntü iyileştirme tekniği olarak diğerlerine göre daha başarılı olduğu gözlenmektedir (Hafizah ve Supriyanto, 2011).

Mahmood ve ark. (2011), ortanca, yumuşatma, Wiener filtre işlemlerinin bağırsak daralması hastalığının US ile belirlenmesinde mide görüntülerinin segmentasyonuna etkisini araştırmışlardır. US cihazından alınan görüntüler sırasıyla ortanca filtre, otsu, morfolojik işlemler ve segmentasyon; yumuşatma, otsu, morfolojik işlemler ve segmentasyon işlemlerine tabi tutulmuştur. Morfolojik işlemler kısmında genleşme ve aşınma işlemleri kullanılmıştır. Segmentasyon işleminde Laplace metodu kullanılmıştır. Çalışmanın sonuç bölümünde belirtildiği üzere US görüntüsünü iyileştirmek ve gürültü azaltmak için çok fazla miktarda yöntem bulunmaktadır. Fakat bunlardan üç tanesi diğerlerine göre daha iyi sonuçlar vermektedir. Bunlar: ortanca, yumuşatma ve Wiener'dir. Bunların içerisinde bulanık görüntüleri de ayırt etme özelliği ile Wiener filtrenin en etkili olarak belirtilmiştir (Mahmood ve ark., 2011).

2013 yılında Ciecholewski ve Chochołowicz yayınladıkları makalede US görüntülerinden safra kesesinin belirlenmesi üzerine çalışmışlardır. US Görüntülerinin daha iyi anlaşılabilmesi için bazı ön-işlem adımlarından geçirmişlerdir. Ön işlem

aşamasında Gaussian filtreleme kullanılarak segmentasyon işlemi uygulanmış ve bu filtrenin etkisi araştırılmıştır. Gaussian filtrelemenin segmentasyonda olumlu etkilerinin olduğunu belirtmişlerdir (Ciecholewski ve Chocholowicz, 2013).

US görüntüleri üzerinde gürültü giderme ile ilgili yapılan araştırmalar incelendiğinde görüntülerde çoğunlukla benek, tuz ve biber ve gausyen gürültülerinin görüldüğü belirtilmiştir. Bu çalışmalarda uygulanan filtrelerin görüntü kalitesini iyileştirmesindeki etkisini ölçmek amacıyla standart sapma, MSE ve PSNR değerlerinin dikkate alındığını görmekteyiz. Yapılan bu çalışmalarda verilen sonuçlar analiz edildiğinde Ortalama, Ortanca, Perona Malik, Wiener, Gaussian, Lee ve Frost filtrelerinin gürültü gidermede diğerlerine oranla daha iyi sonuç verdiği görülmüştür. Dolayısıyla GKD teşhisine yönelik yaptığımız bu çalışmada yukarıda söz edilen 7 adet filtre US görüntülerine uygulanmış ve sonuçları değerlendirilmiştir. Bahsi geçen bu filtrelere ait teknik detaylar aşağıda verilmiştir.

4.2.1. Ortalama Filtresi

Ortalama (Mean) filtre görüntünün yumuşatılması için kullanılır. Pikseller ve komşuları arasındaki parlaklık farkının kapatılması esasına dayanır. Genellikle literatürde Alçak Geçiren filtre olarak bilinir (Şekil 4.4).

A	B	C
D	E	F
G	H	I

$$E' = 1/9 (A+B+C+D+E+F+G+H+I)$$

Şekil 4.4. 3x3'lük bir görüntüde ortalama filtre kullanımı

Ortalama filtre yerel varyansı, dolayısıyla da sinyal gürültü oranı (SNR) değerini azaltma özelliğine sahiptir. Bu yüzden genellikle birkaç filtre ile aynı anda kullanılması önerilmektedir (Narayanan ve Wahidabanu, 2009).

4.2.2. Ortanca Filtresi

Ortanca (Median) filtresi sırayla görüntüdeki her piksel ve onun yakın komşuları arasındaki ilişkiyi incelemektedir. Komşulukları belirlenen değerler sıralandıktan sonra ortanca değer bulunarak ortadaki piksel bu değer ile değiştirilir (Şekil 4.5). Ortanca filtre, görüntünün büyük kısmını koruyabildiği için bazı durumlarda ortalama filtreye göre daha iyi olduğu düşünülmektedir (Loupas ve ark., 1989; Hafızah ve Supriyanto, 2011). Ortanca filtre, uç değerler (aykırı değerler) için ortalamadan daha az duyarlıdır. Bu yüzden görüntünün keskinliği azaltıldığında, kenarları korumada daha iyidir (Mahmood ve ark., 2011).

123	125	126	130	140
122	124	126	127	135
118	120	150	125	134
119	115	119	123	133
111	116	110	120	130

Komşuluk Değerleri : 115, 119, 123, 125, 127,
126, 124, 120, 150
Ortanca değer : 124

Şekil 4.5. 3x3'lük bir görüntüde ortanca filtre kullanımı

4.2.3. Perona Malik Filtresi

Perona Malik (1990) çalışmalarında sürekli görüntüyü yumuşatmak için kısmi diferansiyel denklem önermiştir (Denklem 4.5). Perona Malik algoritmasının temel fikri, difüzyon operatörü yardımıyla kenarları kaybetmeden orijinal görüntüyü geliştirmektir (Wei, 1999).

$$\frac{\partial I}{\partial t} = \nabla \cdot [c(\|\nabla I\|)\nabla I], I(t = 0) = I_0 \quad (4.5)$$

∇ , diverjans operatörü, ∇I ise I görüntüsünün radyal büyüklüğü, $c(\|\nabla I\|)$ görüntüde yer alan kenar bilgisi içeren kısımlarda düşük değere sahip, genelleştirilmiş difüzyon katsayısı veya difüzyon işlevi ve I_0 'da orijinal görüntüdür. Eğer tüm görüntü için $c(\|\nabla I\|)$ fonksiyonu sabit ise, gradyal büyüklük azalacaktır. Genellikle bu yöntem bir sınır belirleme işlevi olarak kullanılır. Perona Malik yöntemi görüntüyü gürültülerden arındırırken kenar bölgelerinin korunmasını sağlamaktadır (Narayanan ve Wahidabanu, 2009).

4.2.4. Wiener Filtresi

Wiener, uyarlamalı bir filtre türüdür. Uyarlamalı filtreler, yerel görüntü varyansının uygun hale getirilmesinde kullanılır ve optimizasyona elverişlidir. Uyarlamalı filtre, görüntüdeki kenar ve diğer bölgeleri bulmada kullanılabilir ve sonuçta lineer filtrelerden daha seçicidir (Haykin, 2008). Çok miktarda gürültü meydana geldiğinde Wiener filtre gibi güçlü lineer bir filtre kullanılmaktadır. Wiener her bir pikselin yerel komşuluk yakınlığını inceleyen adaptif bir yöntemeye dayalıdır (Mahmood ve ark., 2011).

2-boyutta her bir (piksel) matris elemanı için varyans ve yerel ortalama hesabı yapılır (Denklem 4.6,4.7,4.8).

$$\mu = \frac{1}{MN} \sum_{n_1 n_2 \in n} f(n_1 n_2) \quad (4.6)$$


$$\sigma^2 = \frac{1}{MN} \sum_{n_1 n_2 \in n} f^2(n_1 n_2) - \mu^2 \quad (4.7)$$

$$b(n_1, n_2) = \mu + \frac{\sigma^2 - v^2}{\sigma^2} (f(n_1 n_2) - \mu) \quad (4.8)$$

Denklemlerde belirtilen n değerleri görüntü içerisindeki piksel değerleridir. f giriş görüntüsünü b ise çıkış görüntüsünü temsil etmektedir. σ standart sapmayı, v^2 'de gürültü varyansının belirtmektedir. Eğer gürültü varyansı (v^2) verilmişse, her bir topluluk ortalaması için varyanslar kullanılır. Wiener filtrenin daha iyi bir sonuç vermesi, istatistiksel anlamda uyumlu oluşundan ve filtre tipinin uyarlamalı olmasından kaynaklanmaktadır.

4.2.5. Gaussian Filtresi

Gaussian filtre makine görmesi, kenar belirleme, ölçekli alan sonuçları ve dijital verilere dayanan analog miktarların ölçülmesi gibi durumlarda araştırmacılar tarafından sıklıkla tercih edilmektedir. Gaussian filtre (f) giriş sinyali ile gaussian fonksiyonunun (f) konvolüsyonunu hesaplar ($Gf = g * f$) (Young ve Van Vliet, 1995). Tek boyutlu ve iki boyutlu olmak üzere iki farklı çeşidi vardır (Şekil 4.6).



Şekil 4.6. 1-D ve 2-D Gaussian filtresi

Burada σ değeri standart sapmayı belirtmektedir. x ve y ise görüntüdeki piksel koordinat eksen noktalarıdır.

4.2.6. Lee Filtresi

Lee filtresinde çıkış görüntüsü, filtre edilecek bölümün orta piksel yoğunluğunun görüntü yoğunluğu ile doğrusal kombinasyonu şeklide açıklanabilir. Lee ve Kuan filtreler sinyal modelleri varsayımları ve kökenleri farklı olmasına rağmen aynı formülasyona sahiptirler (Baraldi ve Parmiggiani, 1995). Bu filtreler homojen bölgelerdeki temel ortalamalar ile kenarlar ve öznitelik noktaları arasında dengeyi sağlamaktadır. Bu denge hareketli filtre bölümünün varyasyon katsayısına bağlıdır (Kuan ve ark., 1987). Denklem 4.9'da Lee filtresi ve ağırlıklandırma fonksiyonu gösterilmiştir. Denklem 4.10'da ise Kuan filtresi ve ağırlıklandırma fonksiyonu gösterilmiştir (Huang ve Van Genderen, 1996).

$$W(x, y) = 1 - \frac{C_{si}^2}{C_f^2(x, y)} \quad \hat{I} = I \cdot W + \bar{I}(1 - W) \quad (4.9)$$

$$W(x, y) = \frac{1 - C_{si}^2 / C_1^2(x, y)}{1 + C_{si}^2} \quad \hat{I} = I \cdot W + \bar{I}(1 - W) \quad (4.10)$$

Denklem 4.9 ve 4.10'da gösterilen C_{si} standart benek indis, C_1 deęişken benek indisi, x ve y görüntüdeki gri seviye piksel deęerleridir.

4.2.7. Frost Filtresi

Frost filtresi ortalama deęer ile tüm filtreden geirilmiş deęerler arasındaki dengeyi sağlar. Filtrenin yerel cevapları varyasyon katsayısı ile doğrudan ilişkilidir. Geliştirilmiş Frost filtresi ise eşik deęerine göre yerel performansı deęiştirmek için kullanılır. Varyasyon katsayısı daha düşük bir yerel eşik deęerinin altında olduğunda gürültüsüz ortalama uyarılır. Bu filtre varyasyon katsayısı daha yüksek bir yerel eşik üzerinde olduğunda, filtreler sertleşerek gerçekleştirir. Varyasyon katsayısı iki eşik arasında olduğunda, ortalama alma işlemleri ile belirleme çalışması arasında bir denge hesaplanır (Frost ve ark., 1982). Denklem 4.11'de Frost filtresi ve konvolüsyon çarpımı fonksiyonu gösterilmiştir (Huang ve Van Genderen, 1996).

$$W(x, y) = K_1 e^{-K_d C_1(x, y) \sqrt{x^2 + y^2}} \quad \hat{I} = I * W \quad (4.11)$$

Denklem 4.11'de gösterilen K_d sönümlenme faktörü, x ve y görüntüdeki gri seviye piksel deęerleridir.

4.3. Ön İşlem Yöntemlerinin Deęerlendirilmesi

GKD teşhisinde uzmanlar genellikle doğru açı ile yakalanmış görüntü içerisinde asetabulum ve femur bölgelerine bakarak karar verirler. En doğru sonucu alabilmek için görüntü içerisinde bu alanların açık bir şekilde görüntülenmesi gerekmektedir. Bu amaçla, görüntünün iyileştirilmesi ve gürültülerin giderilmesi için uygulanan filtrelerin görüntüye olan etkisinin ölçülmesi işlemi yapılmıştır. Ham görüntülere uygulanan filtrelerin deęerlendirmesi amacıyla farklı yöntemler izlenmiştir. Bunlar:


1. *Gözlemci Hassasiyeti*: Çıkış görüntülerinin insan gözü ile gözlenerek değerlendirilmesi.
2. *Görüntü Kalitesi İstatistiksel Ölçümü*: Çıkış görüntülerinin kalitesinin ortalama kare hata (MSE), tepe sinyal-gürültü oranı (PSNR) ve standart sapma (SS) değerlerine bakılarak değerlendirilmesi.
3. *Görüntü Segmentasyon Testi*: Çıkış görüntülerine bir segmentasyon metodu uygulanarak segmentasyon başarısının izlenmesi (Hafızah ve Supriyanto, 2011).


Selçuk Üniversitesi Tıp Fakültesi Radyoloji A.B.D.'dan alınan 10 adet US görüntüsü üzerine yukarıda bahsedilen filtreler uygulanmış ve bu filtrelerin etkileri yukarıda listelenen yöntemlere göre değerlendirilmiştir.

4.3.1. Gözlemci Hassasiyeti ile Değerlendirme

GKD görüntülerine uygulanan 7 adet filtreden elde edilen çıkış görüntüsü çıplak gözle değerlendirilmiştir. Değerlendirme kriteri olarak, giriş görüntüsünde yer alan gürültülerin ve resimdeki piksellerin parlaklık değişimleri dikkate alınmıştır. Her görüntü için gözlemciye ait değerlendirmeler not edilmiş ve tüm sonuçlar karşılaştırmalı olarak analiz edilmiştir.


Ham GKD görüntülerine (gürültü eklenmeden) uygulanan filtrelerin sonucunda elde edilen görüntüler Şekil 4.7'de verilmiştir.






Şekil 4.7. Ham görüntüler üzerine uygulanan filtreler (a) ham görüntü, (b) Frost filtresi, (c) Gaussian filtresi, (d) Lee filtresi, (e) Ortalama filtresi, (f) Ortanca filtresi, (g) Perona Malik filtresi, (h) Wiener filtresi

Gaussian gürültüsü eklenmiş GKD görüntüleri üzerinde uygulanan filtreler sonucunda oluşan görüntüler Şekil 4.8’de verilmiştir.




Şekil 4.8. Gaussian gürültülü ($\sigma_n = 0.02$) görüntüler üzerinde gürültü gidermek için uygulanan filtreler (a) ham görüntü, (b) Frost filtresi, (c) Gaussian filtresi, (d) Lee filtresi, (e) Ortalama filtresi, (f) Ortanca filtresi, (g) Perona Malik filtresi, (h) Wiener filtresi

Tuz ve Biber gürültüsü eklenmiş GKD görüntüleri üzerinde uygulanan filtreler sonucunda oluşan görüntüler Şekil 4.9'da verilmiştir.



Şekil 4.9. Tuz ve Biber ($\sigma_n = 0.02$) gürültülü görüntüler üzerinde gürültü gidermek için uygulanan filtreler (a) ham görüntü, (b) Frost filtresi, (c) Gaussian filtresi, (d) Lee filtresi, (e) Ortalama filtresi, (f) Ortaça filtresi, (g) Perona Malik filtresi, (h) Wiener filtresi

Benek gürültüsü eklenmiş GKD görüntüleri üzerinde uygulanan filtreler sonucunda oluşan görüntüler Şekil 4.10’da verilmiştir.



Şekil 4.10. Benek ($\sigma_n=0.05$) gürültülü görüntüler üzerinde gürültü gidermek için uygulanan filtreler (a) ham görüntü, (b) Frost filtresi, (c) Gaussian filtresi, (d) Lee filtresi, (e) Ortalama filtresi, (f) Oranca filtresi, (g) Perona Malik filtresi, (h) Wiener filtresi

Filtreleme sonrasında elde edilen görüntüler çıplak göz ile değerlendirildikten sonra not edilen analiz sonuçları şu şekildedir:

- Ham (gürültü eklenmemiş) GKD görüntülerinde Perona Malik filtre görüntünün netliğinde önemli kayıplara sebep olduğu, Wiener filtrenin ise gürültülerin giderilmesinde daha etkili olduğu gözlenmiştir.
- Gaussian gürültüsü eklenmiş GKD görüntülerinde Perona Malik filtrenin gürültü gidermede başarılı olduğu, diğer filtrelerin arasında göz ile fark edilebilir bir farklılığın olmadığı tespit edilmiştir.
- Tuz ve Biber gürültüsü eklenmiş GKD görüntülerinde Oranca filtrenin fark edilebilir seviyede başarılı gürültü gidermeye sahip olduğu, diğer filtrelerin arasında önemli bir farklılığın olmadığı tespit edilmiştir. Oranca filtrenin doğası

gereği Tuz ve Biber gürültüsünü yok etmede başarılı olacağı önceden de tahmin edilebilir.

- Benek gürültüsü eklenmiş GKD görüntülerinde Perona Malik filtre görüntünün netliğinde önemli kayıplara sebep olduğu, Wiener filtrenin ise gürültü gidermede diğerlerine oranla biraz daha etkili olduğu gözlenmiştir.

Bu değerlendirmeler yapılırken belirtilmesi gereken önemli bir husus, gözlemci hassasiyetindeki görsel değerlendirmenin göreceli olarak değişebilmesidir. Kişinin bakış açısı ve uzmanlık bilgisi görüntünün kalitesini değerlendirmede önemli faktörlerdir. Filtrelemelerden elde edilen GKD görüntülerinin analizleri genel anlamda değerlendirildiğinde, Wiener filtrenin diğerlerine oranla gürültü gidermede biraz daha öne çıktığı, Perona Malik filtrenin görüntünün netliğinde önemli kayıplara sebep olduğu gözlemlenmiştir.

4.3.2. Görüntü Kalitesi İstatistiksel Ölçümü

Literatürdeki çalışmalar incelendiğinde, görüntü kalitesinin istatistiksel olarak değerlendirilmesinde orijinal görüntü ve filtrelenmiş görüntüden elde edilmiş ortalama kare hata (MSE), tepe sinyal-gürültü oranı (PSNR) ve standart sapma (SS) değerleri kullanılmaktadır. Bu çalışmada da GKD görüntülerinin iyileştirilmesi amacıyla uygulanan filtre yöntemlerinin etkisinin araştırılmasında PSNR, MSE ve SS değerleri incelenmiştir.

Mean-Squared Error (MSE) (Ortalama Kare Hata) Denklem 4.12'deki şekilde tanımlanır;

$$MSE = \frac{\sum_{i=1}^M \sum_{j=1}^N |f(i,j) - \hat{f}(i,j)|^2}{MN} \quad (4.12)$$

$f(i,j)$ Orijinal görüntüyü, $\hat{f}(i,j)$ çıkış görüntüsünü ve MN ise görüntünün boyutunu temsil etmektedir.

Peak Signal-to-Noise Ratio (PSNR) (Tepe Sinyal-Gürültü Oranı) Denklem 4.13'deki gibi tanımlanır;

$$PSNR = 20 \log_{10} \left[\frac{(2^n - 1)}{\sqrt{MSE}} \right] [dB] \quad (4.13)$$

Burada, n kullanılan görüntü içerisinde temsil edilen bit sayısını belirtmektedir. Gri-seviye görüntü için $n=8$ 'dir (Hafızah ve Supriyanto, 2011).

Görüntünün yüksek PSNR değerine sahip olması, daha değerli sinyaller içerdiğini göstermektedir. Aynı şekilde düşük MSE değeri de görüntüdeki bozulmanın daha düşük oranda olduğunu belirtmektedir (Hafızah ve Supriyanto, 2011).

Standart sapma değeri (Standard deviation) Denklem 4.14'deki gibi tanımlanır;

$$SS = \sqrt{\frac{1}{N \times M} \left(\sum_{i=1}^N \sum_{j=1}^M (f(i,j) - \bar{f}(i,j))^2 \right)} \quad (4.14)$$

Denklemden N ve M değerleri görüntünün yükseklik ve genişlik değerleridir. $f(i,j)$ orijinal görüntüyü, $\bar{f}(i,j)$ ise filtreden geçirilmiş görüntüyü temsil etmektedir. Ayrıca i ve j değerleri ise görüntüdeki piksel adresleridir.

Görüntü kalitesinin istatistiksel değerlendirilmesinde, rastgele seçilen bir US görüntüsü ile tüm US (10 adet) görüntüleri (Ham, Gaussian, Tuz-Biber ve Benek görüntüsü eklenmiş) için ölçülen PSNR, MSE ve SS değerleri çizelge içerisinde sunulmuştur.

Çizelge 4.3. Ham görüntüler için PSNR, MSE ve SS değerleri

Filtre	Rastgele seçilen görüntü			On adet görüntünün ortalaması		
	PSNR	MSE	SS	PSNR	MSE	SS
Filtrelenmemiş	100	0	27.83	100	0	28.38
Frost	40.08	6.38	27.28	40.63	5.72	27.9
Gaussian	38.56	9.07	27.11	39.05	8.20	27.75
Lee	38.52	9.14	27.11	39.10	8.12	27.75
Ortalama	38.22	9.80	27.09	38.71	8.86	27.72
Ortanca	40.31	6.06	27.28	40.92	5.37	27.93
Perona Malik	30.57	56.99	25.34	31.12	50.67	26.02
Wiener	42.83	3.39	27.53	43.49	2.97	28.12

Çizelge 4.3'de ham görüntülere farklı filtreler uygulandıktan sonra oluşan PSNR, MSE, ortalama ve standart sapma sonuçları gösterilmiştir. Çizelgeye göre Wiener filtresi, en yüksek PSNR ve en düşük MSE değerine sahiptir. Bununla birlikte, Perona Malik filtresi en düşük SS değerine sahiptir.

Çizelge 4.4. Gaussian gürültü eklenmiş görüntüler için PSNR, MSE ve SS değerleri ($\sigma_n = 0.02$)

Filtre	Rastgele seçilen görüntü			On adet görüntünün ortalaması		
	PSNR	MSE	SS	PSNR	MSE	SS
Filtrenmemiş	18.51	915.43	27.83	18.51	917.40	28.38
Frost	23.62	282.41	27.62	23.58	285.21	28.07
Gaussian	26.06	161.16	25.2	25.97	164.42	25.74
Lee	26.02	162.67	25.15	25.96	164.82	25.7
Ortalama	26.05	161.54	25.2	26.00	163.58	25.7
Ortanca	25.25	194.17	29.02	25.29	192.56	29.5
Perona Malik	27.71	110.12	22.15	27.68	111.81	22.77
Wiener	24.35	238.98	26.98	24.31	241.27	27.48

Çizelge 4.4’de Gaussian gürültüsü eklenmiş görüntülere farklı filtreler uygulandıktan sonra oluşan PSNR, MSE, ortalama ve standart sapma sonuçları gösterilmiştir. Çizelgeye göre Perona Malik filtresi, en yüksek PSNR ve en düşük MSE ile SS değerine sahiptir.

Çizelge 4.5. Tuz ve Biber gürültü eklenmiş görüntüler için PSNR, MSE ve SS değerleri ($\sigma_n = 0.02$)

Filtre	Rastgele seçilen görüntü			On adet görüntünün ortalaması		
	PSNR	MSE	SS	PSNR	MSE	SS
Filtrenmemiş	20.93	524.38	27.83	20.99	518.20	28.38
Frost	26.69	139.23	29.11	26.58	142.91	29.68
Gaussian	29.99	65.14	27.65	29.68	70.01	28.24
Lee	29.83	67.56	27.7	29.66	70.33	28.25
Ortalama	29.84	67.48	27.69	29.68	70.12	28.24
Ortanca	41.74	4.35	27.29	40.60	5.78	27.93
Perona Malik	22.98	327.29	30.14	22.93	332.24	30.65
Wiener	21.74	435.97	33.85	21.74	435.83	34.28

Çizelge 4.5’de Tuz ve Biber gürültüsü eklenmiş görüntülere farklı filtreler uygulandıktan sonra oluşan PSNR, MSE, ortalama ve standart sapma sonuçları gösterilmiştir. Çizelgeye göre Ortanca filtresi, en yüksek PSNR ve en düşük MSE ile SS değerine sahiptir.

Çizelge 4.6. Benek gürültü eklenmiş görüntüler için PSNR, MSE ve SS değerleri ($\sigma_n = 0.05$)

Filtre	Rastgele seçilen görüntü			On adet görüntünün ortalaması		
	PSNR	MSE	SS	PSNR	MSE	SS
Filtrenmemiş	28.62	89.39	27.83	28.36	96.71	28.38
Frost	33.38	29.89	27.62	33.37	30.30	28.25
Gaussian	34.97	20.70	27.2	35.30	19.37	27.87
Lee	34.88	21.15	27.25	35.35	19.14	27.88
Ortalama	34.74	21.82	27.23	35.20	19.81	27.83
Ortanca	32.83	33.86	27.21	32.94	33.41	27.85

Perona Malik	30.30	60.63	25.46	31.26	49.11	26.09
Wiener	31.75	43.45	28.19	31.63	45.12	28.8

Çizelge 4.6’da Benek gürültüsü eklenmiş görüntülere farklı filtreler uygulandıktan sonra oluşan PSNR, MSE, ortalama ve standart sapma sonuçları gösterilmiştir. Çizelgeye göre Lee filtresi, 10 adet görüntünün ortalaması açısından en yüksek PSNR ve en düşük MSE değerine sahiptir. Bununla birlikte, Perona Malik filtresi en düşük SS değerine sahiptir.


Bu değerler incelendiğinde görüntüye uygulanan filtrenin kalitesi görüntünün çeşidine ve görüntüde bulunan gürültü türüne göre değişmektedir. Alınan sonuçlar değerlendirildiğinde **Wiener**, **Perona Malik** ve **Lee** filtreleri yüksek PSNR, düşük MSE ve düşük SS değerleri açısından ön plana çıkmaktadır. Ancak, **Wiener** filtresi ham (gürültü eklenmemiş) görüntülerde yüksek PSNR ve düşük MSE ile düşük SS değerlerine sahip olduğundan tez çalışmasında daha iyi çözüm sunması öngörülmektedir.

4.3.3. Görüntü Segmentasyon Testi

Çalışmanın bu aşamasında elde edilen GKD görüntüleri üzerine segmentasyon (bölütleme) yapılarak, filtrelerin etkisi ölçülmüş ve sonuçları değerlendirilmiştir. GKD teşhisinde kullanılmak üzere görüntü üzerinde ilium ve femur bölgelerinin belirlenmesi gerekmektedir. Görüntüye uygulanan filtrenin segmentasyon ile ölçülmesi kısmında, filtreleme aşamasında da kullanılan 10 adet GKD görüntüsü üzerinde çalışılmıştır. Bu aşamada ilium bölgesi segmentasyonu için Aktif Kontur Model (AKM) yöntemi, femur bölgesinin segmentasyonu için Dairesel Hough Dönüşümü (DHD) kullanılmıştır. Bu yöntemler, çalışmanın “Segmentasyon” ve “Özellik Çıkarımı” bölümlerinde detaylı bir şekilde açıklanmıştır.

İlk aşamada, tüm görüntülerin ilium bölgesi el ile segmente edilmiştir. Daha sonra segmente edilen ilium bölgesi için Merkez/M, En-Sağ/E-Sa, En-Sol/E-So noktaları tanımlanmıştır. Böylece filtre edilmemiş görüntülere ait değerler manuel olarak oluşturulmuştur (Şekil 4.11 a-b).

İkinci aşamada, filtrelenmiş görüntülere AKM yöntemi uygulanarak segmentasyon işlemi yapılmış ve ilium bölgesi için Merkez/M, En-Sağ/E-Sa, En-Sol/E-So noktaları otomatik olarak tespit edilmiştir (Şekil 4.11 c-d).



Şekil 4.11. GKD görüntüsü: a) elle segmente edilmiş görüntü, b) elle segmente edilmiş görüntüde E-Sa, E-So ve M noktaları, c) ham görüntü segmentasyonu, d) otomatik segmente edilmiş görüntüde E-Sa, E-So ve M noktaları.


Filtrelerin segmentasyon işlemi ile başarılarının ölçülmesi amacıyla bire bir karşılaştırma yapılmıştır. Manuel olarak bulunan E-Sa, E-So ve M noktalarına ait değerler, bilgisayar destekli olarak belirlenen E-Sa, E-So ve M noktaları ile karşılaştırılmıştır. Bu karşılaştırma işlemi için x-y koordinat düzleminde noktaların konum değerlerine bakılmış ve bulunması gereken nokta ile segmentasyon sonucu elde edilen nokta arasındaki fark değerlerine bakılarak % olarak benzerlik oranı hesaplanmıştır. Hesaplanan bu değerler on adet görüntü için bulunmuş ve bu değerlerin ortalamaları alınmıştır (Çizelge 4.7).

Çizelge 4.7. Görüntü segmentasyon testi sonuçları (Merkez/M, En-Sağ/E-Sa, En-Sol/E-So)

		Ham	Frost	Gaussian	Lee	Ortalama	Ortanca	Perona Malik	Wiener
1	M	96.10803	96.10656	96.12633	96.09667	96.09667	96.13771	95.26996	96.10656
	E-Sa	96	96	96	96	96	96	96.39445	96
	E-So	96.83772	96.83772	96.83772	96.83772	96.83772	96.83772	95.87689	96.83772
2	M	97.07781	97.08108	96.56815	96.54589	96.54589	96.56815	94.7487	97.08725
	E-Sa	97.17157	97.17157	97.17157	97.17157	97.17157	97.17157	97.76393	97.17157
	E-So	98	98	98	98	98	98	96.83772	98
3	M	88.8608	88.87343	88.91621	88.9244	88.89814	88.88991	89.90939	88.93951
	E-Sa	87.95841	87.95841	87.19375	87.19375	87.19375	87.19375	90	87.95841
	E-So	98	98	98	98	98	98	98	98
4	M	90.07169	90.62597	90.69148	90.63807	90.66238	90.96999	92.09718	90.08143
	E-Sa	84.9667	84.9667	84.9667	84.9667	84.9667	84.9667	95.75736	84.9667
	E-So	98.58579	98.58579	98.58579	98.58579	98.58579	98.58579	98.58579	98.58579
5	M	96.88377	96.90905	96.89839	96.89839	96.89839	96.89642	97.23204	96.90373
	E-Sa	95.87689	95.87689	95.87689	95.87689	95.87689	95.87689	95.87689	95.87689
	E-So	97	97	97	97	97	97	97	97
6	M	92.92745	92.71752	92.63755	92.59781	92.60756	92.66727	92.57644	92.80749
	E-Sa	94.34315	94.34315	94.34315	94.34315	94.34315	94.34315	94.34315	94.34315
	E-So	89.95012	89	89	89	89	89	87.95841	89.95012
7	M	92.59265	92.61307	92.61307	92.63305	93.12715	92.60307	92.01797	92.68256
	E-Sa	95.52786	95.52786	95.52786	95.52786	95.52786	95.52786	96.39445	95.52786
	E-So	89	89	89	89	89	89	87	88.95464
8	M	89.53652	89.57676	89.5965	89.60675	89.60675	89.49678	90.12975	89.61622
	E-Sa	97.17157	97.17157	97.17157	97.17157	97.17157	97.17157	95.75736	97.17157
	E-So	92	92	92	92	92	92	92	92
9	M	96.60975	96.60864	96.56889	96.45846	96.45846	96.47722	96.17772	96.60751
	E-Sa	98	98	98	98	98	98	97.76393	98
	E-So	93.91724	93.91724	93.91724	93.91724	93.91724	93.91724	92.92893	93.91724
10	M	93.90882	94.01421	93.98027	93.98027	93.98027	93.93195	93.66972	94.04815
	E-Sa	95.87689	95.87689	95.87689	95.87689	95.87689	95.87689	95.52786	96.39445
	E-So	93	91.456	91.456	91.456	91.456	91.75379	89.80196	91.05573
ORTALAMA		94.12537	94.06054	94.0174	94.01016	94.02689	94.02871	94.17993	94.08641


Segmentasyon sonrası belirlenen ilium bölgesinin merkez, en sağ ve en sol noktalarının el ile belirlenen ilium bölgesinde işaretlenmiş merkez, en sağ ve en sol noktalara olan uzaklıklara göre hesaplanan benzerlik oranları incelendiğinde Perona Malik filtresinin %94,17993 değeri ile en yüksek değere sahip olduğu görülmüştür. Bununla birlikte, çizelgedeki değerlerin birbirine olan yakınlıklarına dayanılarak, ilium bölgesi segmentasyonunda filtrelerin etki oranlarının çok fazla olmadığı gözlemlenmektedir.

İlium bölgesi tespiti yapıldıktan sonra bulunan ilium bölgesinden de faydalanılarak femur (çukurluk) bölgesi tespiti yapılmıştır. Femur bölgesinin tespitinde DHD yöntemi uygulanmış ve femur aday bölgeleri işaretlenmiştir (Şekil 4.12).



Şekil 4.12. DHD sonucunda elde edilen aday femur daireleri görüntüsü

Elde edilen aday dairelerden, femur bölgesi olması gereken dairenin belirlenmesinde ilium bölgesinin konumu göz önünde bulundurulmuştur. Bu aşamada aday femur dairelerinin ilium bölgesine olan uzaklığı, yatay ve dikey konumu ve daire boyutu verileri kullanılmış ve en uygun aday femur bölgesi olarak belirlenmiştir (Şekil 4.13).



Şekil 4.13. DHD bölütlemesi sonucunda bulunan femur dairesi

10 adet GKD görüntüsü için femur bölgesi tespitinde uygulanan filtrenin türüne göre başarı oranının değiştiği gözlemlenmiştir (Çizelge 4.8).

Çizelge 4.8. Femur bölgesi için görüntü bölütleme testi sonuçları

	Görüntü	Bölütlenen Görüntü	Başarım Oranı
Ham	10	7	%70
Frost	10	6	%60
Gaussian	10	7	%70
Lee	10	7	%70
Ortalama	10	8	%80
Ortanca	10	8	%80
Perona Malik	10	6	%60
Wiener	10	9	%90
Histogram E.	10	10	%100

Çizelge 4.8'deki değerlere dayanarak, Wiener filtrenin femur bölgesinin segmentasyonunda diğer filtreler göre daha başarılı olduğu gözlemlenmektedir. Bununla birlikte literatürde görüntü iyileştirme amacıyla sıkça tercih edilen histogram eşitleme işleminin femur bölgesinin tespitindeki etkisi araştırılmıştır. Bu amaçla GKD görüntülerine histogram eşitleme uygulanmış ve femur segmentasyonu tekrarlanmıştır. Bunun sonucunda görülmüştür ki, histogram eşitleme femur segmentasyonu aşamasında filtrelemelere oranla daha başarılı sonuç vermiştir (Çizelge 4.8).

Histogram eşitleme işleminin ilium, labrum ve asetabular çatı bölgelerinin bulunmasında etkisini görmek amacıyla, segmentasyon öncesi US görüntülerine histogram eşitleme uygulanmıştır. Bu görüntülere AKM segmentasyon yöntemi uygulandığında, özellikle parlak bölgelerin alan olarak genişlemesi sonucunda kenar haritalarının bozulması ve devamında dışa doğru genişleme işleminin bölgenin dışına taşmasına sebep olduğu görülmüştür. Bu durumda olması gerekenden daha büyük bir bölge işaretlenmiş ve segmentasyon işleminde başarı oranını düşürmüştür.

Ön işlem aşaması genel olarak değerlendirildiğinde;

- Wiener, Perona Malik ve Lee filtreleri istatistiksel ölçme değerlendirme verilerine göre görüntü kalitesini iyileştirmede en başarılı sonucu vermiştir.

- Görüntü segmentasyon testi (AKM yöntemi uygulanarak) sonuçlarına göre ilium bölgesi tespitinde Perona Malik filtresi el ile yapılan segmentasyon sonucuna en yakın değeri vermiştir.

- Görüntü segmentasyon testi (DHD yöntemi uygulanarak) sonuçlarına göre femur bölgesi tespitinde Wiener filtre en başarılı sonucu vermiştir. Bununla birlikte, histogram eşitleme yöntemi uygulandığında Wiener filtreye oranla femur bölgesi tespitinde daha başarılı sonuç alındığı gözlenmiştir.

5. SEGMENTASYON

Segmentasyon işlemi, bir görüntüde bulunması istenen bölgenin tespit edilmesine yönelik işlemleri içerir. Bu çalışmada da, ultrason (US) görüntülerinden gelişimsel kalça displazisi (GKD) teşhisinin yapılabilmesi amacıyla görüntüde yer alan ilium, femur, asetabular çatı ve labrum bölgelerinin tespit edilmesi gerekmektedir. Bu amaçla görüntülere aktif kontur model (AKM) metodu uygulanmış ve ilium, asetabular çatı ve labrum bölgeleri belirlenmiştir. Femur bölgesinin belirlenmesinde ise görüntülere histogram eşitleme ile birlikte dairesel Hough dönüşümü (DHD) uygulanmıştır. Ayrıca segmentasyon sırasında ve sonrasında referans noktalarının belirlenmesi için çeşitli morfolojik görüntü işleme yöntemlerinden de (aşınma, genleşme, açınım, kapanım, iskelet çıkarım, inceltme, budama, kalınlaştırma ve dal noktaları belirleme) yararlanılmıştır. Literatürde görüntü işleme amacıyla sıkça kullanılan bu morfolojik yöntemlerle birlikte gerek segmentasyon ve gerekse referans noktalarının belirlenmesi amacıyla kodlama esnasında özgün nitelikte algoritmalar yazılmıştır.

Tez çalışmasının bu bölümünde US görüntüleri üzerinde GKD teşhisinde gerekli olan bölgelerin belirlenmesinde kullanılan yöntemler anlatılmıştır.

5.1. Aktif Kontur Modeli (Active Contour Model)

Son on yıl içinde, aktif kontur modelleri yaygın olarak görüntü segmentasyonu aşamasında kullanılmaktadır. Aktif kontur modelin (AKM) temel fikri; genel eğri uydurma yöntemi olarak adlandırılan nesneye yakınsayan eğriler geliştirme olarak bilinir (Chenyang ve Prince, 1998; Chan ve ark., 2000; Chan ve Vese, 2001; Osher ve Fedkiw, 2006; Sapiro, 2006). Nesne etrafında segmente edilecek bir eğri seçilir ve daha sonra iç ve dış kuvvetlerin etkisine göre yakınsatma işlemi yapılır. Elde edilen eğrinin gösterimi söz konusu olduğunda ise AKM açık (Chenyang ve Prince, 1998; Chesnaud ve ark., 1999) ve kapalı (Chan ve Vese, 2001; Suri ve ark., 2002; Chunming ve ark., 2005) olarak ikiye ayrılır. Açık AKM'ye örnek olarak gelişen eğrinin açık gösterimi parametrik denklemlerle yapan temel yılan (Snake) model gösterilebilir (Chenyang ve Prince, 1998; Chesnaud ve ark., 1999). Kapalı AKM'ye örnek olarak ise belirli bir mesafe fonksiyonu ile parametrik olarak eğriyi değiştiren düzey kümeleri (Level Sets) modeli gösterilebilir (Osher ve Sethian, 1988; Malladi ve ark., 1995; Osher ve Fedkiw, 2006). Genel olarak kapalı AKM, açık AKM'ye göre topolojik deformasyonlarla başa çıkmada daha etkilidir.

5.1.1. Yılan Modeli (Snake Model)

Bu yöntem ilk olarak Michael Kass, Adrew Witkin ve Demetri Terzopoulos tarafından ele alınmıştır ve International Journal of Computer Vision da 1988 yılında yayınlanarak literatüre girmiştir (Kass ve ark., 1988). Öncelikle görüntüde el ile başlangıç noktaları belirlenir. Daha sonra belirlenen bu noktalar kullanılarak nesne bulunmaya çalışılır. Yılan model algoritması gerekli bölge tespitini otomatik olarak yaparken bu noktaları referans olarak çalışır.

Bu modelde elle belirlenen referans bölgesinin iki alanı bulunmaktadır. Bunlar iç bölge ve dış bölgedir. Bu bölgelerin birbirlerinden farklı enerjilerinin bulunduğu kabul edilmektedir. Program başlamadan önce bu iki enerjinin toplamının belirtilen değerden küçük olması sağlanmaktadır. Program sırasında bu değerden küçük olmayan enerjiler toplamı oluştuğunda; noktalar iç ve dış kuvvetlerin etkisiyle hareket ettirilir ve bu kuvvetler yeniden hesaplanır. Algoritma bu enerjiler toplamını azaltmaya yönelik olarak çalışmaktadır. Enerji fonksiyonu Denklem 5.1'deki gibi tanımlanır (Özkan, 2010);


$$E_{snake}^* = \int_0^1 E_{snake}(v(s))ds = \int_0^1 E_{int}(v(s)) + E_{image}(v(s)) + E_{con}(v(s))ds \quad (5.1)$$

E_{int} kapalı bölge içerisindeki eğim ve süreksizlikleri temsil eder, E_{image} görüntünün kuvvetini ve E_{con} kapalı bölgenin dış sınırlarını belirtmektedir. Görüntü kuvveti çeşitli olaylar olabilir (sınır hatları, kenarları vb). İç eğri enerjisi Denklem 5.2'deki formülle açıklanır; (Kass ve ark., 1988).

$$E_{int} = (\alpha(s)|v_s(s)|^2 + \beta(s)|v_{ss}(s)|^2)/2 \quad (5.2)$$

Denklem 5.2'deki, eğri etrafında boşluk olduğunda birinci dereceden terimler daha büyük değerlere sahip olmaktadır. Eğrinin büküm noktalarında ise ikinci dereceden terimler büyük değerler almaktadır. α ve β değerleri kapalı bölgenin genişleme veya daralması için gerekli olan parametrelerdir (Williams ve Shah, 1992).

Görüntüye göre iç ve dış enerji değerlerinin değişimi Şekil 5.1'de gösterildiği biçimde açıklanabilir.



Şekil 5.1. Yılan modelinde iç ve dış enerjiler

Şekil 5.1.a'da kapalı bölgenin iç ve dış enerjileri yüksektir. İç bölgenin çok kenar ve köşeye sahip olması enerjisini yükseltmektedir. Dış enerjinin yüksek olma sebebi ise belirlenen kapalı bölge kenarlarının şeklin kenarları ile örtüşmemesidir. Bu aşamada şart sağlanmadığı için algoritma yeniden çalıştırılır.

Şekil 5.1.b'de kapalı bölgenin iç enerjisi yüksek ve dış enerjisi düşüktür. İç bölgenin girintiler, çıkıntılar ve keskin hatlarının çok fazla olması enerjisini yükseltmektedir. Dış enerjinin düşük olma sebebi ise genel olarak şekilde beklenen hatlar ile bulunan hatlar uyuşmuş olmasıdır. Bu durumda da dış enerji olarak en düşük seviyeye ulaşılmasına rağmen iç enerji hala yüksek olduğu için algoritma yeniden çalıştırılır.

Şekil 5.1.c'de kapalı bölgenin iç enerji düşüktür. Dış enerji yüksektir. Dış enerji yüksek olduğu için istenmeyen bir durum oluşmuştur ve algoritma yeniden çalıştırılır.

Şekil 5.1.d'de kapalı bölgenin hem iç enerji hem de dış enerji düşüktür, çünkü görüntüde yer alan nesnenin sınırları doğru bir şekilde bulunmuştur, dolayısı ile beklenen arzu edilen sonuca algoritma ulaşmıştır. Algoritma sonlandırılır.

Yılan modelin algoritması dilsel olarak aşağıdaki şekilde açıklanır. Ayrıca yılan modelin algoritmasının akış şeması Şekil 5.2'de verilmiştir.

Adım 1: Başlangıç sınırları (Maske) belirlenir.

Adım 2: Sınırlar üzerinden iç enerji hesaplanır.

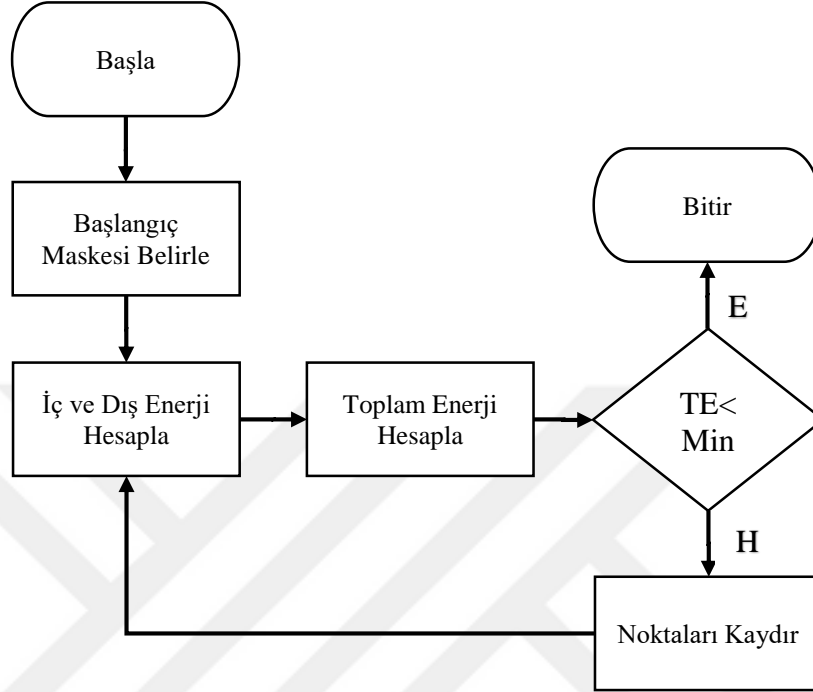
Adım 3: Dış enerji hesaplanır.

Adım 4: Toplam enerji hesaplanır.

Adım 5: Toplam enerjinin önceden tanımlanan bir minimum değere (bir parametre) ulaşip ulaşmadığı kontrol edilir. Minimuma ulaşmış ise işlem sonlandırılır.

Adım 6: Toplam enerjiyi minimize edecek şekilde iç ve dış kuvvetlerin boyutu ve yönüne göre noktalar içe doğru kaydırılır.

Adım 7: Sınırlar tekrar oluşturur. Adım 2'den devam edilir (Özkan, 2010).



Şekil 5.2. Yılan model algoritması akış şeması

5.1.2. Düzey Kümeleri Modeli (Level Sets Model)

Chan ve Vese tarafından sunulmuş olan sınırsız AKM farklı konularda birçok çalışmada kullanılmış olan başarılı bir bölütleme algoritmasıdır (Chan ve Vese, 2001). Eğri yayılımı, Mumford-Shah yöntemi ve düzey kümesi tekniklerine dayanmaktadır (Osher ve Sethian, 1988). Literatürde Chan-Vese (CV) AKM bölge-tabanlı segmentasyon algoritması olarak bilinir. Bu yöntem diğer kontur yöntemlerine göre gürültüye daha az duyarlıdır. Bu model diğer kontur modellerine benzer şekilde enerji değerlerini minimize edecek bir fonksiyon içermektedir. Yılan modelden ayırt edici özelliği iç hatları tespit ederken başlangıç değerlerine bağlı kalmadan hareket etmesidir. Hareketli bir eğri olan görüntüdeki yüzeyin sıfır düzey kümesi, görüntüde nesneyi algılar. Kapalı gösterimi sayesinde, bölme ve birleştirme gibi topolojik değişiklikler otomatik olarak tespit edilebilir. CV AKM yöntemine göre, bir görüntü, bu düzey fonksiyonu kullanılarak homojen bölgelere ayrılır. Bu bölgeler kapalı alan değerleri içeren görüntü parçalardan oluşmaktadır.

C-V algoritması C kapalı sınıрыyla ikiye ayrılmış olan u_0 resmine $F(c_1, c_2, C)$ enerji fonksiyonu tanımlamaktadır. Bu fonksiyon Denklem 5.3'deki gibi tanımlanır (Özmen, 2009).

$$F(c_1, c_2, C) = \mu \cdot Uzunluk(C) + v \cdot Alan(i\check{c}(C)) + \lambda_1 \int_{i\check{c}(C)} |u_0(x, y) - c_1|^2 dx dy + \lambda_2 \int_{dış(C)} |u_0(x, y) - c_2|^2 dx dy \quad (5.3)$$

Burada $\mu \geq 0, \lambda_1, \lambda_2 > 0$ ve sabit parametrelerdir. c_1 değişen C konturunun içinde kalan bölgenin ortalama değeri, c_2 ise dışında kalan bölgenin ortalama değerleridir. İlk terim; en son bulunan konturun gürültü nedeniyle küçük bir alan ile birleşmesini engelleyen regülarizasyon (düzeltme) terimidir. Son iki terim ise uydurma (fitting) terimleridir. Chan ve Vese düzey kümesi analizini kullanarak enerji fonksiyonunu yeniden Denklem 5.4'deki gibi tanımlanabilir (Osher ve Sethian, 1988).

$$(c_1, c_2, \phi) = \mu \int_{\Omega} \delta(\phi(x, y)) |\nabla \phi(x, y)| dx dy + v \int_{\Omega} H(\phi(x, y)) dx dy + \lambda_1 \int_{\Omega} |u(x, y) - c_1|^2 H(\phi(x, y)) dx dy + \lambda_2 \int_{\Omega} |u_0(x, y) - c_2|^2 (1 - H(\phi(x, y))) dx dy \quad (5.4)$$

$\phi: \mathbb{R}^2 \rightarrow \mathbb{R}$ iken; düzey kümesi koşullarını sağlamaktadır.

$$\phi(x, t) \begin{cases} x \in \omega(i\check{c}) \rightarrow > 0 \\ x \in \partial\omega = C(t) (sınırda) \rightarrow = 0 \\ x \in \Omega - \omega(dış) \rightarrow < 0 \end{cases} \quad (5.5)$$

$H(\phi)$ olarak tanımlanan Heaviside basamak fonksiyonu Denklem 5.6'da gösterilmiştir.

$$H(\phi) = \begin{cases} \phi \geq 0 \rightarrow 1 \\ \phi \leq 0 \rightarrow 0 \end{cases} \quad (5.6)$$

Ele alınan problem çözümü F enerji fonksiyonunu Euler-Lagrange eşitliği ile yinelemeli olarak en küçüklemeye (minimize edilmesine) dayanır. Bu eşitlik yalnızca ön plan ve arka plan bilgisinin tamamı ile birbirinden ayrıldığında sağlanmaktadır (Denklem 5.7) (Tunali ve Kilic, 2013).

$$\frac{\partial \phi}{\partial t} = \delta_\epsilon \left[\mu \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - v - \lambda_1 (u_0 - c_1)^2 + \lambda_2 (u_0 - c_2)^2 \right] = 0 \quad (5.7)$$

5.2. Hough Dönüşümü (Hough Transform)

Hough (1962) dönüşümü, Paul Hough tarafından tasarlanmış ve sonraları pek çok yazar tarafından geliştirilerek farklı görüntü işleme uygulamalarında kullanılmıştır. Hough dönüşümü, düz ve elips çizgilerin tespiti için son derece başarılı bir yöntemdir (Hough, 1962). Temel olarak siyah beyaz görüntülerdeki düzgün doğruları tespit etmek için geliştirilmiştir. Görüntüden yakalanabilecek olan şekiller arasında, düzgün doğrular, eğriler, çemberler ve elipslere ek olarak doğrusal olmayan keyfi dağılımlı düzensiz şekiller de yer almaktadır (Pınar, 2014).


Hough fonksiyonu, görüntüdeki sıfırdan farklı her bir noktayı (piksel) parametre uzayında bir sinüs dalgasına dönüştürür (Şekil 5.3). Tersine durumunda ise, parametre uzayında her bir nokta görüntüde bir düz doğruya karşılık gelir. Klasik dönüşüm, giriş görüntüsündeki doğruları saptamaya yöneliktir (Duda ve Hart, 1972).

Hough dönüşümü x, y düzlemindeki bir noktanın parametre uzayına dönüşümü olarak tanımlanabilir. Parametre uzayı ilgilenilen nesnenin şekline göre tanımlanır. x, y düzlemi üzerinde x_1, y_1 noktasından geçen bir doğru, Denklem 5.8'de gösterildiği şekilde ifade edilir; (Chaichana ve ark., 2008).

$$y_0 = ax_0 + b \quad (5.8)$$

Kartezyen koordinat sisteminde bir doğrunun denklemini ifade eden bu gösterimde a ile b doğrunun parametrelerini temsil eder. Yalnız doğrular için kullanılan Hough dönüşümünde bu denklem kullanılmaz. Çünkü x eksenine dik olan çizgiler sonsuz α değerine sahip olmaktadır. Bu da a, b parametre uzayının sonsuz boyutta olmasını gerektirir. Bunun yerine bir doğruyu temsil etmek için θ açısı ve ρ uzunluğuyla gösterilen doğrunun normali kullanılır. Parametre uzayındaki doğru denklemini Denklem 5.9'da verilmiştir (Chaichana ve ark., 2008).

$$\rho = x \cos \theta + y \sin \theta \quad (5.9)$$



Şekil 5.3. a) Düz bir doğrunun ρ ve θ gösterimi, b) görüntü uzayı, c) Hough uzayı

5.2.1. Dairesel Hough Dönüşümü (Circular Hough Transform)


Daireler, doğrulara oranla parametre uzayında daha basit bir şekilde ifade edilebilir. Çünkü dairenin parametreleri doğrudan parametre uzayına transfer edilebilmektedir. Bir daire denklemi Denklem 5.10'da gösterildiği şekilde ifade edilir.

$$r^2 = (x - a)^2 + (y - b)^2 \quad (5.10)$$

Denklem 5.10'da görüldüğü üzere dairenin a , b ve r olmak üzere üç parametresi vardır. Burada a ve b , x , y düzleminde dairenin yönünü, r ise çapını belirtmektedir. Dairenin parametrik gösterimi Denklem 5.11'deki gibidir.


$$x = a + r \cos(\theta), y = b + r \sin(\theta) \quad (5.11)$$

Bu nedenle dairenin parametrik uzayı R^3 'e ait iken, doğrunun parametrik uzayı R^2 'ye aittir. Şekli ifade eden parametreler arttıkça parametre uzayı R de artacaktır ve böylece Hough dönüşümü daha karmaşık bir hale gelecektir. Şekil 5.4'de dairesel Hough dönüşümü için kullanılan parametre uzayı gösterilmiştir. a , b ve r bu parametre uzayının parametreleridir. Çizilebilecek daireler a - b düzlemi üzerinde herhangi bir noktada merkeze sahiptirler. Dairenin yarıçapı olan r bilindiğinde ise bu daire parametre uzayı üzerinde çizilebilmektedir (Söylemez, 2012).



Şekil 5.4. Hough dönüşümü için kullanılacak parametre uzayı

Hough dönüşümü yardımıyla görüntüler üzerine daireleri bulmak için öncelikle şekil üzerinde radyal büyüklüğü (gradient of the magnitude) hesaplanır. Daire denklemine göre yatay ve dikey radyal büyüklüklerin hesaplanması ve ardından eşik değerinde radyal büyüklüğe sahip bölgelerde önceden belirlediğimiz yarıçap büyüklüğünde daireler çizilir. Bu çizim işlemi x eksenini a , y eksenini b ve yarıçap z olmak üzere parametre uzayında yapılır. Bu işlemden sonra parametre uzayı ile aynı büyüklükte bir matris olan akümülatör, çizilen dairenin koordinatları kullanılarak artırılır. Bütün kenar noktalarına bu işlemler uygulandıktan sonra dairelerin tespiti için akümülatör kullanılır. Akümülatörün içerisindeki sayılar o koordinattan geçen dairelerin sayısını göstermektedir. Buradaki en yüksek sayıyı içeren koordinat, dairenin merkezi olarak seçilmektedir. Şekil 5.5'te üç nokta ve sabit bir yarıçap yardımıyla yapılan Hough dönüşümü gösterilmektedir.




Şekil 5.5. Üç nokta ve sabit bir yarıçap yardımıyla yapılan Hough dönüşümü

Şekil 5.5'deki ilk bölümde bir dairenin kenarlarında yer alıp almadığı tespit edilecek olan üç nokta vardır. Gösterim açısından bir dairenin üzerinde olduğu resmedilmiştir. Bir sonraki örnekte merkezi bu noktalar olmak üzere aynı yarıçapta daireler çizilmiştir. Dairelerin en çok kesiştiği yer olan nokta üzerinde toplam 3 daire kesişmiştir ve Hough dönüşümünün sonucu olarak bu nokta, üç noktanın da üzerinde bulunduğu dairenin merkezi olarak belirlenmiştir (Söylemez, 2012).

Dairesel Hough bir görüntüden elde edilmiş kenarlar üzerindeki belirli bir yarıçap aralığına sahip dairesel örüntüleri tespit eder. Öncelikle görüntü uzayından elde edilen kenar örüntüleri üzerindeki her bir noktayı söz konusu yarıçapa sahip bir çemberin merkezi varsayarak bu yeni sanal çemberin üzerindeki her bir noktanın parametre uzayındaki değeri bir arttırılır. Bu işlem görüntü uzayındaki kenarların üzerindeki her bir nokta için uygulandıktan sonra parametre uzayındaki en yüksek değere sahip koordinatlar görüntü uzayında çemberimsi örüntülerin merkezi olarak belirlenmiş olur (Rizon ve ark., 2005; Chaichana ve ark., 2008).

5.3. Segmente Edilecek Bölgeler


Tez çalışmasında GKD görüntüleri üzerinde segmente edilmesi gereken bölgeler Şekil 5.6'da gösterilmiştir. Şekilde kırmızı ile belirtilen alan ilium bölgesi, sarı ile belirtilen alan labrum bölgesi, mavi ile belirtilen alan asetabular çatı bölgesi ve dairesel alan ise femur bölgesidir. Elle belirlenmiş bu alanlar çalışmamızda görüntü içerisinde otomatik olarak segmente edilmektedir. Bu alanlar kullanılarak ise GKD teşhisi yapılmaktadır.



Şekil 5.6. Görüntü içerisinde segmente edilmesi gereken alanlar

5.4. İlium Bölgesi Tespiti

Çalışmanın bu aşamasında GKD teşhisi amacıyla ilium bölgesinin tespitinde US görüntülerine aktif kontur model (AKM) uygulanmıştır. Uzmandan alından bilgiler ışığında, ilium bölgesinin en belirgin özelliği, US görüntüsü içerisinde beyaz piksellerin en yoğun olduğu bölgedir. Bu bölge, GKD teşhisi için alınan US görüntülerinde genellikle aynı bölgededir (resmin sol yarısında, orta bölgede). Yaptığımız incelemede resmin sol üst köşesi (0,0) referans noktası alınarak, (100,50) noktasından başlayarak aşağı-sağ yönde 100x200 boyutlarında bir alan kesilmiştir. Kesilen bu görüntü üzerinde eşikleme yapılarak görüntüde en beyaz piksellerin bulunduğu bölge tespit edilmiştir. Eşikleme için kullanılan eşik değeri 0.8'dir. Tespit edilen bu bölge referans alınmış ve AKM'in uygulanacağı başlangıç maskesi belirlenmiştir (Şekil 5.7).




Şekil 5.7. AKM başlangıç noktasının belirlenmesi

Başlangıç maskesi kullanılarak, AKM merkez noktasından adım adım dışarı doğru bölgesel genişleme yapar. Her adımda genişleyen bölgenin iç kuvveti ile bölgenin dışında kalan kuvvet karşılaştırılır ve bu iki kuvvet eşit olana kadar genişleme devam eder. Ancak bu durum bazı riskleri içermektedir. Zira bir kısıt konmadığı ve iç-dış kuvvetin eşitlenemediği durumda genişleme ilium bölgesinin dışına taşabilmektedir. Bu problemin üstesinden gelmek amacıyla adım sayısında sınırlama yapılmıştır. Yaptığımız denemelerde 400-500 adım arası ilium bölgesi tam olarak belirlenebilmektedir. Dolayısıyla AKM uygulaması 500 adımla sınırlandırılmıştır. AKM sonrası tespit edilen ilium bölgesine ilişkin görüntü Şekil 5.8.a' da verilmiştir.


İlium bölgesi işaretlendikten sonra bu bölge ilium haritası olarak ikili seviyeye aktarılmıştır (Şekil 5.8.b). Bu harita üzerinde birbiri ile bağlantısı olmayan her bir bölgede

piksel sayımı yapılmış ve 150 pikselin altında kalan bölgeler haritadan atılmıştır. Eğer birden fazla bölge kalmışsa, bu kalan bölgeler içerisinde piksel sayısı en fazla olan bölge ilium bölgesi olarak bırakılmıştır. Ardından, bu ikili seviyedeki harita üzerinde 25x25 piksel boyutlarında yapısal bileşen kullanılarak sırasıyla aşınma (Şekil 5.8.c) ve genişleme (Şekil 5.8.d) uygulanmıştır.



Şekil 5.8. İlium segmentasyonu a) AKM 500 iterasyonu b) segmentasyon sonucu c) aşınma işlemi d) genişleme işlemi


İlium bölgesinin sınırlarının tam olarak bulunabilmesi için Şekil 5.8.d'de segmente edilen görüntüden yararlanılmıştır. Bu alan ilgili US görüntüsünde başlangıç maskesi olarak kullanılmış ve AKM uygulanmıştır. Bu işlemde segmentasyon sonucu elde edilmiş olan ilium bölgesi maskesinde En-Sağ/R-E ve En-Sol/L-E noktaları referans alınmıştır. AKM işlemi sonrasında tahmini ilium bölgesi içerisinde kesin ilium şekli ortaya çıkartılmıştır (Şekil 5.9).



Şekil 5.9. Tahmini ilium bölgesi içerisinde ilium tespiti

GKD teşhisinde ilium bölgesinin femur yönünde ikiye ayrıldığı en uç nokta merkez nokta kabul edilerek asetabular çatı ve labrum bölgelerine çizilecek referans noktası olarak kullanılmaktadır. Bu çizgiler ile iliumda yer alan temel çizgi arasında kalan açılar teşhiste kullanılan alfa ve beta açıları olarak karşımıza çıkmaktadır.

İlium bölgesi belirlendikten sonra ilgili bölge ikili olarak haritalanmıştır. Bu harita üzerinde asetabular çatı ve labrum bölgelerinin belirlenebilmesi için referans noktasının bulunması gereklidir. Referans noktasının bulunması için ikili görüntü üzerinde inceltme, budama ve dal noktası belirleme (branchpoints) işlemleri uygulanmıştır (Şekil 5.10). Segmente edilmiş olan kesin ilium bölgesi yaklaşık olarak 150x50 piksel boyutlarındadır. Elde edilen çözünürlük değeri göz önüne alındığında uygulanacak morfolojik işlemler için 5x5 boyutunda yapısal bileşen kullanılmıştır.



Şekil 5.10. Referans noktası tespiti için yapılan morfolojik işlemler a) segmentasyon sonucu, b) inceltme işlemi sonucu, c) budama işlemi sonucu, d) dal noktası belirleme işlemi sonucu


Algoritmada öncelikle segmente edilmiş bölge inceltme (thinning) işlemine tabi tutularak birer piksellik çizgi haline getirilmiştir (iskelet çıkarım) (Şekil 5.10.b). Bu sayede görüntümüz dallardan oluşan bir yapıya bürünmüştür. İnceltme işlemi gerçekleştirilirken istenmeyen çıkıntıların oluştuğu görülmüş ve bu hatalı çıkıntıların elenmesi için görüntü budama (pruning) işlemine tabi tutulmuştur (Şekil 5.10.c). Son aşamada ise dal noktalarının belirlenmesi amacıyla budak noktası bulma (branchpoints)

işlemi yapılmıştır (Şekil 5.10.d). Bu işlemde kullanılan yapısal bileşen dört farklı açıda döndürülerek uygulanmış ve budak (çatalın başlangıcı) noktası belirlenmiştir (Şekil 5.11).




Şekil 5.11. Budak noktası bulma (branchpoints) işlemi için kullanılan yapısal eleman

Elde edilen referans noktası incelenmiş ve inceltme işleminden dolayı referans noktanın olması gerekenden daha içeride (femurdan daha uzakta) olduğu görülmüştür. Bu durum alfa ve beta açılarının olması gerekenden daha düşük çıkmasına sebebiyet vermektedir. Bunun üstesinden gelebilmek için elde edilen nokta, Şekil 5.12’de kırmızı renkte 1 numaralı işlemde gösterildiği gibi, y eksenini sabit kalmak şartı ile x ekseninde segmentasyon sonucunda siyah nokta gelene kadar sağa doğru hareket ettirilmiştir. Ancak bu işlem sonrası elde edilen referans noktası uzman ile birlikte tekrar incelenmiş ve referans noktasının ilium başı olarak tabir edilen yerden daha içeride olduğu gözlenmiştir. Bu hatayı düzeltmek amacıyla elde edilen referans noktası ve çevresi üzerinde AKM bir defa daha çalıştırılmış ve Şekil 5.12’de yeşil renkte 2 numaralı işlemde gösterildiği gibi, elde edilen segmente edilmiş görüntünün merkez noktası referans noktası olarak belirlenmiştir.



Şekil 5.12. Referans noktası belirlemede eksen kayması

Ekseni kaydırılmış kesin referans noktası segmente edilmiş bölgenin merkez noktasıdır. Bu bölgenin sağ üst ve sol üst noktaları tespit edilerek asetabular çatı ve labrum noktalarının belirlenmesinde kullanılmak üzere kaydedilmiştir (Şekil 5.13).

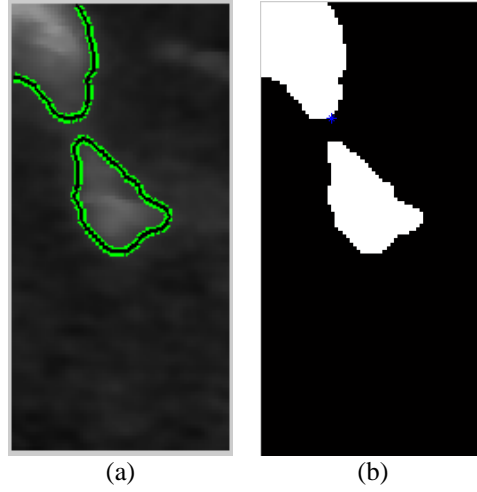


Şekil 5.13. İlium bölgesinde doğru referans noktasının belirlenmesi

Referans noktası doğru olarak tespit edildikten sonra bulunması gereken iki alan vardır. Bunlar asetabular çatı ve labrum'dur. Graf yöntemi için; Asetabular çatı alfa açısının belirlenmesinde, labrum ise beta açısının belirlenmesinde kullanılmaktadır.

5.5. Asetabular Çatı (İliak) Bölgesi Tespiti


İlium bölgesi tespitinde belirlenen referans noktası kullanılarak asetabular çatı (iliak) bölgesinde uç noktanın işaretlenmesi işlemi yapılmıştır. Bu işlemde öncelikle referans noktasından başlayarak içerisinde asetabular çatı bölgesinin yer aldığı geniş bir alan belirlenmiştir. Bu alanın belirlenmesinde referans noktası temel alınmıştır. Görüntüde yer alan referans noktasının alt sağ kısmında kalan 50x100 piksellik bir bölümü kullanılmıştır. Bu alan içerisinde referans noktası giriş maskesi olarak belirlenmiş ve AKM segmentasyonu uygulanmıştır. Segmentasyon sonucunda eğer iki şekil segmente edilmiş ise birinci şeklin en alt noktası, eğer tek şekil segmente edilmiş ise bu şeklin ağırlık merkezi noktası asetabular çatı noktası olarak işaretlenmiştir (Şekil 5.14).



Şekil 5.14. Asetabular çatı noktası tespiti a) segmentasyon sonucu b) nokta tespiti

5.6. Labrum Bölgesi Tespiti


İlium bölgesi tespitinde belirlenen referans noktası kullanılarak labrum bölgesinde uç noktanın işaretlenmesi işlemi yapılmıştır. Bu işlemde öncelikle referans noktasından başlayarak içerisinde labrum bölgesinin yer aldığı geniş bir alan belirlenmiştir. Bu alanın belirlenmesinde referans noktası temel alınarak, görüntüde yer alan referans noktasının y ekseninde 50 piksel yukarıdan başlayarak üst sağ kısmında kalan 100x100 piksellik bir bölümü kullanılmıştır. Bu alan içerisinde sağ üst bölge giriş maskesi olarak belirlenmiş ve AKM segmentasyonu uygulanmıştır. Segmentasyon sonucunda eğer tek şekil segmente edilmiş ise o şeklin sol üst noktası, eğer iki şekil segmente edilmiş ise bu şekillerden sağda olanın sol üst noktası labrum noktası olarak işaretlenmiştir (Şekil 5.15).



Şekil 5.15. Labrum noktası tespiti a) segmentasyon sonucu b) nokta tespiti


5.7. Femur Bölgesi Tespiti

Çalışmanın bu aşamasında, belirlenen referans noktasından faydalanılarak femur (çukurluk) bölgesi tespiti yapılmıştır. Öncelikle tüm resim üzerinden DHD yöntemi uygulanarak femur aday daireleri belirlenmiştir (Şekil 5.16).



Şekil 5.16. DHD sonucunda elde edilen aday femur daireleri görüntüsü

Daha sonra referans noktası temel alınarak görüntünün referans noktasının sağ kısmında kalan 200x200 piksellik bir bölümü kullanılmıştır (Şekil 5.17).




Şekil 5.17. DHD sonucunda tahmini femur bölgesindeki aday daireler

Elde edilen aday dairelerden, femur bölgesi olması gereken dairenin belirlenmesinde ilium bölgesinin konumu göz önünde bulundurulmuştur. Bu aşamada aday femur dairelerinin ilium bölgesine olan uzaklığı, yatay ve dikey konumu, daire

boyutu ve akümülatör değeri (dairenin merkez pikseli etrafındaki gri seviye yoğunluğu) verileri kullanılmış ve en uygun aday femur bölgesi olarak belirlenmiştir (Şekil 5.18).

En uygun femur dairesinin belirlenmesinde;

- Öncelikle dairenin merkez noktasının referans noktasından yatayda ve dikeyde en az 30 piksel uzaklıkta olması şartı aranmıştır.
- Daha sonra dairenin yarıçap bilgisinin 520x420 piksel boyutundaki görüntü içerisinde 55 ile 70 piksel aralığında olma şartına bakılmıştır.
- DHD yöntemi sonrasında belirlenen dairelerin akümülatör değerlerine bakılarak en yüksek değere sahip olan daire doğru femur bölgesi olarak belirlenmiştir.



Şekil 5.18. DHD bölütlemesi sonucunda bulunan femur dairesi

Çalışmada kullanılan 50 farklı GKD görüntüsü için femur bölgesi tespiti yapıldığında kullanılan filtrenin türüne göre başarı oranının değiştiği gözlemlenmiştir (Çizelge 5.1).

Çizelge 5.1. 50 adet GKD görüntüsü için femur bölgesi segmentasyonu

	Bölütlenen Görüntü	Başarı Oranı	Histogram Eş.	Başarı Oranı
Raw	30	%60	34	%68
Frost	32	%64	37	%74
Gaussian	33	%66	34	%68
Lee	30	%60	32	%64
Mean	37	%74	40	%80
Median	36	%72	42	%84
Perona Malik	31	%62	35	%70
Wiener	40	%80	48	%96


6. ÖZELLİK ÇIKARIMI

Özellik çıkarma, üzerinde karar verme veya sınıflandırma gibi işlemlerin yapılacağı bölgeye ait niteleyici bileşenlerin oluşturduğu vektörel kümenin elde edilmesidir. Bu aşama, karar verme aşamasından önce gelen ve doğru sonucun elde edilmesinde önemli bir etkiye sahiptir. Zira hatalı olarak elde edilecek bir özellik vektörü karar verme işleminin de hatalı olmasına yol açacaktır (Ünal, 2015).

Tez çalışmasının bu bölümünde US görüntüleri üzerinde sınıflandırma yöntemlerinin uygulanabilmesi için gerekli olan değerlerin belirlenmesi anlatılmıştır. Bu aşamada; bir önceki bölümde anlatılan, segmentasyon ile görüntü içerisinde belirlenen bölgelerden yararlanılarak Graf ve Yapay Zeka yöntemleri ile sınıflandırmayı sağlayacak değerlerin belirlenmesi sağlanmıştır. Graf yöntemi ile GKD teşhisi yapılması için gerekli olan değerler alfa ve beta açılarıdır. Yapay zeka yönteminde ise alfa ve beta açıları dışında temel çizgi/femur oranı değerleri de özellik vektörüne eklenmiş ve sınıflandırma işlemi yapılmıştır. Temel çizgi/femur oranı özellik bilgisi GKD teşhisinde ilk defa kullanılmıştır.

6.1. Alfa Açısının Belirlenmesi

Alfa açısının belirlenebilmesi için segmentasyon aşamasında belirlenen bölgelerden; temel çizgi, referans noktası ve asetabular çatı bölgesinden yararlanılmıştır. Referans noktası ile asetabular çatının bittiği nokta arasında kalan doğrunun temel çizgi ile oluşturduğu açı alfa açısıdır. Alfa açısının belirlenmesinde görüntü üzerinde; öncelikle referans noktası belirlenmiş (Şekil 6.1.a), sonra temel çizgi çizilmiş (Şekil 6.1.b), daha sonra asetabular çatı en alt noktası belirlenmiş (Şekil 6.1.c) ve bu nokta ile referans noktası ile arasında kalan doğru çizilmiştir (Şekil 6.1.d). Oluşan bu doğru literatürde kemik çatı çizgisi (roof line) olarak geçmektedir. Temel çizgi ile kemik çatı çizgisi arasında kalan açı ise alfa açısıdır.



Şekil 6.1. Alfa açısının belirlenmesi: a) referans noktası b) temel çizgi c) asetabular çatı en alt nokta d) kemik çatı çizgisi


50 adet görüntü için Şekil 6.1'deki tüm işlemler uygulanmış ve sonuçları Çizelge 6.1'de verilmiştir.

Çizelge 6.1. 50 adet GKD görüntüsü için alfa açısı değerleri

Görüntü No	Alfa Açısı	Görüntü No	Alfa Açısı	Görüntü No	Alfa Açısı	Görüntü No	Alfa Açısı	Görüntü No	Alfa Açısı
1	69	11	72	21	48	31	55	41	59
2	69	12	52	22	60	32	57	42	65
3	62	13	59	23	52	33	56	43	62
4	55	14	52	24	48	34	57	44	67
5	50	15	52	25	47	35	55	45	66
6	60	16	46	26	64	36	62	46	51
7	65	17	60	27	56	37	66	47	59
8	55	18	56	28	55	38	73	48	59
9	52	19	49	29	62	39	63	49	61
10	60	20	50	30	63	40	61	50	78

6.2. Beta Açısının Belirlenmesi

Beta açısının belirlenebilmesi için segmentasyon aşamasında belirlenen bölgelerden; temel çizgi, referans noktası ve labrum bölgesinden yararlanılmıştır. Referans noktası ile labrum bitiş noktası arasında kalan doğrunun temel çizgi ile oluşturduğu açı beta açısıdır. Beta açısının belirlenmesinde görüntü üzerinde; öncelikle referans noktası belirlenmiş (Şekil 6.2.a), sonra temel çizgi çizilmiştir (Şekil 6.2.b), daha sonra labrum bitiş noktası belirlenmiş (Şekil 6.2.c) ve bu nokta ile referans noktası ile arasında kalan doğru çizilmiştir (Şekil 6.2.d). Oluşan bu doğru literatürde kırkırdak çatı çizgisi (inclination line) olarak geçmektedir. Temel çizgi ile kırkırdak çatı çizgisi arasında kalan açı beta açısıdır.



Şekil 6.2. Beta açısının belirlenmesi: a) referans noktası b) temel çizgi c) labrum bitiş noktası d) kırkırdak çatı çizgisi


50 adet görüntü için Şekil 6.2'deki tüm işlemler uygulanmış ve sonuçları Çizelge 6.2'de verilmiştir.

Çizelge 6.2. 50 adet GKD görüntüsü için beta açısı değerleri

Görüntü No	Beta Açısı	Görüntü No	Beta Açısı	Görüntü No	Beta Açısı	Görüntü No	Beta Açısı	Görüntü No	Beta Açısı
1	63	11	64	21	59	31	67	41	78
2	56	12	59	22	69	32	45	42	55
3	63	13	52	23	65	33	40	43	66
4	39	14	51	24	55	34	48	44	69
5	66	15	53	25	55	35	67	45	49
6	63	16	72	26	55	36	74	46	47
7	59	17	73	27	41	37	65	47	77
8	53	18	59	28	53	38	72	48	60
9	58	19	38	29	76	39	67	49	81
10	62	20	53	30	60	40	56	50	58

6.3. Temel Çizgi / Femur Oranının Belirlenmesi

Temel çizgi/femur oranının belirlenebilmesi için segmentasyon aşamasında belirlenen bölgelerden; temel çizgi ve femur bölgesinden yararlanılmıştır. Görüntü üzerinde; öncelikle referans noktası belirlenmiş (Şekil 6.3.a), ardından temel çizgi çizilmiştir (Şekil 6.3.b), daha sonra femur bölgesi belirlenmiş (Şekil 6.3.c) ve en sonunda temel çizgi ile femur dairesi kesiştirilmiştir (Şekil 6.3.d). Bu kesişim sonucunda oluşan şekilde femur dairesinin görüntüsünün üst kısmında kalan bölüm üst alan yüzdesi, alt kısmında kalan bölüm alt alan yüzdesi olarak belirlenmiştir. Bu oran femur dairesinin yüzde oranıdır.




Şekil 6.3. Temel çizgi/femur oranının belirlenmesi: a) referans noktası, b) temel çizgi c) femur bölgesi d) temel çizgi / femur kesişimi

50 adet görüntü için Şekil 6.3'deki tüm işlemler uygulanmış ve sonuçları Çizelge 6.3'de verilmiştir. 50 görüntüden 4 tanesinde femur bölgesini işaretleyen daire çukurluk bölümü ile tam olarak örtüşmemiştir. 2 adet görüntüde ise femur dairesi temel çizgi dışında belirlendiği için alt ve üst bölge oranları belirlenememiştir. Dolayısıyla 48 adet görüntü için femur dairesi temel çizgi ile çakışmaktadır ve alt bölge ve üst bölge oranı çıkartılmıştır.

Çizelge 6.3. 50 adet GKD görüntüsü için temel çizgi/femur oranı değerleri

Görüntü No	Temel Çizgi/Femur			Görüntü No	Temel Çizgi/Femur		
	Hatalı	Üst %	Alt%		Hatalı	Üst %	Alt%
1		40	60	26	X	57	43
2		42	58	27		55	45
3		40	60	28		48	52
4		52	48	29		44	56
5		55	45	30		35	65
6		44	56	31		49	51
7		38	62	32		49	51
8		55	45	33		49	51
9	X	62	38	34		30	70
10		39	61	35		64	36
11		45	55	36	X	-	-
12		43	57	37		43	57
13		45	55	38		33	67
14		53	47	39		43	57
15		41	59	40	X	79	21
16		61	39	41		59	41
17		48	52	42		55	45
18		44	56	43		47	53
19		43	57	44		48	52
20		55	45	45		53	47
21		44	56	46		38	62
22		67	33	47		54	46
23		32	68	48		52	48
24	X	-	-	49		41	59
25	X	43	57	50		41	59

Tez çalışmamızın özellik çıkarımı kısmında US görüntüleri içerisinde GKD sınıflandırmasına kaynak oluşturacak alfa, beta açıları ve temel çizgi/femur oranı verileri belirlenmiş ve sayısal olarak değerleri bulunmuştur. Tüm özellik belirleme işlemi sonrası elde edilen sonuç görüntü Şekil 6.4’de verilmiştir.



Şekil 6.4. Özellik çıkarımı aşaması

Özellik çıkarımı aşamasında tespit edilen ilium, asetabular çatı, labrum ve femur bölgelerinden yararlanılarak temel çizgi, kemik çatı çizgisi ve kıkırdak çatı çizgileri ile femur bölgesindeki dairesel alan çizilmiştir. Temel çizgi ile kemik çatı çizgisi arasında kalan alfa açısı, temel çizgi ile kıkırdak çatı çizgisi arasında kalan beta açısı ölçümleri yapılmıştır. Ayrıca temel çizgi baz alınarak femur dairesinde, çizginin altında ve üstünde kalan alanlar da yüzde oran olarak hesaplanmıştır. 50 adet US görüntüsüne tüm bu işlemler uygulanmış ve Çizelge 6.4 deki değerler elde edilmiştir. Elde edilen bu veriler bir sonraki aşamada GKD teşhisi için kullanılmıştır.

Çizelge 6.4. 50 adet GKD görüntüsü için özellik çıkarımı sonucu

Görüntü No	Açılar		Femur			Görüntü No	Açılar		Femur		
	Alfa	Beta	Hatalı Bölge	Üst %	Alt %		Alfa	Beta	Hatalı Bölge	Üst %	Alt %
1	69	63		40	60	26	64	55	X	57	43
2	69	56		42	58	27	56	41		55	45
3	62	63		40	60	28	55	53		48	52
4	55	39		52	48	29	62	76		44	56
5	50	66		55	45	30	63	60		35	65
6	60	63		44	56	31	55	67		49	51
7	65	59		38	62	32	57	45		49	51
8	55	53		55	45	33	56	40		49	51
9	52	58	X	62	38	34	57	48		30	70
10	60	62		39	61	35	55	67		64	36
11	72	64		45	55	36	62	74	X	-	-
12	52	59		43	57	37	66	65		43	57
13	59	52		45	55	38	73	72		33	67
14	52	51		53	47	39	63	67		43	57
15	52	53		41	59	40	61	56	X	79	21
16	46	72		61	39	41	59	78		59	41
17	60	73		48	52	42	65	55		55	45
18	56	59		44	56	43	62	66		47	53
19	49	38		43	57	44	67	69		48	52
20	50	53		55	45	45	66	49		53	47
21	48	59		44	56	46	51	47		38	62
22	60	69		67	33	47	59	77		54	46
23	52	65		32	68	48	59	60		52	48
24	48	54	X	-	-	49	61	81		41	59
25	47	54	X	43	57	50	78	58		41	59

7. GELİŞİMSEL KALÇA DİSPLAZİSİ SINIFLANDIRMASI

Sınıflandırma, verilerde bulunan ortak özelliklere göre verilerin ayrıştırılması olarak tanımlanabilir. Görüntü sınıflandırma, görüntü veri setinden anlamlı sayısal konu haritaları üretme işlemidir. Sınıf, aynı türe ait görüntü elemanları ya da belli özelliklerle belirtilen alan türü olarak tanımlanmaktadır (Boran, 2006).

Çalışmamızın bu aşamasında GKD görüntüleri kullanılarak hastalık teşhisi (sınıflandırması) yapılmıştır. Bu sınıflandırma işlemi, US görüntüleri üzerinde yapılan ön işlem, segmentasyon ve özellik çıkarımı sonucunda ortaya çıkan veriler kullanılarak gerçekleştirilmiştir. Bu bölümde, sınıflandırma işlemi iki farklı yöntem ile yapılmış ve sonuçları tartışılmıştır.

Öncelikle literatürde bahsedilen ve kabul görmüş bir yöntem olan Graf yöntemi ile sınıflandırma yapılmış ve sınıflandırma sonuçları uzman tarafından belirlenen sonuçlar ile test edilmiştir. Daha sonra yapay zekâ (YZ) yöntemlerinden Yapay Sinir Ağı (YSA) ve Bulanık Sinir Ağı (BSA) kullanılarak bir sınıflandırma işlemi yapılmış ve test sonuçları uzman sınıflandırması ile karşılaştırılmıştır. Literatür incelendiğinde YZ tabanlı bir sınıflandırma yaklaşımı ile GKD teşhisine yönelik bir çalışmaya rastlanılmamıştır.

7.1. Graf Yöntemi ile Sınıflandırma


Graf yöntemi, yan yatırılan bebekte, trokanter majör üzerine ve vücut aksına paralel konulan transduser ile belirli anatomik noktaların standart planda görüntülenip, sonogram üzerinde ölçülen açılarla kalça eklemi morfolojisinin tiplendirilmesidir (Graf, 2006). Bu yöntemde, görüntü standart planda gösterilir ve kalça eklemi açılarının (alfa ve beta) değerine göre morfoloji belirlenir. Alfa ve beta açılarının değerine göre sınıflandırma Çizelge 7.1’de gösterilmiştir.

Çizelge 7.1. Graf sınıflandırmasına göre kalça tipleri

Alfa	Beta	Yaş	Tip I	Tip II
>60	<55	0-3 ay	1	A
>60	>55	0-3 ay	1	B
>50&<60	>55	0-3 ay	2	A
>50&<60	>55	3 aydan büyük	2	B
>43&<50	<77	0-3 ay	2	C
>43&<50	>77	0-3 ay	2	D
<43	>77	0-3 ay	3-4	-

Graf yönteminin uzman radyologlar tarafından uygulanmasında öncelikle Tip I değerine bakılarak hastanın GKD'li olup olmadığına karar verilmektedir. Eğer hasta GKD'siz ise Tip I için 1 değerine sahip olmaktadır. Eğer hasta GKD'li ise Tip I için 2,3 veya 4 değerlerine sahip olmaktadır. GKD'li hastanın hastalık derecesini belirlemek için Tip II değerlendirmesi yapılmaktadır. Örneğin, eğer hasta Tip I için 1 ise GKD'siz, Tip II için A ise tekrar kontrole gerek yok veya Tip II B ise tekrar kontrole gelmesinde fayda var olarak teşhis konulmaktadır. Tip I değeri 2, 3, 4 için ise hastaya tedavi uygulanmasına ihtiyaç olduğu ve Tip II değerine göre tedavi sürecinin yöntemi planlanmaktadır. Doktorların Graf yöntemini bu şekilde uygulamasından dolayı çalışmamızın sınıflandırma aşamasında iki farklı değerlendirme yapılmıştır. Elde edilen veriler kullanılarak veri kümemizde bulunan tip türlerinden sadece Tip I (1, 2) ve Tip I/Tip II (1/A, 1/B, 2/A) değerleri için birer sınıflandırma yapılmış ve sonuçları tartışılmıştır.

Çalışmanın özellik çıkarımı kısmında US görüntüleri için alfa ve beta değerleri belirlenmiştir. Bu alfa ve beta değerleri kullanılarak Graf yöntemine göre tiplendirmeler yapılmış ve sonuçlar kaydedilmiştir (Şekil 7.1).



Şekil 7.1. Alfa ve beta değerlerine göre Graf sınıflandırması

50 adet görüntü için alfa ve beta açısı değerlerine göre Graf sınıflandırması yapılmıştır. Elde edilen sonuçlar, radyoloji uzmanından alınan değerler ile karşılaştırılmıştır (Çizelge 7.2). Çalışmada kullanılan veri setinde Graf yönteminde bulunan tiplerde 1/A, 1/B ve 2/A sınıfları bulunmaktadır. Bu çalışmada kullanılan veriler 0-3 ay arası yeni doğan bebeklerden alındığı için Tip I değeri 2 olup alfa değeri 50 ve üzeri olanların Tip II değerleri A olarak belirtilmiştir. Çizelge 7.2.'de uzman değerlendirmesi ile uyuşmayan bilgisayar değerlendirmesi sonuçları kırmızı renk ile işaretlenmiştir. Sadece beta açısına göre hatalı bulunanlar ise yeşil renkte gösterilmiştir.

Çizelge 7.2. Graf sınıflandırmasına göre kalça tipleri

Görüntü No	Uzman Değerlendirmesi				Bilgisayar Değerlendirmesi			
	Alfa	Beta	Tip I	Tip II	Alfa	Beta	Tip I	Tip II
1	69	57	1	B	69	63	1	B
2	69	54	1	A	69	56	1	B
3	67	60	1	B	62	63	1	B
4	60	52	1	A	55	39	2	A
5	58	57	2	A	50	66	2	A
6	60	56	1	B	60	63	1	B
7	60	58	1	B	65	59	1	B
8	58	57	2	A	55	53	2	A
9	65	60	1	A	52	58	2	A
10	69	60	1	B	60	62	1	B
11	62	57	1	B	72	64	1	B
12	60	50	1	A	52	59	2	A
13	59	58	2	A	59	52	2	A
14	56	56	2	A	52	51	2	A
15	59	57	2	A	52	53	2	A
16	60	50	1	A	46	72	2	A
17	60	58	1	B	60	73	1	B
18	59	57	2	A	56	59	2	A
19	63	52	1	A	49	38	2	A
20	59	56	2	A	50	53	2	A
21	60	58	1	B	48	59	2	A
22	60	57	1	B	60	69	1	B
23	58	60	2	A	52	65	2	A
24	55	58	2	A	48	54	2	A
25	57	56	2	A	47	54	2	A
26	64	55	1	A	64	55	1	A
27	60	52	1	A	56	41	2	A
28	59	55	2	A	55	53	2	A
29	60	59	1	B	62	76	1	B
30	66	57	1	B	63	60	1	B
31	60	57	1	B	55	67	2	A
32	58	59	2	A	57	45	2	A
33	56	56	2	A	56	40	2	A
34	65	59	1	B	57	48	2	A
35	58	57	2	A	55	67	2	A
36	60	57	1	B	62	74	1	B
37	60	59	1	B	66	65	1	B
38	69	59	1	B	73	72	1	B
39	61	58	1	B	63	67	1	B

Görüntü No	Uzman Değerlendirmesi				Bilgisayar Değerlendirmesi			
	Alfa	Beta	Tip I	Tip II	Alfa	Beta	Tip I	Tip II
40	60	56	1	B	61	56	1	B
41	59	56	2	A	59	78	2	A
42	60	53	1	A	65	55	1	B
43	60	58	1	B	62	66	1	B
44	60	59	1	B	67	69	1	B
45	60	51	1	A	66	49	1	A
46	60	52	1	A	51	47	2	A
47	58	56	2	A	59	77	2	A
48	59	58	2	A	59	60	2	A
49	60	57	1	B	61	81	1	B
50	65	58	1	B	78	58	1	B

Çizelge incelendiğinde, Graf yöntemi sınıflandırmasına göre sadece Tip I değerine bakıldığında 50 adet US görüntüsünden 40 tanesinde uzman değerlendirmesi ile bilgisayar değerlendirmesi sonucu uyuşmaktadır. Tip I ve Tip II değerlerine birlikte bakıldığında ise 50 adet görüntüden 38 adedinde uzman değerlendirmesi ile bilgisayar değerlendirmesi uyuşmaktadır.

Çalışmamızda Graf yöntemi üzerinden GKD teşhisinde yalnızca Tip I temel alınarak sınıflandırma yapıldığında elde edilen başarı oranı %80'dir. Bununla birlikte, Tip I ve Tip II temel alınarak sınıflandırma yapıldığında ise elde edilen başarı oranı %76'dır.

Graf yöntemi ile GKD teşhisinde alfa ve beta açılarının keskin hatlarla birbirinden ayrılarak tiplerin belirlenmesi işlemi bazı sorunlara yol açmaktadır. 59 derecelik bir alfa açısının Tip 1 (GKD'siz), 60 derecelik bir alfa açısının ise Tip 2 (GKD'li) grubuna dahil edilmesi bu duruma örnek olarak verilebilir.

Graf yöntemi kullanılarak elde edilen sonuçlar değerlendirildiğinde; bu yöntemin keskin hatlarla tiplendirme yapmasından dolayı GKD'li-GKD'siz ayrımının küçük ölçüm hatalarını elimine edemediği görülmüştür. Dolayısıyla Graf yöntemine alternatif bir değerlendirme yönteminin gerekliliği oluşmaktadır.

7.2. Yapay Zekâ Yaklaşımı ile Sınıflandırma

Tez çalışmasının bu aşamasında; önceki bölümlerde bahsedilen GKD teşhisinde kullanılan Graf metodunun görüntü işleme yöntemleri teşhisinde ortaya çıkan sorunları gidermek amacıyla, öğrenme tabanlı bir yapay zekâ (YZ) sınıflandırma yaklaşımında bulunulmuştur.

YZ, bir bilgisayarın ya da bilgisayar denetimli bir makinenin, genellikle insana özgü nitelikler olduğu varsayılan akıl yürütme, anlam çıkartma, genelleme ve geçmiş deneyimlerden öğrenme gibi yüksek zihinsel süreçlere ilişkin görevleri yerine getirme yeteneği olarak tanımlanmaktadır (Nabiyev, 2005). YZ tekniklerinden yapay sinir ağları (YSA) özellikle sınıflandırma problemlerinde etkili bir çözüm sunmaktadır. Bununla birlikte yine YZ tekniklerinden bulanık mantık (BM) keskin geçişleri dilsel ifadeler kullanarak ara değerlere dönüştürme yeteneğine sahip olması sayesinde karmaşık problemlerin üstesinden gelebilmektedir.

Önişlem, segmentasyon ve özellik çıkarımı aşamalarının sonucunda US görüntülerinden elde edilen alfa ve beta açıları ile birlikte bu çalışmada önerilen temel çizgi/femur oranları değerleri BM ve YSA ile sınıflandırma işlemine giriş olarak verilmiş ve GKD teşhisi gerçekleştirilmiştir. Bu tekniklerin çalışma prensiplerine ilişkin bilgiler aşağıda verilmiştir.

7.2.1. Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları, insan beyninin işleyişini taklit ederek yeni sistem oluşturulmaya çalışılan yaklaşımlardır. Beynimizdeki biyolojik sinir hücrelerinin yapısı temel alınarak YSA yapısı oluşturulur. YSA’da aynen beynimizde olduğu gibi öğrenme ve öğrenilen bilgilere göre karar verme mekanizmaları bulunur (Allahverdi, 2002; Sağıroğlu ve ark., 2003; Öztemel, 2006; Elmas, 2007).

YSA alanında yapılan ilk çalışmalar McCulloch ve Pitts tarafından gerçekleştirilmiştir (McCulloch ve Pitts, 1943). Bu araştırmacıların yayınladığı “Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap” başlıklı makalede YSA konusunda ilk adım atılmıştır. İlerleyen zamanlarda Hebb (1952), Rosenblatt (1958), Widrow ve Hoff (1960), Hopfield (1982), Kohonen (1982), Rumelhart ve ark. (1986) ve daha birçok araştırmacı farklı YSA öğrenme algoritmaları geliştirmişlerdir.

Yapay Sinir Ağları, birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden (nöron) meydana gelmektedir. Temel olarak bir YSA’nın görevi, kendisine gösterilen giriş setine karşılık bir çıkış seti belirlemektir. Bunu gerçekleştirebilmek için ağ, ilgili problemin örnekleri ile eğitilerek (öğrenme), o problemle ilgili istenenleri çözebilme yeteneğine kavuşturulur. YSA’lar öğrenme, ilişkilendirme, sınıflandırma, genelleme, tahmin, özellik belirleme, optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır (Emir, 2013).

7.2.1.1. YSA'nın Genel Özellikleri

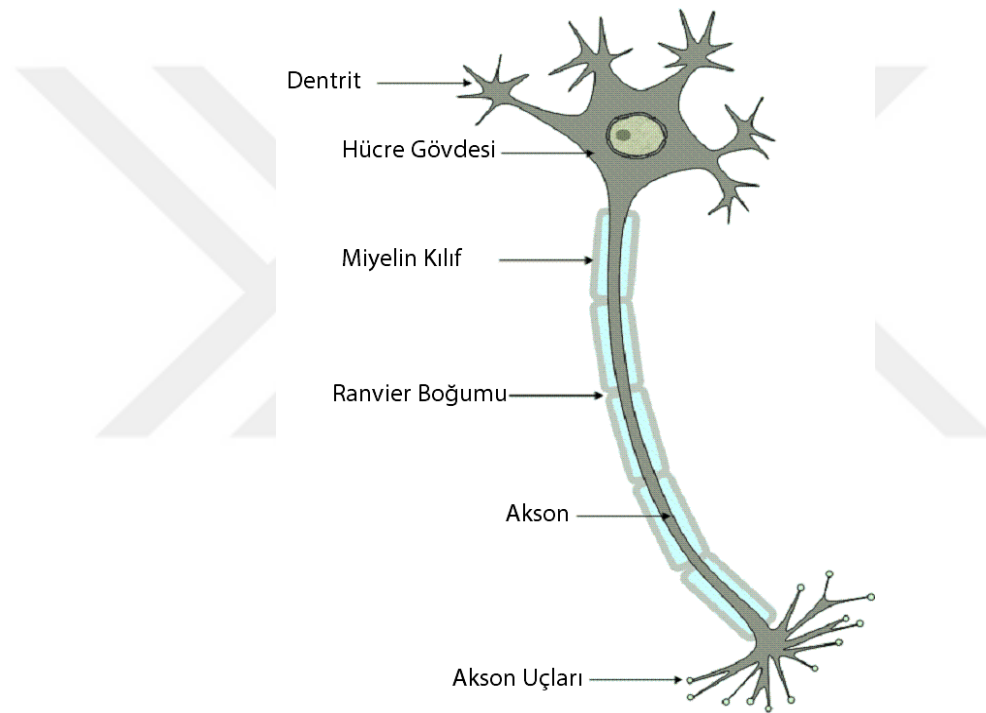
YSA'nın karakteristik özellikleri uygulanan ağ modeline göre değişebilmektedir. Genel karakteristik özellikler şunlardır: (Allahverdi, 2002; Sağıroğlu ve ark., 2003; Öztemel, 2006).

- Yapay sinir ağları öğrenme gerçekleştirirler. Olayları öğrenerek benzer olaylar karşısında benze kararlar vermeye çalışırlar.
- Bilgi geleneksel yöntemlere göre farklı biçimde saklanır. Bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Bir veri tabanı yoktur.
- Görülmemiş örnekler hakkında bilgi üretebilirler. Ağ kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler.
- Görüntü tanıma ve sınıflandırma yapabilirler. Kendisine örnekler halinde verilen görüntüleri işleyerek öğrenme yapar ve daha sonra gelen bir örneğin hangi sınıfa dâhil olduğuna karar verebilir.
- Kendi kendine organize olma yetenekleri vardır. Örnekler ile kendisine gösterilen durumlara adapte olup yeni olayları sürekli olarak öğrenebilmektedir.
- Eksik bilgi ile çalışabilir. YSA'lar eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmamasına rağmen sonuç üretebilirler.
- Hata toleransı özelliğine sahiptir. Eksik bilgilerle çalışabilmesi hatalara karşı toleranslı olmasını sağlar.
- Dağıtık bellek özelliğine sahiptirler. Yapay sinir ağında bilgi ağa yayılmış durumdadır.
- Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir.
- Sadece sayısal bilgi ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin sayısal bilgilere çevrilmesi gerekir (Koçer, 2007).

7.2.1.2. YSA Hücresi

YSA Hücresi biyolojik sinir hücresinden esinlenerek ortaya çıkartıldığı için öncelikle biyolojik sinir hücresinin yapısının bilinmesinde fayda vardır.

Biyolojik sinir: Bir insan beyninde, sayısı milyarı bulan biyolojik sinir (nöron)lar bulunmaktadır. Bu sinirler birbirlerine bağlı ve iletişim halindedirler. Biyolojik sinirlerin görevleri içerisinde en önemlisi bilgi iletişimini gerçekleştirmeleridir. Her bir nöronun aksonu ayrıştırılmıştır ve bir sinaps olarak adlandırılan bir kavşak vasıtasıyla diğer nöronların dendritlerine bağlanmıştır. Her bir nöronun diğer nöronlarla bağlantıya sahip olduğu bu yapı, biyolojik sinir ağı olarak adlandırılmaktadır. Bu çok geniş bir hesaplama gücü ve hafıza sağlamaktadır. Bir biyolojik nöron (sinir hücresi) temel olarak dört ana bölüme ayrılabilir. Bunlar; dendrit, soma, akson ve sinapslardır. Şekil 7.2’de biyolojik sinir hücresi görülmektedir (Ünal, 2015).



Şekil 7.2. Biyolojik sinir hücresi (Ünal, 2015)

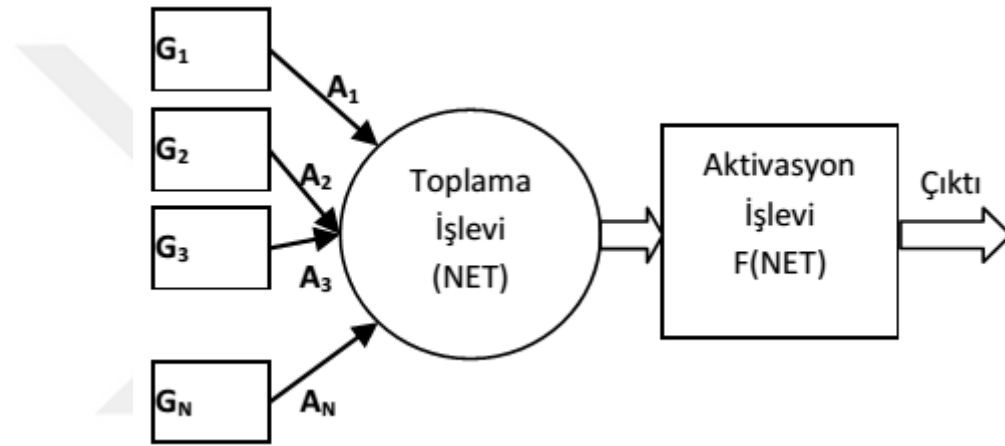
Girişler (Dendritler): Dendritler, kısa lifler olup diğer sinirlerden gelen bilgileri alan yapılardır.

Soma (Hücre gövdesi): Soma, gelen bilgileri toparlayan, birleştiren ve biçimini değiştirerek diğer sinirlere gönderen yapıdır.

Çıkış (Aksonlar): Aksonlar, uzun lifler olup bilgiyi diğer sinirlere transfer etmekte kullanılan yapılardır.

Sinapslar: Akson ile diğer bir nöronun dendritinin birleşme noktası sinaps olarak adlandırılır (Hacıfendioğlu, 2012).

Temel bir YSA hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. En temel nöron (hücre) modeli Şekil 7.3'de görülmektedir. YSA hücresinde temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler (girişler), ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır. Dış ortamdan alınan veri, ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Toplam fonksiyonu ise net girişi hesaplar. Net giriş; girişlerle, bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur. Aktivasyon fonksiyonu işlem süresince net çıkışı hesaplar ve bu işlem aynı zamanda nöron çıkışını verir. Genelde aktivasyon fonksiyonu doğrusal olmayan (nonlinear) bir fonksiyondur (Haykin, 1999).



Şekil 7.3. Bir yapay sinir hücresi

Şekil 7.3'de belirtilen; $G_1, G_2, G_3 \dots, G_N$ ile gösterilen girdiler bir YSA'nın girişleri olarak bilinir. $A_1, A_2, A_3 \dots, A_N$ ağırlıklar olarak tanımlanır ve yapay sinir hücresine gelen bilginin etkisini gösterir. Toplama işlevi fonksiyonu (NET) bir sinir hücresine gelen net bilgiyi hesaplar. Bu değeri bulmak için ağ yapısına göre maksimum, minimum ya da çarpım fonksiyonu gibi değişik fonksiyonlardan yararlanılmakla birlikte en çok kullanılanı Denklem 7.1'de gösterilen toplam ağırlığı bulan ifadedir. Burada G_i i. giriş değerini, A_i ise bu giriş değerinin ağırlığını ve NET ise fonksiyonun toplam değerini gösterir (Çevik ve Koçer, 2013).

$$NET = \sum_i^n G_i A_i \quad (7.1)$$

Yapay sinir hücresindeki aktivasyon işlevi fonksiyonu (FNET) hücreye gelen net girdileri hesaplayarak üretilen çıkış değerini belirler. Aktivasyon fonksiyonlarının

lineer fonksiyon, step fonksiyonu, sinüs fonksiyonu, eşik değer fonksiyonu, sigmoid fonksiyonu ve hiperbolik tanjant fonksiyonu olmak üzere değişik gösterimleri mevcuttur. Uygulamaların geneli çok katmanlı algılayıcı (ÇKA) biçiminde tasarlandığı için çalışmalarda genel olarak Sigmoid Fonksiyonu tercih edilmektedir (Öztemel, 2006). Bu fonksiyon Denklem 7.2'deki formülle gösterilir. Tez çalışmamızda kullanılan yazılımda, problemlerin çözümünde Sigmoid fonksiyonundan yararlanılmıştır.

$$F(NET) = \frac{1}{1+e^{-NET}} \quad (7.2)$$

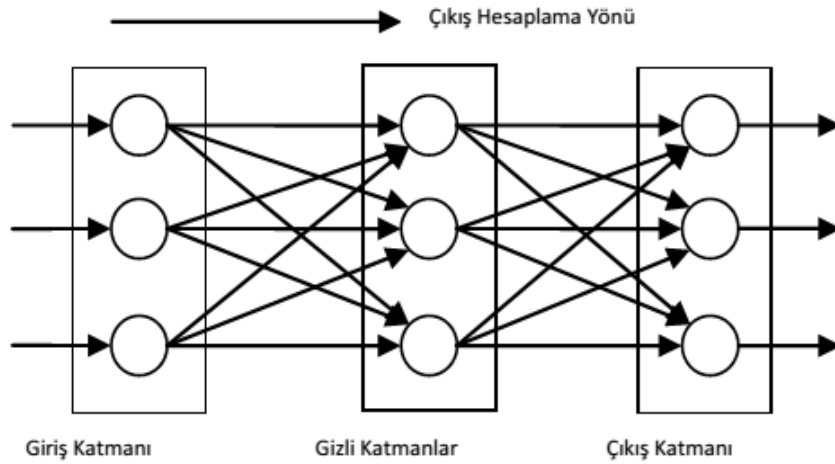
Proses elemanındaki *Çıktı* değeri de aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı ya başka hücreye ya da kendisine tekrar gönderilerek değerlendirilir. Temel olarak bir YSA'nın görevi, kendisine verilen giriş setine karşılık bir çıkış seti belirlemektir. Bunu gerçekleştirebilmek için ağ, ilgili problemin örnekleri ile eğitilerek (öğrenme), o problemle ilgili istenenleri çözebilme yeteneğine kavuşturulur (Kaastra ve Boyd, 1996).

Yapay sinir hücreleri, gerçek sinir hücrelerinin simüle edilmesiyle elde edilir. Yapay sinir hücreleri, aralarında bağ kurarak yapay sinir ağlarını oluştururlar. Yapay sinir hücrelerinin biyolojik sinir hücreleri ile olan benzerliğini şu şekildedir:

- Akson – Çıktı,
- Dentrit – Toplama Fonksiyonu,
- Çekirdek – Aktivasyon Fonksiyonu,
- Sinaps – Ağırlıklar (Yalçın, 2012).

7.2.1.3. YSA'nın Yapısı

YSA bir dizi sinir hücresinin ileri sürümlü ve geri beslemeli bağlantı şekilleri ile birbirine bağlanması ile oluşur (Haykin, 1999; Uğur ve Kınacı, 2006). YSA'da sinir hücrelerinin aynı doğrultuda bir araya gelmeleriyle YSA'nın katmanları meydana gelmektedir. Bir YSA'nın genel ağ yapısı Şekil 7.4'te gösterilmiştir.



Şekil 7.4. YSA' nın genel ağ yapısı

Giriş Katmanı: Bu katman sistemin girişidir. Girdiler ağa bu kısımdan giriş yaparlar. Giriş katmanında bir işlem yapılmadan girdiler, gizli katmana geçmektedir. Giriş katmanında her bir girdiye karşılık bir hücre bulunmaktadır. Buradaki hücreler birer giriş ve çıkışa sahiptir. Giriş katmanındaki hücreler gizli katmandaki bütün hücrelere bağlıdır.

Gizli Katmanlar: Giriş katmanından alınan veriler gizli katmana gelirler. Buraya gelen veri gizli katmandan işlenir ve kendisinden sonraki katmana aktarılır. Gizli katmandaki hücrelerin sayısı, girdi ve çıktı sayılarına bağlı olmaksızın değişebilir. Hücre sayıları farklı olabileceği gibi, YSA'daki gizli katman sayıları da farklı olabilir. Gizli katman sayısının ve buradaki hücre sayılarının artması, YSA'nın hesaplama sürelerini ve karmaşıklığını artırsa da, daha karmaşık problemleri çözebilmesini de sağlamaktadır (Ünal, 2015).

Çıkış Katmanı: Gizli katmandan aldığı veriyi işler ve girişten gelen girdilere uygun olarak çıktı üretir. Çıkış katmanında hücre sayısı tek olmak zorunda değildir. Çıkış katmanındaki her hücre, kendinden önceki katmanın her hücresine bağlı olmak zorundadır (Yalçın, 2012).

7.2.1.4. Yapılarına göre YSA

İleri beslemeli: İleri beslemeli YSA girişten çıkışa kadar düzenli katmanlar şeklindedir. Bu yapıda gelen bilgi, giriş katmanından ara katmana, ara katmandan da çıkış katmanına iletilir. Bir katman sadece kendinden sonraki katmanlar ile bağlantılıdır. İleri beslemeli YSA'da bir hücrenin çıktısı sadece kendisinden sonra gelen hücreye giriş

olarak verilir. İleri beslemeli ağlara örnek olarak, çok katmanlı algılayıcı (Multi Layer Perseptron – MLP), modüler sinir ağları (Modular Neural Networks – MNN), vektör kuantalamalı öğrenme (Learning Vector Quantization – LVQ), radyal tabanlı fonksiyon (Radial Basis Function – RBF) ve olasılık tabanlı (Probabilistic Neural Network – PNN) sinir ağları verilebilir

Geri Beslemeli: Geri beslemeli yapay sinir ağlarında ileri beslemeli olanların aksine bir hücrenin çıktısı sadece kendinden sonra gelen katmana girdi olarak verilmez. Kendinden önceki katmanda veya kendi katmanında bulunan herhangi bir hücreye girdi olarak verilebilir. Geri beslemeli YSA doğrusal olmayan dinamik bir davranış göstermektedir. Geri besleme özelliğini kazandıran bağlantıların bağlantı şekline göre geri aynı YSA ile farklı davranışta ve yapıda geri beslemeli YSA elde edilebilir. (Kakıcı, 2009). Geri beslemeli ağ modeline örnek olarak Hopfield, adaptif rezonans teori (ART), kendi kendine organize olabilen harita (Self Organizing Map – SOM) ağları, Elman ve Jordan ağları verilebilir.

7.2.1.5. Öğrenme Algoritmalarına göre YSA

Danışmanlı: Bu yapıdaki ağlarda problemin öğrenilebilmesi için bir öğretmene, yani danışmana ihtiyaç vardır. Danışmanlı sisteme öğretilmesi istenilen problemin örnekleri girdi-çıkı veri seti olarak verilir. Yani sisteme problem ile ilgili örnek giriş ve bu giriş sonucunda ortaya çıkacak sonuç bilgisi verilir. Burada ağın işi verilen girişlere göre danışmanın verdiği çıkışları bulabilmektir. Bu sayede problemin girdileri ile çıktıları arasındaki ilişkiler öğrenilmektedir (Öztemel, 2006).

Danışmansız: Bu sistemde öğrenmeye yardımcı olan herhangi bir danışman veya öğretici yoktur. Sisteme sadece girdiler verilir, örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendine öğrenmesi beklenir. Danışmanlı öğrenmeye göre çok daha hızlıdır ve matematik algoritmaları daha basittir. ART (Adaptif Rezonans Teori) ağları örnek olarak verilebilir (Yalçın, 2012).


YSA' da hücre eleman bağlantılarının ağırlık değerlerinin belirlenmesi işleme ağın eğitilmesi denir. Başlangıçta bu değerler rastgele belirlenir. Ancak daha sonra çıktı değerlerine göre bu ağırlık değerleri tekrar tekrar değiştirilerek gerçek durumuna erişir (Haykin, 2008). Eğitim verisinin tamamlanmasından sonra eğitilmiş olan ağ, ağırlık değerlerinin son durumuna göre, verilen herhangi bir veri setinin sonucunu tahmin edebilmektedir (Haykin, 1999; Uğur ve Kınacı, 2006). Buna da ağın öğrenmesi denir.

Ağın öğrenmesine referans olarak gösterilen farklı öğrenme modelleri vardır (Haykin, 2008).

7.2.1.6. Geri Yayılımlı Öğrenme (Backpropagation)

Geri yayılım ağı, Hinton ve McClelland tarafından ilk kez ortaya atılmıştır. Bu ağlar hiyerarşik bir yapıdadır. En az üç katmandan oluşur ki bunlar; giriş çıkış ve gizli katmandır. Gizli katman sayısı ve gizli katmandaki nöron sayısı değişebilir. Nöron sayısının fazla olması ağın hatırlama yeteneğini artırmaktadır fakat öğrenme süresini uzatmaktadır. Giriş katmanındaki her bir düğüm, gizli katmandaki tüm düğümlere ve gizli katmandaki her bir düğüm çıkışı da, çıkış katmanındaki her düğüme bağlıdır. Hiçbir düğüm kendi katmanındaki düğüme bağlı değildir. Bu sebepten dolayı geri yayılımlı ağlar ileri beslemeli ağ yapısına sahiptir (Elmas, 2007).

Geri yayılım çok katmanlı ağlarda kullanılan delta öğrenme kuralı için geliştirilmiş bir algoritmadır. Geri yayılım ağında hatalar, ileri besleme aktarım işlevinin türevi tarafından, ileri besleme mekanizması içinde kullanılan bağlantılar aracılığıyla geriye doğru yayılmaktadır. Bu ağ yapısı sistem hatasını veya maliyet işlevini azaltma esasına dayanan bir optimizasyon işlemidir. Bu yöntemle ağırlık ayarlaması yapıldığı için geri yayılım ismi kullanılmıştır. Öğrenme aşamasında giriş örnekleri sisteme verilir. Her bir katmandan alınan çıkış değerleri sistemin çıkışına ulaşıncaya kadar hesaplanır (İleri Hesaplama). Hesaplanan çıkış değeri ile beklenen değer karşılaştırılır ve hata miktarı belirlenir. Elde edilen bu hata ağın bağlantıları ile geriye doğru tüm katman ve nöronlara paylaşılır. Bu hata değerleri kullanılarak katman ve nöron ağırlıkları yeniden hesaplanır ve bu işlem istenilen toplam hata miktarı yakalanıncaya kadar devam eder (Öztemel, 2006; Elmas, 2007).



Şekil 7.5. Hatanın geri yayılımı (Elmas, 2007).

7.2.2. Bulanık Mantık (BM)

Bilgisayarların kullandığı Aristo mantığından farklı olarak; insanın yaklaşık ve belirsizlik içeren veri ve bilgi ile işlem yapabilme yeteneği vardır. Bu yeteneği sayesinde insan günlük hayatta karşılaştığı karmaşık olayları çözebilmektedir. Bulanık mantık (Fuzzy Logic) kavramı, insanların kesin olmayan ifadelerle düşünme yeteneğinin bilgisayarlara aktarılmasıdır. Başka bir deyişle, bulanık mantık soğuk-sıcak, hızlı-yavaş, yüksek-alçak gibi ikili değişkenlerden oluşan keskin dünyayı, az soğuk-az sıcak, az hızlı-az yavaş, az yüksek-az alçak gibi esnek nitelilerle gerçek dünyaya benzetir (Gökberk, 2014). Kesin veriler günümüzde birçok problemin çözüm modellerini oluşturmada yetersiz kalmaktadır. Çünkü insan yargıları ve tercihleri karşılaşılan her bir gerçek durum için genellikle belirsizdir ve kesin sayısal değerler ile tahmin edilemezler (Nabiyev, 2005).

Bulanık Mantık (BM) yaklaşımı ilk defa 1965 yılında Lotfi A. Zadeh tarafından “Information and Control” dergisinde yayınlanan “Bulanık Kümeler” adlı makale ile ortaya çıkmıştır (Zadeh, 1965). Zadeh bu çalışmasında insan düşüncesinin büyük bir bölümünün kesin olmadığını ve bu yüzden 0 ve 1 ile temsil edilen boolean mantığının insan düşünce sistemini yeterince modelleyemediğini belirtmiştir. İnsan mantığında açık, kapalı, sıcak ve soğuk gibi kavramların yanında az açık, çok soğuk vb. kavramlarında olduğunu ve bunların modellenmesinin boolean mantığı ile yeterli ölçüde modellenemediğini belirtmiştir. Dolayısıyla BM ikili seviye değil çok seviyeli işlemleri kullanmaktadır. Önceleri pek kabul görmeyen bu yaklaşımı; ilk defa 1972 yılında


İngiltere’ de Ebrahim Mamdani, bir buhar makinesi için kontroller tasarlayarak kullanmıştır. Daha sonra Danimarka’ da çimento sanayisindeki uygulama bu yöntemin avantajlarını göstermiştir. Bulanık mantığın en çok uygulandığı ülke Japonya olmuştur. Japon bilim adamları ve mühendisleri bulanık mantığı metroda, otomatik tren kontrolü, hisse senedi portföyü, asansör vs. birçok alanda kullanmışlar ve bundan büyük ekonomik kazançlar elde etmişlerdir (Elmas, 2003).

7.2.2.1. Bulanık Küme Teorisi

Klasik kümelerde bir eleman o kümenin ya elemanıdır ya da elemanı değildir. Kısmi üyelik terimi bulunmamaktadır. Eleman eğer o kümenin elemanı ise üyelik değeri 1, elemanı değilse üyelik değeri 0’dır. Yani klasik küme teorisinde elemanların üyelikleri 0 ve 1 değerlerini alırlar. Matematiksel olarak Denklem 7.3’deki gibi gösterilir (Nabiyev, 2005).

$$\mu_A(x) = \begin{cases} 1, & \text{Eğer } x \in A \\ 0, & \text{Eğer } x \notin A \end{cases} \quad (7.3)$$

Örneğin elini suya sokan bir kişi hiçbir zaman suyun ısısını net olarak bilemez. Bu problem klasik küme ile çözülmek istenir ise suyun sıcaklık değeri ölçülür ve 30 °C’nin altında düşerse sıcak değildir şartı konulması gerekir. Bu durumda 30 °C’nin altındaki sıcaklıklar “sıcak değil” olarak tanımlanacak, 30 °C’nin üstündeki sıcaklıklar ise “sıcak” olarak tanımlanacaktır. Doğal olarak bu yaklaşımın hiçbir esnekliği yoktur (Şekil 7.6).




Şekil 7.6. Kesin küme

Günlük hayatta karşılaştığımız birçok problemde ise 0 ve 1 gibi kesin değerler kullanılarak sonuç almak, içerdiği belirsizlikler sebebiyle oldukça zordur. Çünkü gerçek hayat oldukça karmaşık bir yapıya sahiptir. Gerçek hayatta kullandığımız “pek açık değil”, “muhtemelen öyledir”, “çok iyi”, ”idare eder” gibi sayabileceğimiz birçok ifadeyi bir kümeye tam olarak yerleştirmek mümkün değildir. Karşılaşılan bu sözel ifadelerin bir kümeye aitlik derecelerinin hesaplanması yöntemine bulanık küme teorisi denir (Nabiyev, 2005).

Bulanık mantık teoreminde bir eleman birden fazla kümeye ait olabilir. Bu aitlik değeri o kümenin üyelik fonksiyonu ile tanımlanır. Eğer A klasik kümesi [0,1] arasında değerleri alırsa A^1 kümesi bulanık küme olacaktır ve Denklem 7.4’deki gibi tanımlanır (Nabiyev, 2005).

$$A^1 = \{x, \mu_A^1(x) | x \in A\} \quad (7.4)$$

Elini suya sokan insanın suyun ısısını sözsöz ifadeler belirtmesi bulanık kümeye verilebilecek en basit örnektir. Böyle bir durumda kişi suyun sıcaklık değerini kesin olarak bilemez ve bunun yerine sıcak, az sıcak, soğuk, çok soğuk gibi dilsel ifadeleri kullanır.

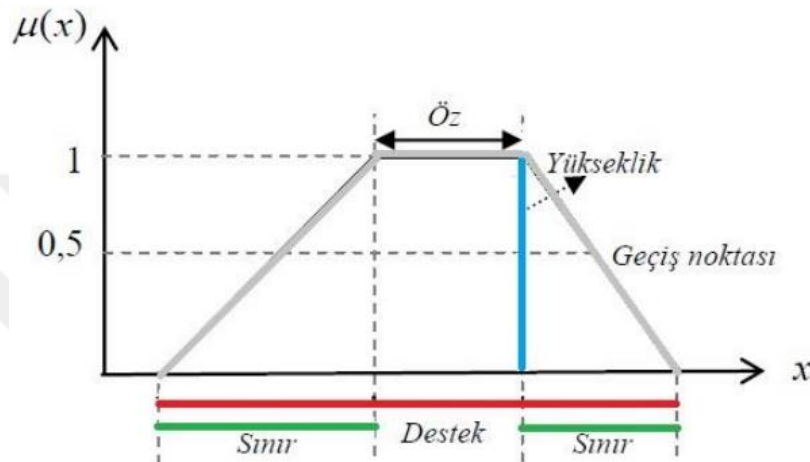


Şekil 7.7. Bulanık küme

Şekil 7.7’de verilen bulanık küme örneğine göre; 20-40 °C arasındaki değerler sıcak kümesinin üyeleridir. 30-40 °C arasındaki değerlerin üyelik derecesi 1’dir. 20-30 °C arasındaki değerlerin üyelik derecesi 0 ile 1 arasında değişmektedir. Başka bir deyişle 22 °C az sıcak, 27 °C biraz sıcak olarak değer alabilecektir. Bu örnekte 25 °C’nin sıcak kümesine aitliği 0.5’dir (Nabiyev, 2005).

7.2.2.2. Üyelik İşlevi


Üyelik fonksiyonu U evrensel kümesinde bir x elemanın A klasik kümesine ya da A^1 bulanık kümesine aitlik derecesini gösteren fonksiyon olarak tanımlanabilir (Sumathi ve Paneerselvam, 2010). Üyelik fonksiyonları kümedeki elemanlar ayrık ya da sürekli olup olmamasına bakmaksızın var olan bulanıklığı somutlaştırmayı sağlayan fonksiyonlardır (Ross, 2009).



Şekil 7.8. Üyelik işlevinin bölümleri (Ross, 2009)

Bir bulanık üyelik işlevi çeşitli bölümlerden oluşur. Öz bulanık kümeye tam üyelik derecesinde ait olan bölgeyi temsil eder. Bulanık kümeye tam olarak ait olmayan yani aitlik değeri 1 olmayan alanlar sınır olarak adlandırılır. Kümenin sıfırdan büyük elemanları kümenin destek bölgesinde bulunur. Kümenin en yüksek aitlik değeri bu kümenin yüksekliğidir. Üyelik fonksiyonun yarısında bulunan (0.5) nokta ise geçiş noktasıdır (Ross, 2009).

BM sisteminin temeli, üyelik işlevlerinden ortaya çıkarılan dilsel değişkenlerin oluşturduğu giriş değerlerini kara verme sürecinde kullanmaktır. Kurallar listesi ve üyelik işlevi tasarımı için genellikle uzmandan alınan bilgiler kullanılır. Üyelik işlevleri Şekil 7.9 'da görüldüğü gibi üçgen, yamuk, çan eğrisi (gausyen) vb. şekillerde kullanılabilir. Denetimi yapılan sistemin özelliğine göre bunların dışında uygun bir işlev de kullanılabilir (Elmas, 2007).




Şekil 7.9. Üçgen, yamuk ve çan eğrisi üyelik işlevleri

Örnek olarak üçgen üyelik işlevinin matematiksel gösterimi Denklem 7.5’de gösterilmiştir (Elmas, 2007). Diğer üyelik fonksiyonları da Şekil 7.5’ deki benzer biçimde tanımlanabilir.

$$\mu_A(x) = \begin{cases} 0, & x \leq a \\ \frac{a-x}{a-b}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & x \geq c \end{cases} \quad (7.5)$$

7.2.2.3. Bulanık İşlem Süreci

Bir bulanık çıkarım işlem sürecinin elemanları ve aşamaları Şekil 7.10’daki gibi gösterilebilir.



Şekil 7.10. Bulanık işlem süreci akış şeması

Bulanıklaştırma işleminde, bulanık sistem için belirlenen üyelik fonksiyonuna göre sayısal olarak verilen giriş bilgilerinin dilsel olarak belirlenen kümelerle olan aitlik oranları belirlenir. Dilsel ifadeler ile belirlenen kümelerin aitlik oranları üyelik fonksiyonunun çeşidine göre değişmektedir. Bulanıklaştırma sürecinde ele alınan üyelik fonksiyonları, problemin yapısına ve amacına uygun olmalıdır. Genel anlamda üyelik

fonksiyonları sezgisel, matematik, geometrik ya da istatistiksel yaklaşımlara dayandırılabilir (Yen ve ark., 1995).

Klasik mantıkta elde edilen önermelerden bir sonuca varmaya çıkarım denir. Klasik mantıkta önermeler kesin ve açıktır. Çıkarım ise önermelerin birbirleriyle tam uyuşması durumunda yapılabilir. Örneğin “balıklar suda yüzer” ve “lüfer bir balıktır” önermeleri dikkate alındığında çıkarım “lüfer suda yüzer” olmaktadır. Bulanık sistemlerde ise girişler orta, soğuk, yüksek gibi dilsel değişkenlerden oluştuğundan dolayı; bu girişler hakkında karar verme ancak EĞER-O HALDE türünden kuralların belirlenmesi ile gerçekleştirilebilir. Örneğin “Hava çok soğuksa sıkı giyinirim” bilgisinin sahip bir bulanık sisteme verilen “hava biraz soğuk” önermesi sonucunda sistemin çıkarımı “biraz sıkı giyin” olabilmektedir (Elmas, 2007). Bulanık çıkarım yani karşılaşılan problem için, oluşturulan kümelerin bulanık değerleri sonucunda ortaya çıkacak bulanık değerlere karar vermek için deneyim tecrübe ve uzman bilgisi gerekmektedir.

Bulanıklaştırma sonunda elde edilen dilsel ifadeler, kural tabanındaki önermelerle karşılaştırılır. Bu karşılaştırma sonucunda sözel yargı sonuçları elde edilir. Bu sonuçların hangi oranda geçerli olduğunu yine girişteki üyelik dereceleri belirler. Bu kısma bulanık karar verme süreci adı verilir. Bulanık karar verme sürecinin çıkışında yargı sonuçlarını ifade eden sözel ifadeler ve bunların destek dereceleri bulanık çıkışlar olarak adlandırılır. Eğer bilgisayar çıkışta bir makineye bilgi yolluyorsa, bulanık çıkışlar yine makinelerin anlayacağı dil olan sayısal çıkış değerlerine dönüştürülmelidir. Bu dönüştürme işlemi durulaştırma denir. Durulaştırma işlemi sonucunda birden fazla sözel yargı değeri tek bir sayısal ifadeye çevrilir. Literatürde farklı çıkarım modelleri tanımlanmıştır. Bu bulanık çıkarım modellerinde en önemli modeller: Mamdani Bulanık Modeli ve Takagi - Sugeno Bulanık Modelidir. Literatürde en sık karşılaşılan Mamdani modeli aşağıda detaylandırılmıştır (Mamdani, 1974; Takagi ve Sugeno, 1985).

Mamdani Bulanık Modeli: Mamdani tipi bulanık model ilk kurulan bulanık modeldir, oluşturması kolay ve insan davranışlarına çok uygundur. Bu nedenle çok yaygın bir kullanıma sahiptir ve diğer bulanık mantık modellerin temelini oluşturur. İlk defa bir buhar motorunun insan tecrübelerinden elde edilen sözel kontrol kuralları yardımıyla kontrolü amacıyla kullanılmıştır (Mamdani ve Assilian, 1975). Mamdani modellemede, sistem tanımlamada kullanılan matematiksel denklemlerin yerini eğer-ise

(if-then) biçiminde kurallar almaktadır. Mamdani modelin yapısı Denklem 7.6'daki gibi ifade edilmektedir (Mamdani, 1977).

$$\text{Eğer } x = A_i \text{ ve } y = B_i \text{ ise } z = C_i, i \in k \quad (7.6)$$

Denklem 7.6'da k toplam kural sayısını, i kural sırasını, x ve y girdi değişkenlerini ve z 'de çıktı değişkenini (bulanık kümeleri) belirtmektedir.

Mamdani tipi bir bulanık model aşağıdaki 5 adımda oluşturulur;

1. Girdilerin bulanıklaştırılması: Girişteki bütün bulanık ifadeleri kullanarak girdi değişkenlerine ait 0 ile 1 arasında değişen üyelik derecelerinin belirlenmesi.
2. Bulanık mantık işlemlerini kullanarak kural ağırlıklarının belirlenmesi
3. Bulanık küme mantıksal işlemcilerin (ve, veya) uygulanması
4. Sonuçların toplanması: Her bir kuralın çıktısını temsil eden bulanık kümelerin birleştirilmesi
5. Durulaştırma: Tek bir sayıya dönüştürülmüş toplam bulanık küme sonuçlarının durulaştırılması (Mamdani, 1977).


Çıkarım sonucunda elde edilen sonuç dilsel olarak ifade edildiğinden dolayı bu değerlerin durulaştırılması yani sayısal ifadeye çevrilmesi gerekmektedir. Bu aşamada, uygun bir durulaştırma yöntemi kullanılarak sayısal çıktı elde edilir. Durulaştırmaya ilişkin metotlardan sıklıkla kullanılanları; ağırlık merkezi, maksimumlar ve alan açığı yöntemleridir. Bu yöntemler içerisinde literatürde de en sık karşılaşılan Ağırlık Merkezi yöntemi aşağıda açıklanmıştır.

Ağırlık Merkezi (Centroid) Yöntemi: En çok tercih edilen durulaştırma yöntemidir. Bu yöntemde atışlenen kuralların bulanık çıkışlarındaki üyelik fonksiyonu değerleriyle sayısal ağırlıkları çarpılarak toplamları alınır. Elde edilen bu çıkış kümesinin ağırlık merkezi bulunarak veya Denklem 7.7 uygulanarak çıkışın sayısal değeri belirlenir.

$$Z_0 = \frac{\sum_{j=1}^n \mu_z(\omega_j) \cdot \omega_j}{\sum_{j=1}^n \mu_z(\omega_j)} \quad (7.7)$$

Burada n ; kural sayısını, Z_0 ; kesin kontrol eylemini, ω_j ; bulanıklaştırmada oluşmuş her bir fonksiyonun üyelik derecesi en büyük olan elemanlarını ve $\mu_z(\omega_j)$ ise bu elemanlara karşılık gelen üyelik derecelerini belirtir (Zadeh, 1984).

Şekil 7.11’de ağırlık merkezi yönteminin sistem çıkışına uygulanması gösterilmektedir. Burada $B(1)$, $B(2)$... $B(N)$ her bir kurala karşılık gelen çıkışları göstermektedir ($\mu_z(\omega_j)$). Z_0 sistemin sonucunda oluşan birleşim kümesinin ağırlık merkezini dolayısıyla sistemin çıkış değerini sayısal olarak ifade etmektedir.




Şekil 7.11. Ağırlık merkezi yönteminin gösterimi (Kıyak ve Kahvecioğlu, 2003)

7.2.3. Bulanık Sinir Ağları (BSA)

Standart matematiksel modeller kullanan sınırların, t-norm ve t-conorm bileşke işlemcileri kullanan bulanık sınırlara dönüştürülmesi işlemine bulanık sinir ağları (BSA) denir. Bu yaklaşımda bulanık mantık kavramları, klasik sinir ağının bilgi sunum yeteneklerini geliştirmek için kullanılmaktadır. Bu da sinir ağlarının girdi, ağırlıklar, bileşke işlemleri, aktivasyon fonksiyonları ve çıktı gibi düzeylerinde bulanık kavramların kullanılmasıyla sağlanmaktadır (Baykal ve Beyan, 2004).

BSA, bulanık sinyalleri işleyen ve/veya bulanık ağırlıkları olan sinir ağıdır. BSA, BM’in insan gibi kara verme ve uzman bilgisinden yararlanma özellikleri ile YSA’nın öğrenme yeteneği ve en uygunu bulma özelliklerini birleştirilmesi fikrine dayanmaktadır (Elmas, 2003). Şekil 7.12’de bulanık sinir ağı modeli gösterilmiştir.



Şekil 7.12. Bulanık sinir ağı modeli (Baykal ve Beyan, 2004)


Literatürde kullanılan 4 tip BSA vardır (Fullér, 1995). Genellikle sınıflandırma problemlerinde BSA₁ ağı kullanılır (Ishibuchi ve ark., 1992; Lee ve Wang, 1994). BSA₂, BSA₃, BSA₄ ağları ise bulanık Eğer-O Halde kurallarını gerçekleştirmek için kullanılır (Ishibuchi ve ark., 1994). BSA tipleri Çizelge 7.3’de verilmiştir.

Çizelge 7.3. Bulanık sinir ağı tipleri (Kahramanlı, 2008)

Bulanık Sinir Ağı	Ağırlıklar	Girişler	Çıktılar
Tip 1 (BSA ₁)	Kesin	Bulanık	Kesin
Tip 2 (BSA ₂)	Kesin	Bulanık	Bulanık
Tip 3 (BSA ₃)	Bulanık	Bulanık	Bulanık
Tip 4 (BSA ₄)	Bulanık	Kesin	Bulanık

Eğer sinir ağında sinirsel işleme birimi, çarpma toplama veya lojistik aktivasyon fonksiyonunu kullanıyorsa buna standart ya da düzenli bulanık sinir ağı denir. Hibrit sinir ağları ise t-norm, t-conorm veya diğer sürekli işlemleri kullanarak gelen sinyalleri ve ağırlıkları sonucu elde etmek için birleştirir. Düzenli bulanık sinir ağları Zadeh’in genişleme ilkesine dayalı bulanık aritmetiği kullanırken, hibrit sinir ağları ise evrensel yaklaşımı kullanmaktadır (Baykal ve Beyan, 2004).

BSA₁ yapısına örnek olarak Yamakawa ve arkadaşlarının (1993) geliştirdiği bulanık sinir ağı yapısı verilebilir. Burada her bir x_i girişi için sinir hücresi tek bir ağırlık yerine, ağırlıklar dizisine ($w_{ij} j = 1..m$) sahiptir. Bu değerlerin her biri üçgen bulanık sayılar (μ_{ij}) ile ilişkilidir. Her bir x_i girişi için, yalnızca iki komşu üyelik fonksiyonu sıfırdan farklı olacağından dolayı x_i ile ilişkili sinir hücresinin çıkışı komşu iki ağırlığın ortalamasıdır. Yamakawa’nın çalışmalarında deneysel kural kullanılarak, ağırlıkların güncellenmesine dayalı bir sistem görülmektedir (Şekil 7.13).



Şekil 7.13. BSA₁ Bulanık ağ yapısı (Baykal ve Beyan, 2004)

Çalışmamızın bu aşamasında, YSA sınıflandırıcısına özellik çıkarımı aşamasında elde edilmiş alfa, beta ve temel çizgi/femur oranları giriş olarak verilmiştir. Çıkış değerleri olarak uzmandan alınan teşhis değerleri atanmıştır. 50 adet görüntü içerisinde temel çizgi/femur oranı belirlenmesinde 48 adet doğru bölge olduğu için sınıflandırma aşamamızın bu kısmında 48 adet görüntü örneği kullanılmıştır (Çizelge 7.4).

Çizelge 7.4. YSA sınıflandırması için kullanılan veri seti


Görüntü No	Girişler				Çıkışlar		Görüntü No	Girişler				Çıkışlar	
	Alfa	Beta	Üst %	Alt %	Tip I	Tip II		Alfa	Beta	Üst %	Alt %	Tip I	Tip II
1	69	63	40	60	1	B	25	64	55	57	43	1	A
2	69	54	42	58	1	A	26	56	41	55	45	1	A
3	62	63	40	60	1	B	27	55	53	48	52	2	A
4	55	39	52	48	1	A	28	62	76	44	56	1	B
5	50	66	55	45	2	A	29	63	60	35	65	1	B
6	60	63	44	56	1	B	30	55	67	49	51	1	B
7	65	59	38	62	1	B	31	57	45	49	51	2	A
8	55	53	55	45	2	A	32	56	40	49	51	2	A
9	52	58	62	38	1	A	33	57	48	30	70	1	B
10	60	62	39	61	1	B	34	55	67	64	36	2	A
11	72	64	45	55	1	B	35	66	65	43	57	1	B
12	52	59	43	57	1	A	36	73	72	33	67	1	B
13	59	52	45	55	2	A	37	63	67	43	57	1	B
14	52	51	53	47	2	A	38	61	56	79	21	1	B
15	52	53	41	59	2	A	39	59	78	59	41	2	A
16	46	72	61	39	1	A	40	65	55	55	45	1	A
17	60	73	48	52	1	B	41	62	66	47	53	1	B
18	56	59	44	56	2	A	42	67	69	48	52	1	B
19	49	38	43	57	1	A	43	66	49	53	47	1	A
20	50	53	55	45	2	A	44	51	47	38	62	1	A

Görüntü No	Girişler				Çıkışlar		Görüntü No	Girişler				Çıkışlar	
	Alfa	Beta	Üst %	Alt %	Tip I	Tip II		Alfa	Beta	Üst %	Alt %	Tip I	Tip II
21	48	59	44	56	1	B	45	59	77	54	46	2	A
22	60	69	67	33	1	B	46	59	60	52	48	2	A
23	52	65	32	68	2	A	47	61	81	41	59	1	B
24	47	54	43	57	2	A	48	78	58	41	59	1	B

Çizelge 7.4’de belirtilen, GKD teşhisi için US görüntülerinden alınmış veri kümesi YSA’ ya girdi olarak verilmiştir. Ağın çıkış kısmında, Graf yöntemine göre sadece Tip I ile teşhis konulabileceği için, iki farklı çıkış yapısına göre ağ tasarımı yapılmıştır. Sadece Tip I çıkışını sınıflandırmak için çıkışta 2 sınıf (1 ve 2) belirlenmiş, Tip I ve Tip II çıkışlarını sınıflandırmak için ise çıkışta 3 sınıf (1/A, 1/B, 2/A) belirlenmiş ve sonuçları tartışılmıştır.

Bu çalışmada kullanılan YSA, çok katmanlı mimariye sahiptir. YSA eğitimi yapılırken geriye yayılım eğitim algoritması kullanılmıştır. Eğitimin durdurulması kriteri olarak maksimum iterasyon sayısı ve hata oranı kullanılmıştır. Tüm girişler için bulunan çıkışlara göre ortalama karesel hata değerine bakılmıştır.

2 sınıflı (1 ve 2) YSA parametreleri Çizelge 7.5’te verilmiştir. Bu parametreler doğrultusunda tasarlanmış YSA’nın yapısı Şekil 7.14’de gösterilmiştir.



Şekil 7.14. Tasarlanan 2 sınıflı YSA yapısı

Çizelge 7.5. YSA parametreleri (2 sınıflı)

Parametre	Değerler
Giriş katman nöron sayısı	4
Gizli katman nöron sayısı	30
Çıkış katman nöron sayısı	1
Aktivasyon fonksiyonu	Tanjant Hiperbolik
Maksimum adım sayısı	15.000
Eğitime giren veri sayısı	36 (%75)
Test veri sayısı	12 (%25)

Sınıflama işleminin doğruluğunu onaylayabilmek amacı ile eğitim ve test işlemi beş kez tekrar edilmiştir. Rastgele belirlenen eğitim ve test verileri, YSA ile eğitim işlemine tabi tutulup, sonrasında test edilmiştir. Bu işlemin sonucunda elde edilen doğru/yanlış sınıflandırma oranları Çizelge 7.6’da gösterilmiştir.

Çizelge 7.6. 2 sınıflı ağ için beş tekrar eğitim/test işlemi sonuçları

Tekrar No	Eğitim Verisi	Test Verisi	Doğru Sınıflandırma	Yanlış Sınıflandırma	Başarı %
1	36	12	10	2	83.34
2	36	12	9	3	75
3	36	12	10	2	83.34
4	36	12	9	3	75
5	36	12	10	2	83.34
Ortalama	36	12	9.6	2.4	80

Çizelge incelendiğinde YSA eğitimi işleminin 5 kez tekrarlanması sonucunda ortalama başarı oranı %80’dir. En başarılı sınıflandırma değeri %83.34 ile 1, 3 ve 5 numaralı veri setleridir. Eğitim işlemine ait doğru sınıflandırma yüzde grafiği Şekil 7.15’de gösterilmiştir.




Şekil 7.15. 2 sınıflı ağ için eğitim aşaması eğitim aşaması doğru sınıflandırma grafiği

3 sınıflı (1/A, 1/B ve 2/A) YSA parametreleri Çizelge 7.7’de verilmiştir. Bu parametreler doğrultusunda tasarlanmış YSA’nın yapısı Şekil 7.16’de gösterilmiştir.

Çizelge 7.7. YSA parametreleri (3 sınıflı)

Parametre	Değerler
Giriş katman nöron sayısı	4
Gizli katman nöron sayısı	30
Çıkış katman nöron sayısı	3
Aktivasyon fonksiyonu	Tanjant Hiperbolik
Maksimum adım sayısı	15.000
Eğitime giren veri sayısı	36 (%75)
Test veri sayısı	12 (%25)



Şekil 7.16. Tasarlanan 3 sınıflı YSA yapısı

Sınıflama işleminin doğruluğunu onaylayabilmek amacı ile eğitim ve test işlemi beş kez tekrar edilmiştir. Rastgele belirlenen eğitim ve test verileri, YSA ile eğitim işlemine tabi tutulup, sonrasında test edilmiştir. Bu işlemin sonucu Çizelge 7.8'de sonuçları gösterilmiştir.

Çizelge 7.8. 3 sınıflı ağ için beş tekrar eğitim/test işlemi sonuçları

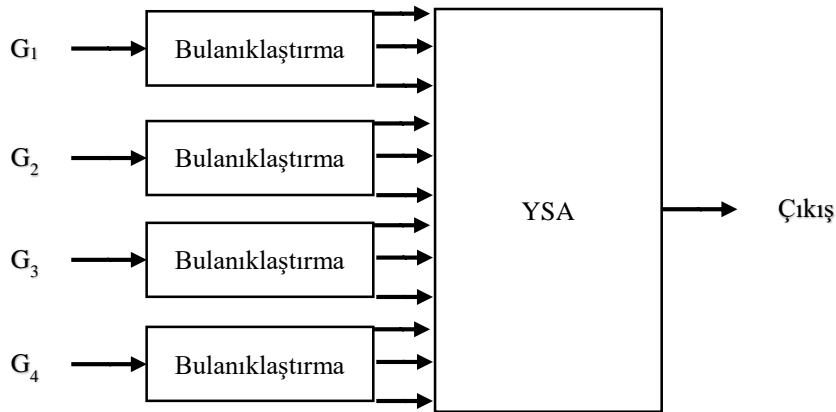
İşlem No	Eğitim Verisi	Test Verisi	Doğru Sınıflandırma	Yanlış Sınıflandırma	Başarı %
1	36	12	9	3	75
2	36	12	10	2	83.34
3	36	12	8	4	66.67
4	36	12	9	3	75
5	36	12	9	3	75
Ortalama	36	12	9	3	75

Çizelge incelendiğinde YSA eğitimi işleminin 5 kez tekrarlanması sonucunda ortalama başarı oranı %75'dir. En başarılı seçim değeri %83.34 ile 2 numaralı veri setidir. 5 kez tekrarlanan eğitim işlemi içerisinde başarı oranı en yüksek olan sınıflandırma sonucu için 15.000 adım süresince, eğitim verileri başarı oranı ve sistemin genel hata değişimi Şekil 7.17'de gösterilmiştir.




Şekil 7.17. 3 sınıflı ağ için eğitim aşaması doğru sınıflandırma grafiği

YSA ile gerçekleştirilen sınıflandırma başarı oranları ile Graf yönteminden elde edilen başarı oranları karşılaştırıldığında sonuçların birbirine oldukça yakın olduğu gözlenmiştir. Sınıflandırma yapılırken verilerin keskin değerler şeklinde tip gruplarına dahil edilmesi başarı oranına olumsuz etkide bulunmaktadır. Bu durum ölçme sırasında oluşabilecek küçük hataları elimine edilememesine sebep olmaktadır. Bu problemin üstesinden gelebilmek amacıyla ölçülen giriş değerlerinin dilsel ifadeler şeklinde temsil edildiği bulanık değerlere sahip kümelere dönüştürülerek bulanık sinir ağı (BSA) yapısında bir sınıflandırma yöntemi önerilmiştir. Bu yöntemde ölçülen alfa, beta ve temel çizgi/femur oranları değerleri bulanıklaştırılıp YSA'ya giriş olarak verilmiştir. Her bir giriş için üç adet bulanık küme (Düşük, Orta, Yüksek) kullanılmıştır. Giriş verileri bahsi geçen bulanık kümelere olan üyelik dereceleridir. Tasarlanan BSA yapısı Şekil 7.18'de gösterilmiştir.



Şekil 7.18. Tasarlanan BSA yapısı

Alfa değerlerini bulanıklaştırmak için kullanılan üyelik fonksiyonu Şekil 7.19'da gösterilmiştir.




Şekil 7.19. Alfa değeri için bulanık üyelik fonksiyonu

Özellik çıkarımı aşamasında elde edilen 48 adet alfa değerinin düşük, orta ve yüksek bulanık kümelerine aitlik bilgisini içeren değerler Çizelge 7.9'da gösterilmiştir.

Çizelge 7.9. Alfa değerlerinin bulanıklaştırılması

Görüntü No	Alfa	Düşük	Orta	Yüksek	Görüntü No	Alfa	Düşük	Orta	Yüksek
1	69	0	0	1	25	64	0	0.2	0.8
2	69	0	0	1	26	56	0.8	0.2	0
3	62	0	0.6	0.4	27	55	1	0	0
4	55	1	0	0	28	62	0	0.6	0.4
5	50	1	0	0	29	63	0	0.4	0.6
6	60	0	1	0	30	55	1	0	0
7	65	0	0	1	31	57	0.6	0.4	0
8	55	1	0	0	32	56	0.8	0.2	0
9	52	1	0	0	33	57	0.6	0.4	0
10	60	0	1	0	34	55	1	0	0
11	72	0	0	1	35	66	0	0	1
12	52	1	0	0	36	73	0	0	1
13	59	0.2	0.8	0	37	63	0	0.4	0.6
14	52	1	0	0	38	61	0	0.8	0.2
15	52	1	0	0	39	59	0.2	0.8	0
16	46	1	0	0	40	65	0	0	1
17	60	0	1	0	41	62	0	0.6	0.4
18	56	0.8	0.2	0	42	67	0	0	1
19	49	1	0	0	43	66	0	0	1
20	50	1	0	0	44	51	1	0	0
21	48	1	0	0	45	59	0.2	0.8	0
22	60	0	1	0	46	59	0.2	0.8	0
23	52	1	0	0	47	61	0	0.8	0.2
24	47	1	0	0	48	78	0	0	1

Beta değerlerini bulanıklaştırmak için kullanılan üyelik fonksiyonu Şekil 7.20’de gösterilmiştir.




Şekil 7.20. Beta değeri için bulanık üyelik fonksiyonu

Özellik çıkarımı aşamasında elde edilen 48 adet beta değerinin düşük, orta ve yüksek bulanık kümelerine aitlik bilgisini içeren değerler Çizelge 7.10’da gösterilmiştir.

Çizelge 7.10. Beta değerlerinin bulanıklaştırılması

Görüntü No	Beta	Düşük	Orta	Yüksek	Görüntü No	Beta	Düşük	Orta	Yüksek
1	63	0	0	1	25	55	0	1	0
2	54	0.2	0.8	0	26	41	1	0	0
3	63	0	0	1	27	53	0.4	0.6	0
4	39	1	0	0	28	76	0	0	1
5	66	0	0	1	29	60	0	0	1
6	63	0	0	1	30	67	0	0	1
7	59	0	0.2	0.8	31	45	1	0	0
8	53	0.4	0.6	0	32	40	1	0	0
9	58	0	0.4	0.6	33	48	1	0	0
10	62	0	0	1	34	67	0	0	1
11	64	0	0	1	35	65	0	0	1
12	59	0	0.2	0.8	36	72	0	0	1
13	52	0.6	0.4	0	37	67	0	0	1
14	51	0.8	0.2	0	38	56	0	0.8	0.2
15	53	0.4	0.6	0	39	78	0	0	1
16	72	0	0	1	40	55	0	1	0
17	73	0	0	1	41	66	0	0	1
18	59	0	0.2	0.8	42	69	0	0	1
19	38	1	0	0	43	49	1	0	0
20	53	0.4	0.6	0	44	47	1	0	0
21	59	0	0.2	0.8	45	77	0	0	1
22	69	0	0	1	46	60	0	0	1
23	65	0	0	1	47	81	0	0	1
24	54	0.2	0.8	0	48	58	0	0.4	0.6

Temel çizgi/femur üst oran değerlerini bulanıklaştırmak için kullanılan üyelik fonksiyonu Şekil 7.21’de gösterilmiştir.




Şekil 7.21. Temel çizgi/femur üst oran değeri için bulanık üyelik fonksiyonu

Özellik çıkarımı aşamasında elde edilen 48 adet üst oran değerinin düşük, orta ve yüksek bulanık kümelerine aitlik bilgisini içeren değerler Çizelge 7.11’de gösterilmiştir.

Çizelge 7.11. Temel çizgi/femur üst oran değerlerinin bulanıklaştırılması

Görüntü No	Üst %	Düşük	Orta	Yüksek	Görüntü No	Üst %	Düşük	Orta	Yüksek
1	40	0	1	0	25	57	0	0.15	0.85
2	42	0	0.9	0.1	26	55	0	0.25	0.75
3	40	0	1	0	27	48	0	0.6	0.4
4	52	0	0.4	0.6	28	44	0	0.8	0.2
5	55	0	0.25	0.75	29	35	0.25	0.75	0
6	44	0	0.8	0.2	30	49	0	0.55	0.45
7	38	0.1	0.9	0	31	49	0	0.55	0.45
8	55	0	0.25	0.75	32	49	0	0.55	0.45
9	62	0	0	1	33	30	0.5	0.5	0
10	39	0.05	0.95	0	34	64	0	0	1
11	45	0	0.75	0.25	35	43	0	0.85	0.15
12	43	0	0.85	0.15	36	33	0.35	0.65	0
13	45	0	0.75	0.25	37	43	0	0.85	0.15
14	53	0	0.35	0.65	38	79	0	0	1
15	41	0	0.95	0.05	39	59	0	0.05	0.95
16	61	0	0	1	40	55	0	0.25	0.75
17	48	0	0.6	0.4	41	47	0	0.65	0.35
18	44	0	0.8	0.2	42	48	0	0.6	0.4
19	43	0	0.85	0.15	43	53	0	0.35	0.65
20	55	0	0.25	0.75	44	38	0.1	0.9	0
21	44	0	0.8	0.2	45	54	0	0.3	0.7
22	67	0	0	1	46	52	0	0.4	0.6
23	32	0.4	0.6	0	47	41	0	0.95	0.05
24	43	0	0.85	0.15	48	41	0	0.95	0.05

Temel çizgi/femur alt oran değerlerini bulanıklaştırmak için kullanılan üyelik fonksiyonu Şekil 7.22’de gösterilmiştir.



Şekil 7.22. Temel çizgi/femur alt oran değeri için bulanık üyelik fonksiyonu

Özellik çıkarımı aşamasında elde edilen 48 adet alt oran değerinin düşük, orta ve yüksek bulanık kümelerine aitlik bilgisini içeren değerler Çizelge 7.12’de gösterilmiştir.

Çizelge 7.12. Temel çizgi/femur alt oran değerinin bulanıklaştırılması

Görüntü No	Alt %	Düşük	Orta	Yüksek	Görüntü No	Alt %	Düşük	Orta	Yüksek
1	60	0	1	0	25	43	0.85	0.15	0
2	58	0.1	0.9	0	26	45	0.75	0.25	0
3	60	0	1	0	27	52	0.4	0.6	0
4	48	0.6	0.4	0	28	56	0.2	0.8	0
5	45	0.75	0.25	0	29	65	0	0.75	0.25
6	56	0.2	0.8	0	30	51	0.45	0.55	0
7	62	0	0.9	0.1	31	51	0.45	0.55	0
8	45	0.75	0.25	0	32	51	0.45	0.55	0
9	38	1	0	0	33	70	0	0.5	0.5
10	61	0	0.95	0.05	34	36	1	0	0
11	55	0.25	0.75	0	35	57	0.15	0.85	0
12	57	0.15	0.85	0	36	67	0	0.65	0.35
13	55	0.25	0.75	0	37	57	0.15	0.85	0
14	47	0.65	0.35	0	38	21	1	0	0
15	59	0.05	0.95	0	39	41	0.95	0.05	0
16	39	1	0	0	40	45	0.75	0.25	0
17	52	0.4	0.6	0	41	53	0.35	0.65	0
18	56	0.2	0.8	0	42	52	0.4	0.6	0
19	57	0.15	0.85	0	43	47	0.65	0.35	0
20	45	0.75	0.25	0	44	62	0	0.9	0.1
21	56	0.2	0.8	0	45	46	0.7	0.3	0
22	33	1	0	0	46	48	0.6	0.4	0
23	68	0	0.6	0.4	47	59	0.05	0.95	0
24	57	0.15	0.85	0	48	59	0.05	0.95	0

Alfa, beta ve temel çizgi/femur oranı değerlerinin Düşük, Orta, Yüksek kümelerine üyelik dereceleri sayısal olarak ifade edilmiş ve toplamda 12 adet giriş verisi elde edilmiştir. Bu sayede YSA'ya uygulanacak giriş verileri bulanıklaştırılmıştır. Bunun yanında BSA₁ yapısına uygun olarak çıkış verisi bulanıklaştırılmamış, kesin değer olarak bırakılmıştır. Çizelge 7.13'de 48 adet veri için hazırlanmış olan bulanık giriş ve kesin çıkış değerleri gösterilmiştir.

Çizelge 7.13. YSA sınıflandırması için kullanılan bulanık veri seti

Görüntü No	Alfa			Beta			Üst %		Alt %			Çıkış		
	Düşük	Orta	Yüksek	Düşük	Orta	Yüksek	Düşük	Orta	Yüksek	Düşük	Orta	Yüksek	Tip I	Tip II
1	0	0	1	0	0	1	0	1	0	0	1	0	1	B
2	0	0	1	0.2	0.8	0	0	0.9	0.1	0.1	0.9	0	1	A
3	0	0.6	0.4	0	0	1	0	1	0	0	1	0	1	B
4	1	0	0	1	0	0	0	0.4	0.6	0.6	0.4	0	1	A
5	1	0	0	0	0	1	0	0.25	0.75	0.75	0.25	0	2	A
6	0	1	0	0	0	1	0	0.8	0.2	0.2	0.8	0	1	B
7	0	0	1	0	0.2	0.8	0.1	0.9	0	0	0.9	0.1	1	B
8	1	0	0	0.4	0.6	0	0	0.25	0.75	0.75	0.25	0	2	A
9	1	0	0	0	0.4	0.6	0	0	1	1	0	0	1	A
10	0	1	0	0	0	1	0.05	0.95	0	0	0.95	0.05	1	B
11	0	0	1	0	0	1	0	0.75	0.25	0.25	0.75	0	1	B
12	1	0	0	0	0.2	0.8	0	0.85	0.15	0.15	0.85	0	1	A
13	0.2	0.8	0	0.6	0.4	0	0	0.75	0.25	0.25	0.75	0	2	A
14	1	0	0	0.8	0.2	0	0	0.35	0.65	0.65	0.35	0	2	A
15	1	0	0	0.4	0.6	0	0	0.95	0.05	0.05	0.95	0	2	A
16	1	0	0	0	0	1	0	0	1	1	0	0	1	A
17	0	1	0	0	0	1	0	0.6	0.4	0.4	0.6	0	1	B
18	0.8	0.2	0	0	0.2	0.8	0	0.8	0.2	0.2	0.8	0	2	A
19	1	0	0	1	0	0	0	0.85	0.15	0.15	0.85	0	1	A
20	1	0	0	0.4	0.6	0	0	0.25	0.75	0.75	0.25	0	2	A
21	1	0	0	0	0.2	0.8	0	0.8	0.2	0.2	0.8	0	1	B
22	0	1	0	0	0	1	0	0	1	1	0	0	1	B
23	1	0	0	0	0	1	0.4	0.6	0	0	0.6	0.4	2	A
24	1	0	0	0.2	0.8	0	0	0.85	0.15	0.15	0.85	0	2	A
25	0	0.2	0.8	0	1	0	0	0.15	0.85	0.85	0.15	0	1	A
26	0.8	0.2	0	1	0	0	0	0.25	0.75	0.75	0.25	0	1	A
27	1	0	0	0.4	0.6	0	0	0.6	0.4	0.4	0.6	0	2	A
28	0	0.6	0.4	0	0	1	0	0.8	0.2	0.2	0.8	0	1	B
29	0	0.4	0.6	0	0	1	0.25	0.75	0	0	0.75	0.25	1	B
30	1	0	0	0	0	1	0	0.55	0.45	0.45	0.55	0	1	B

Görüntü No	Alfa			Beta			Üst %			Alt %			Çıkış	
	Düşük	Orta	Yüksek	Düşük	Orta	Yüksek	Düşük	Orta	Yüksek	Düşük	Orta	Yüksek	Tip I	Tip II
31	0.6	0.4	0	1	0	0	0	0.55	0.45	0.45	0.55	0	2	A
32	0.8	0.2	0	1	0	0	0	0.55	0.45	0.45	0.55	0	2	A
33	0.6	0.4	0	1	0	0	0.5	0.5	0	0	0.5	0.5	1	B
34	1	0	0	0	0	1	0	0	1	1	0	0	2	A
35	0	0	1	0	0	1	0	0.85	0.15	0.15	0.85	0	1	B
36	0	0	1	0	0	1	0.35	0.65	0	0	0.65	0.35	1	B
37	0	0.4	0.6	0	0	1	0	0.85	0.15	0.15	0.85	0	1	B
38	0	0.8	0.2	0	0.8	0.2	0	0	1	1	0	0	1	B
39	0.2	0.8	0	0	0	1	0	0.05	0.95	0.95	0.05	0	2	A
40	0	0	1	0	1	0	0	0.25	0.75	0.75	0.25	0	1	A
41	0	0.6	0.4	0	0	1	0	0.65	0.35	0.35	0.65	0	1	B
42	0	0	1	0	0	1	0	0.6	0.4	0.4	0.6	0	1	B
43	0	0	1	1	0	0	0	0.35	0.65	0.65	0.35	0	1	A
44	1	0	0	1	0	0	0.1	0.9	0	0	0.9	0.1	1	A
45	0.2	0.8	0	0	0	1	0	0.3	0.7	0.7	0.3	0	2	A
46	0.2	0.8	0	0	0	1	0	0.4	0.6	0.6	0.4	0	2	A
47	0	0.8	0.2	0	0	1	0	0.95	0.05	0.05	0.95	0	1	B
48	0	0	1	0	0.4	0.6	0	0.95	0.05	0.05	0.95	0	1	B


Çizelge 7.13’de belirtilen, GKD teşhisi için US görüntülerinden alınmış veri kümesinin bulanıklaştırılmış verileri YSA’ ya girdi olarak verilmiştir. Ağın çıkış kısmında, Graf yöntemine göre sadece Tip I ile teşhis konulabileceği için iki farklı çıkış yapısına göre ağ tasarımı yapılmıştır. Sadece Tip I çıkışını sınıflandırmak için çıkışta 2 sınıf (1 ve 2) belirlenmiş, Tip I ve Tip II çıkışlarını sınıflandırmak için ise çıkışta 3 sınıf (1/A, 1/B, 2/A) belirlenmiş ve sonuçları tartışılmıştır.

Bu çalışmada kullanılan YSA, çok katmanlı mimariye sahiptir. YSA eğitimi yapılırken geriye yayılım eğitim algoritması kullanılmıştır. Eğitimin durdurulması kriteri olarak maksimum iterasyon sayısı ve hata oranı kullanılmıştır. Tüm girişler için bulunan çıkışlara göre ortalama karesel hata değerine bakılmıştır.

2 sınıflı (1 ve 2) YSA parametreleri Çizelge 7.14’de verilmiştir. Bu parametreler doğrultusunda tasarlanmış YSA’nın yapısı Şekil 7.23’de gösterilmiştir.

Çizelge 7.14. YSA parametreleri (2 sınıflı)

Parametre	Değerler
Giriş katman nöron sayısı	12
Gizli katman nöron sayısı	30
Çıkış katman nöron sayısı	1
Aktivasyon fonksiyonu	Tanjant Hiperbolik
Maksimum adım sayısı	15.000
Eğitime giren veri sayısı	36 (%75)
Test veri sayısı	12 (%25)




Şekil 7.23. Tasarlanan bulanık girişli 2 sınıflı YSA yapısı

Sınıflama işleminin doğruluğunu onaylayabilmek amacı ile eğitim ve test işlemi beş kez tekrar edilmiştir. Rastgele belirlenen eğitim ve test verileri YSA ile eğitim işlemine tabi tutulup, sonrasında test edilmiştir. Bu işlemin sonucu Çizelge 7.15’de sonuçları gösterilmiştir.

Çizelge 7.15. 2 sınıflı ağ için beş tekrar eğitim/test işlemi sonuçları

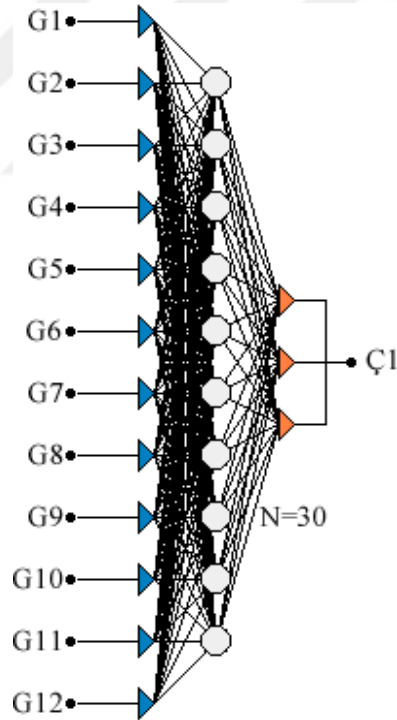
İşlem No	Eğitim Verisi	Test Verisi	Doğru Sınıflandırma	Yanlış Sınıflandırma	Başarı %
1	36	12	11	1	91.67
2	36	12	12	0	100
3	36	12	11	1	91.67
4	36	12	11	1	91.67
5	36	12	11	1	91.67
Ortalama	36	12	11.2	0.8	93.34

Çizelge incelendiğinde YSA eğitimi işleminin 5 kez tekrarlanması sonucunda ortalama başarı oranı %93.34'dür. En başarılı seçim değeri %100 ile 2 numaralı veri setidir. 5 kez tekrarlanan eğitim işlemi içerisinde başarı oranı en yüksek olan sınıflandırma sonucu için 15.000 adım süresince, eğitim verileri başarı oranı ve sistemin genel hata değişimi Şekil 7.24'de gösterilmiştir.



Şekil 7.24. 2 sınıflı ağ için eğitim aşaması doğru sınıflandırma grafiği

3 sınıflı (1/A, 1/B ve 2/A) YSA parametreleri Çizelge 7.16'de verilmiştir. Bu parametreler doğrultusunda tasarlanmış YSA'nın yapısı Şekil 7.25'de gösterilmiştir.



Şekil 7.25. Tasarlanan bulanık girişli 3 sınıflı YSA yapısı

Çizelge 7.16. YSA parametreleri (3 sınıflı)


Parametre	Değerler
Giriş katman nöron sayısı	12
Gizli katman nöron sayısı	30
Çıkış katman nöron sayısı	3
Aktivasyon fonksiyonu	Tanjant Hiperbolik
Maksimum adım sayısı	15.000
Eğitime giren veri sayısı	36 (%75)
Test veri sayısı	12 (%25)

Sınıflama işleminin doğruluğunu onaylayabilmek amacı ile eğitim ve test işlemi beş kez tekrar edilmiştir. Rastgele belirlenen eğitim ve test verileri YSA ile eğitim işlemine tabi tutulup, sonrasında test edilmiştir. Bu işlemin sonucu Çizelge 7.17’de sonuçları gösterilmiştir.

Çizelge 7.17. 3 sınıflı ağ için beş tekrar eğitim/test işlemi sonuçları

İşlem No	Eğitim Verisi	Test Verisi	Doğru Sınıflandırma	Yanlış Sınıflandırma	Başarı %
1	36	12	11	1	91.67
2	36	12	10	2	83.34
3	36	12	11	1	91.67
4	36	12	12	0	100
5	36	12	11	1	91.67
Ortalama	36	12	11	1	91.67

Çizelge incelendiğinde YSA eğitimi işleminin 5 kez tekrarlanması sonucunda ortalama başarı oranı %91.67’dir. En başarılı seçim değeri %100 ile 4 numaralı veri setidir. 5 kez tekrarlanan eğitim işlemi içerisinde başarı oranı en yüksek olan sınıflandırma sonucu için 15.000 adım süresince, eğitim verileri başarı oranı ve sistemin genel hata değişimi Şekil 7.26’da gösterilmiştir.



Şekil 7.26. 3 sınıflı ağ için eğitim aşaması doğru sınıflandırma grafiği

7.3. Sınıflandırma Sonuçlarının Değerlendirilmesi

Bu çalışmada US görüntüleri üzerinden GKD teşhisinde iki farklı yaklaşımda bulunulmuştur. Bunlar, Graf yöntemi ve yapay zekâ yöntemi olarak sıralanabilir.

Graf yönteminde, US görüntüleri üzerinden elde edilen alfa ve beta açıları değerlendirilmiş ve tiplendirme yapılmıştır. Çalışmadan elde edilen tiplendirmeler, uzmanın karar verdiği tiplendirmelerle karşılaştırılmıştır. Yalnızca Tip I temel alınarak sınıflandırma yapıldığında elde edilen başarı oranı %80'dir. Bunun yanında, Tip I ve Tip II birlikte değerlendirilerek sınıflandırma yapıldığında ise elde edilen başarı oranı %76'dır.

Yapay zekâ yaklaşımında ise iki farklı giriş veri seti ve buna karşılık iki farklı çıkış seti kullanılmıştır. 50 adet US görüntüsünden 2 adedinde femur bölgesi tespitinde hata olduğundan 48 adet US görüntüsüne ait veriler giriş olarak YSA yazılımına verilmiştir.

İlk giriş veri seti alfa, beta açıları ile temel çizgi/femur oranı değerleridir. Bu giriş değerleri için kullanılacak çıkış verileri ise yalnızca Tip I değerini içeren 2 sınıflı (1, 2) veriler ve Tip I ve Tip II (1/A, 1/B, 2/A) değerlerini içeren 3 sınıflı verilerdir. Eğitim işlemleri sırasında giriş verilerinden %75'i yani 36 adet giriş eğitim, geriye kalan %25 yani 12 adet giriş test için kullanılmıştır. Eğitim ve test grubu verileri rastgele seçilmiş ve bu işlem 5 defa tekrarlanarak sistemin güvenilirliği sağlanmaya çalışılmıştır.

Bu veri setinin, yalnızca Tip I temel alınarak YSA ile sınıflandırma yapıldığında elde edilen en yüksek başarı oranı %83.34 ve 5 kez tekrarlamadan sonra elde edilen ortalama başarı oranı %80'dir. Bununla birlikte, Tip I ve Tip II birlikte değerlendirilerek sınıflandırma yapıldığında ise elde edilen en yüksek başarı oranı %83.34 ve 5 kez tekrarlamadan sonra elde edilen ortalama başarı oranı %75'dir.

İkinci giriş veri seti alfa, beta açıları ile temel çizgi/femur oranlarının Düşük, Orta, Yüksek gibi bulanık sınıflara ait üyelik derecelerini içeren veri kümeleridir. Bu giriş değerleri için kullanılacak çıkış verileri ise yalnızca Tip I değerini içeren 2 sınıflı (1, 2) veriler ve Tip I ve Tip II (1A, 1B, 2A) değerlerini içeren 3 sınıflı verilerdir. Eğitim işlemleri sırasında giriş verilerinden %75'i yani 36 adet giriş eğitim, geriye kalan %25 yani 12 adet giriş test için kullanılmıştır. Eğitim ve test grubu verileri rastgele seçilmiş ve bu işlem 5 defa tekrarlanarak sistemin güvenilirliği sağlanmaya çalışılmıştır.

Bulanıklaştırılmış bu veri setinin, yalnızca Tip I temel alınarak YSA ile sınıflandırma yapıldığında elde edilen en yüksek başarı oranı %100 ve 5 kez tekrarlamadan sonra elde edilen ortalama başarı oranı %93.34'dür. Bununla birlikte, Tip

I ve Tip II birlikte değerlendirilerek sınıflandırma yapıldığında ise elde edilen en yüksek başarı oranı %100 ve 5 kez tekrarlardan sonra elde edilen ortalama başarı oranı %91.67'dir.

GKD teşhisine yönelik yapılan sınıflandırma işleminde uygulanan Graf ve YZ yaklaşımlarında elde edilen tüm başarı oranları Çizelge 7.18'de verilmiştir.

Çizelge 7.18. Sınıflandırma yöntemlerinin karşılaştırılması

Yöntem	Başarı Oranı En Yüksek (%)		Başarı Oranı Ortalama (%)	
	Tip I	Tip I-II	Tip I	Tip I-II
GRAF	80.00	76.00	-	-
YSA	83.34	83.34	80.00	75.00
BSA ₁	100.00	100.00	93.34	91.67

Bu sonuçlara göre BSA₁ yöntemi kullanılarak yapılan sınıflandırma tekniği en yüksek başarı oranına sahiptir. Graf yöntemi ile YSA yönteminden alınan sonuçlara bakıldığında YSA yönteminin başarı oranı Graf yöntemi başarı oranına göre biraz daha yüksek olduğu görülmektedir.

8. SONUÇLAR VE ÖNERİLER

8.1. Sonuçlar

Gelişimsel kalça displazisi (GKD) veya kalça çıkığı, femur başı ile asetabulum arasındaki uyumsuzluk sonucu meydana gelen yapısal bir bozukluktur. Dünya’da sıklığı 1/3000 olarak saptanan bu hastalığın prevalansı Japonya ve Akdeniz Havzası’nda daha yüksektir. GKD erken tanı ile başarılı bir şekilde tedavi edilebilir. Tanıda ve tedavide gecikme uzuv kısalığı, topallama ve fonksiyonel özürülük gibi kısıtlı hareket bozukluklarına neden olabilir. Yürüme çağına gelmiş çocuklarda ise, konservatif tedavi şansı kalmamaktadır. Cerrahi tedavi ile de olguların tümünde başarılı sonuçlar almak olanaksızdır.

Tüm bu durumlar göz önüne alındığında, erken tanı ve tedavinin ne kadar önemli olduğu ortaya çıkmaktadır. Erken teşhis için fiziksel muayene ve Ultrason (US) ile görüntüleme şeklinde iki yöntem kullanılmaktadır. Fiziksel muayene uzmanın el becerisi ve deneyimine bağlı bir uygulamadır. US görüntüleme yönteminde ise teşhis işlemi için literatürde kabul görmüş Graf yöntemi kullanılmaktadır. Graf yönteminin uygulanmasında uzmanın deneyiminden kaynaklanan hatalar oluşabilmektedir. GKD teşhisine yönelik bilgisayar destekli araştırmalar yapılmaktadır. Ancak bu çalışmalar US görüntülerinin filtrelemelerle iyileştirilmesinin ötesine gidememiştir. US görüntülerinin alınmasında ve görüntü üzerinden manuel olarak ölçüm yapılmasında zorluklar vardır. Bu zorluklar uzmanın becerisine ve bilgisine bağlı olarak hatalı sonuçlar edinilmesine sebep olmaktadır. Bilgisayar destekli teşhis yöntemi ile bu zorlukların giderilmesi ve ölçüm hatalarının azaltılması sağlanabilir.

Bu çalışmada US görüntüleri üzerinde GKD teşhisinde doktor, radyolog ve uzmana yardımcı olabilecek ve uzmandan bağımsız çalışabilecek bir bilgisayar destekli teşhis sistemi sunulmuştur. Çalışmamızda geliştirilen yazılım ile GKD teşhisinde oluşan sorunların önüne geçilmesi hedeflenmektedir.

Çalışmada iki farklı görüntü grubu kullanılmıştır. Bunlardan Selçuk Üniversitesi Tıp Fakültesi Radyoloji A.B.D. ’dan alınan görüntüler (10 adet) filtreleme aşamasında kullanılmıştır. Diğer görüntü grubu ise Bağcılar Eğitim ve Araştırma Hastanesinden alınan, 25 adet hastadan sağ ve sol kalça olmak üzere toplam 50 adet görüntüden oluşmaktadır. Bu 50 görüntü segmentasyon, özellik çıkarımı ve sınıflandırmada kullanılmıştır. Tüm görüntüler 0-3 ay arası yeni doğan bebeklerden alınmıştır.

Çalışmanın ilk aşamasında US görüntülerine 7 adet filtre (Mean, Median, Gaussian, Wiener, Perona & Malik, Lee, Frost) uygulanmıştır. Bu filtreler US görüntülerinin iyileştirilmesi amacıyla uygulanmış ve görüntü üzerinde yer alan gürültülerin atılması sağlanmıştır. Filtreleme işlemi sonrası elde edilen görüntüler hem göz ile hem de PSNR ve MSE değerlerine bakılarak değerlendirilmiştir. Ayrıca filtrelerin etkisinin araştırılması amacıyla görüntü segmentasyonu uygulanmış ve sonuçlar analiz edilmiştir. Ön işlem aşaması genel olarak değerlendirildiğinde; Wiener, Perona Malik ve Lee filtreleri istatistiksel ölçme değerlendirme verilerine göre görüntü kalitesini iyileştirmede en başarılı sonucu vermiştir. Görüntü segmentasyon testi (AKM yöntemi uygulanarak) sonuçlarına göre ilium bölgesi tespitinde Perona Malik filtresi el ile yapılan segmentasyon sonucuna en yakın değeri vermiştir. Görüntü segmentasyon testi (DHD yöntemi uygulanarak) sonuçlarına göre femur bölgesi tespitinde Wiener filtre en başarılı sonucu vermiştir. Bununla birlikte, histogram eşitleme yöntemi uygulandığında Wiener filtreye oranla femur bölgesi tespitinde daha başarılı sonuç alındığı gözlenmiştir.

Segmentasyon aşamasında GKD teşhisinde gerekli olan değerleri elde etmek için görüntüde bulunan ilium, femur, asetabular çatı ve labrum bölgeleri belirlenmiştir. Ilium, asetabular çatı ve labrum bölgelerinin belirlenmesinde Aktif Kontur Model (AKM) yöntemi kullanılmıştır. Femur bölgesinin tespitinde ise Dairesel Hough Dönüşümü (DHD) yöntemi uygulanmıştır. Bu aşamada AKM yöntemi ile öncelikle ilium bölgesinde yer alan ve alfa beta açılarının belirlenmesinde rol alacak olan referans noktası tespit edilmiştir. Bu işlemde ilium bölgesi görüntüsü üzerinde aşınma, genleşme, inceltme, iskelet çıkarma, budama ve dal noktası belirleme gibi morfolojik yöntemleri kullanılmıştır. Ardından yine AKM tekniği uygulanarak labrum ve asetabular çatı bölgesinde yer alan ve yine alfa-beta açılarını belirleyecek olan kemik çatı çizgisi ve kırıkdağ çatı çizgisinin çizileceği alt ve üst referans noktaları tespit edilmiştir. Femur bölgesi tespitinde ise ilium bölgesinde önceden belirlenmiş olan merkez referans noktasının konum bilgileri dikkate alınarak DHD yöntemi uygulanmış ve dairesel femur çukurluğu tespit edilmiştir. Bu aşamada görüntü segmentasyonunda sıkça tercih edilen histogram eşitleme işlemi ön işlem olarak uygulanmış ve 50 adet US görüntüsünden 48 adedinde femur dairesi doğru olarak tespit edilmiştir.

Özellik çıkarımı aşamasında, segmentasyon aşamasında belirlenmiş olan ilium, femur, asetabular çatı ve labrum bölgeleri üzerinde bilgisayar destekli otomatik olarak ölçümler yapılmıştır. Bu ölçümler, uzmanların GKD teşhisinde tiplendirme amacı ile kullandıkları alfa ve beta açıları ile bu çalışmada yeni bir yaklaşım olarak önerilen temel

çizgi/femur oranı değerlerini içermektedir. Alfa açısının ölçümünde temel çizgi, referans noktası ve asetabular çatı bölgelerinden yararlanılmıştır. Bu işlemde kemik çatı çizgisi (asetabular çatının en alt noktası ile referans noktası arasındaki doğru) belirlenmiş ve bu doğru ile temel çizgi arasında kalan açı ölçülmüştür. Beta açısının ölçümünde ise temel çizgi, referans noktası ve labrum bölgelerinden yararlanılmıştır. Bu işlemde kıkırdak çatı çizgisi (labrumun bitiş noktası ile referans noktası arasındaki doğru) belirlenmiş ve bu doğru ile temel çizgi arasında kalan açı ölçülmüştür. Açı ölçümlerinde görülmüştür ki; referans noktası, asetabular çatı alt noktası ve labrum bitiş noktasının doğru olarak belirlenmesi büyük önem taşımaktadır. Uzmanlarla yapılan görüşmelerde, açı değerlerinin GKD teşhisinde kullanımında öncelikle alfa açısı dikkate alınmaktadır ve bu açı değerine göre GKD 'li / GKD 'siz teşhisi konmaktadır. GKD 'li olarak teşhis edilen hastanın bir sonraki aşamada beta açıları dikkate alınarak, GKD'nin seviyesi belirlenir ve tiplendirme yapılmaktadır. Bu aşamada, uzmanın tavsiyesi ile temel çizgi doğrusunun femur bölgesindeki uzantısına göre oran ölçüm değerlerine bakılmıştır. Elde edilen temel çizgi/femur oran değeri sınıflandırmada alfa ve beta açısı yanında ekstra bir giriş verisi olarak alınmıştır. Sınıflandırma aşamasında, temel çizgi/femur oranının alfa ve beta açıları dışında kullanılabilecek anlamlı bir giriş verisi olduğu ve GKD teşhisinde başarıyı artırdığı görülmüştür.

Sınıflandırma aşamasında, US görüntülerine ait alfa-beta açıları ile temel çizgi/femur oranı değerleri kullanılmıştır. Bu aşamada iki farklı yaklaşımda bulunulmuştur. İlk yaklaşımda literatürde sıkça kullanılan ve uzmanlarca kabul görmüş Graf yöntemine göre alfa ve beta açıları kullanılarak GKD teşhisi yapılmıştır. İkinci yaklaşımda ise alfa-beta açıları ile temel çizgi/femur oranı değerleri birlikte kullanılarak YSA ve BSA sınıflandırma yöntemleri kullanılmıştır. Bu yöntemler, bu tez çalışması kapsamında önerilen ve bu alanda yapılan önceki araştırmalarda kullanılmamış yeni bir yaklaşımdır.

Günümüzde uygulanan GKD teşhisinde uzman radyologlar US ölçüm verilerine göre Tip I (1, 2, 3 ve 4) ve Tip II (A, B, C ve D) şeklinde tiplendirme yapmaktadır. Tip I değeri GKD 'li-GKD 'siz ayrımında, Tip II değeri ise GKD 'li hastanın hastalık derecesini belirlemektedir. Bu çalışmada kullanılan veriler Tip I (1 ve 2), Tip II (A ve B) gruplarına girmektedir. Dolayısıyla sınıflandırma aşamasında bu tiplendirme gruplarına göre işlemler yapılmıştır.

Graf yöntemi yaklaşımında, sadece Tip I değerine bakıldığında 50 adet US görüntüsünden 40 tanesinde uzman değerlendirmesi ile bilgisayar değerlendirmesi

sonucu uyuşmaktadır. Tip I ve Tip II değerlerine birlikte bakıldığında ise 50 adet görüntüden 38 adedinde uzman değerlendirmesi ile bilgisayar değerlendirmesi uyuşmaktadır. Dolayısıyla, Graf yöntemi üzerinden GKD teşhisinde yalnızca Tip I temel alınarak sınıflandırma yapıldığında elde edilen başarı oranı %80, Tip I ve Tip II temel alınarak sınıflandırma yapıldığında ise elde edilen başarı oranı %76'dır.

Yapay sinir ağı (YSA) yaklaşımında giriş veri seti alfa, beta açıları ile temel çizgi/femur oranı değerleridir. 2 sınıflı (1 ve 2) çıkışa sahip YSA yapısında gerçekleştirilen sınıflandırma işlemi sonucu 5 kez tekrardan sonra ortalama %80 başarı elde edilmiştir. 3 sınıflı (1/A, 1/B ve 2/A) çıkışa sahip YSA yapısında gerçekleştirilen sınıflandırma işlemi sonucu 5 kez tekrardan sonra ortalama %75 başarı elde edilmiştir.

Bulanık sinir ağı (BSA) yaklaşımında ise giriş veri setinde yer alan alfa, beta ve temel çizgi/femur oranı değerleri bulanık küme oluşturma yöntemi kullanılarak Düşük, Orta, Yüksek bulanık kümelerine dönüştürülmüş ve küme üyelik dereceleri YSA 'ya giriş olarak verilmiştir. Elde edilen giriş veri seti; 4 adet giriş verisinden, 12 adet giriş verisine çıkmıştır. Bu yaklaşımda da YSA yaklaşımında olduğu gibi 2 sınıflı ve 3 sınıflı çıkış içeren sınıflandırma gerçekleştirilmiştir. 2 sınıflı (1 ve 2) çıkışa sahip BSA yapısında gerçekleştirilen sınıflandırma işlemi sonucu 5 kez tekrardan sonra ortalama %93.34 başarı elde edilmiştir. 3 sınıflı (1/A, 1/B ve 2/A) çıkışa sahip BSA yapısında gerçekleştirilen sınıflandırma işlemi sonucu 5 kez tekrardan sonra ortalama %91.67 başarı elde edilmiştir.

Bu sonuçlardan da anlaşılacağı üzere, günümüzde kullanılan Graf yaklaşımı yönteminde keskin geçişlere sahip alfa ve beta değerlerinin kullanılması sonucu bilgisayar destekli GKD teşhisi işlemi başarı oranı %80'lerde kalmaktadır. Graf yaklaşımında kullanılan verilerle birlikte bu tez çalışmasında yeni bir öneri olarak sunulan temel çizgi/femur oranı değerleri doğrudan YSA 'ya verildikten sonra yapılan sınıflandırma başarı oranı da yine %80 civarındadır. Bu durum giriş verileri olarak kullanılan ve GKD teşhisi amacıyla ölçülen alfa, beta ve temel çizgi/femur oranı değerlerinin tiplendirilmesinde keskin çizgilerle ayrılmasından kaynaklandığına bir gösterge olabilir. Bu amaçla giriş verilerinin bulanıklaştırılarak, bulanık küme üyelik derecelerinin sinir ağına (BSA) verilmesi ve sınıflandırmanın bu yeni değerlerle yapılması işlemi gerçekleştirilmiştir. BSA 'da yapılan sınıflandırma işlemi sonrasında %93,34 gibi diğer yöntemlere oranla daha yüksek bir teşhis başarısı elde edilmiştir.

8.2. Öneriler

Çalışmadan elde edilen sonuçlar değerlendirildiğinde aşağıdaki önerilerde bulunulabilir.

- Genellikle gürültü oranı yüksek olan ultrason görüntülerinin iyileştirilmesinde farklı teknikler uygulanmış ve Wiener filtrenin ultrason görüntülerinin gürültülerini gidermede ve görüntü kalitesinin artırılmasında en başarılı sonucu verdiği görülmüştür. Bununla birlikte histogram eşitleme yönteminin de dairesel bölgelerin belirlenmesinde başarıyı artırdığı söylenebilir.
- Segmentasyon aşamasında kullanılan aktif kontur model yönteminde genişlemenin başlayacağı noktanın önemi büyüktür. Bu çalışmada, ilium bölgesinin belirlenmesinde en yüksek gri seviye piksel değeri temel alınarak genişleme yapılmıştır. Başka bir çalışmada bu noktanın belirlenmesinde farklı bir özellik kullanılabilir.
- Graf yöntemine göre sınıflandırmada, alfa ve beta açılarının keskin geçişlere sahip olması teşhisin doğruluğunu olumsuz etkilemektedir. Bu geçişlerin birbirini kenarlarından kapsayacak şekilde yapılması GKD teşhisinin doğruluğu açısından önerilebilir.
- Graf yönteminde alfa ve beta açılarının keskin geçişleri sonucu olumsuz etkilediği için alternatif bir yöntemin önerilmesine ihtiyaç duyulmaktadır. Bu amaçla, uzmanların da görüşüne başvurularak temel çizgi/femur oran verileri GKD teşhisinde giriş verisi olarak kullanılmış ve başarılı sonuçlar alınmıştır. Bu yaklaşımın uzman doktor/radyologlar tarafından da kullanılması önerilebilir.
- YSA'da kullanılan giriş değerlerinin keskin geçişler ile birbirinden ayrıldığı durumlarda sistemin başarısını artırmak için genelde eğitime katılan örnek sayısı artırılmaktadır. Bu durumda giriş değerlerinin bulanıklaştırılarak elde edilen bulanık küme üyelik derecelerinin bulanık sinir ağına (BSA) giriş olarak verilmesi, sınıflandırma başarısını aynı sayıdaki eğitim kümesine oranla artırdığı için bu yöntemin bilgisayar destekli GKD teşhisinde kullanılması önerilebilir.
- Bu çalışmanın devamı niteliğinde sayılabilecek gerçek zamanlı GKD teşhisine yönelik araştırmalar yapılabilir. Bu araştırmalar neticesinde ortaya çıkacak

olan yazılımlar ultrason cihazına da eklenerek uzmanların anlık olarak GKD teşhisini yapabilmeleri sağlanabilir.

Sonuç olarak, GKD teşhisinin fiziksel muayene zorluğu, US görüntüleri üzerinde Graf yönteminin uygulanmasının göreceliliği ve uzman bilgisine dayanması, bu rahatsızlığa yakalanan kişilerdeki yaşam kalitesinin düşmesi, uzuv kısalığı, topallama, fonksiyonel özürlülük ve tedavi maliyetlerinin büyüklüğü gibi parametreler düşünüldüğünde; tez çalışmasında geliştirilen bilgisayar destekli GKD teşhis sisteminin önemi ortaya çıkmaktadır.



EKLER**EK-1 Etik Kurul Kararları**

T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI

GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU KARARLARI**Toplantı Sayısı: 2014/11****Toplantı Tarihi : 27.05.2014**

Karar Sayısı 2014/162 S.Ü. Tıp Fakültesi Radyoloji Anabilim Dalı Öğretim Üyesi Doç.Dr. Mustafa KOPLAY'ın, "Görüntü İşleme Teknikleri ile Gelişimsel Kalça Displazisi Teşhisi" başlıklı araştırmasının değerlendirilme talebi ile ilgili 14.05.2014 tarihli dilekçesi ve ekleri görüşüldü.

Yapılan inceleme ve görüşmelerden sonra; Doç.Dr. Mustafa KOPLAY'ın, "Görüntü İşleme Teknikleri ile Gelişimsel Kalça Displazisi Teşhisi" adlı araştırmanın kabulüne, TÜBİTAK desteği alındıktan sonra protokolün dosyaya ilave edilmek üzere Etik Kurul sekreteryasına teslim edilmesine oy birliği ile karar verildi.

ASLI GİBİDİR
27/05/2014
Mehmet KESİK
Sekreteryası



T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI


GİRİŞİMSEL OLMAYAN KLİNİK ARAŞTIRMALAR ETİK KURULU KARARLARI**Toplantı Sayısı: 2016/1****Toplantı Tarihi : 12.01.2016**

Karar Sayısı 2016/14 Kurulumuzun 27.05.2014 tarih ve 2014/162 sayılı karar ile uygunluğu verilen Selçuk Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı Öğretim Üyesi Doç.Dr. Mustafa KOPLAY'ın, "Görüntü İşleme Teknikleri ile Gelişimsel Kalça Displazisi Teşhisi" adlı doktora tez çalışması ile ilgili araştırma projesinin yürütücüsünün S.Ü. Teknik Eğitim Fakültesi Elektronik ve Bilgisayar Eğitimi Bölümü Öğretim Üyesi Yrd.Doç.Dr. Hasan Erdiç KOÇER olarak değiştirilmesi talebi ile ilgili 30.12.2015 tarihli dilekçesi görüşüldü

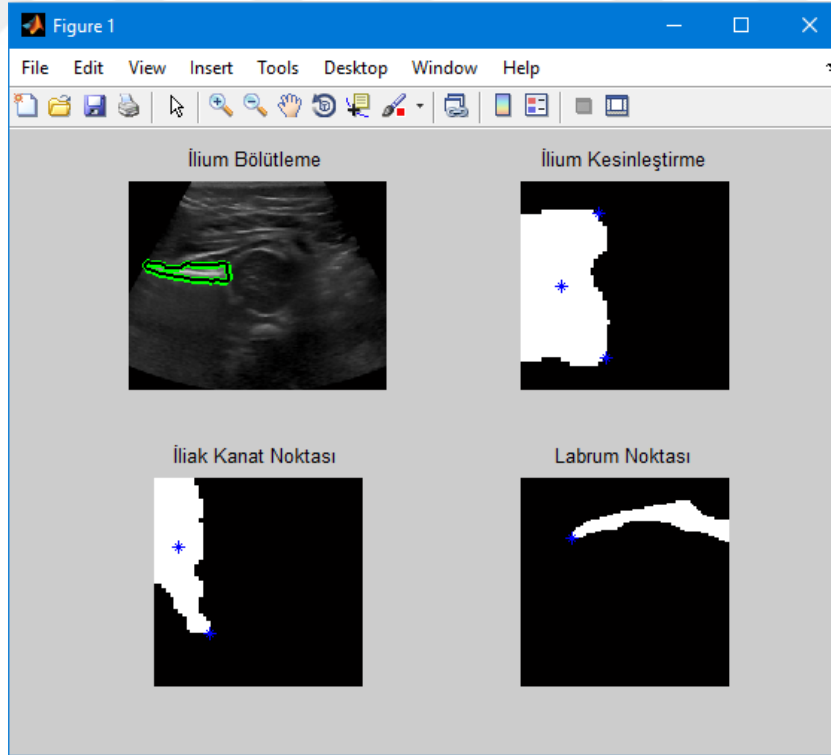
Yapılan inceleme ve görüşmelerden sonra; Doç.Dr. Mustafa KOPLAY'ın, 30.12.2015 tarihli dilekçesinin kabulüne oy birliği ile karar verildi.

ASLI GİBİDİR
12/01/2016
Mehmet KESİK
Sekreteryası


EK-2 MATLAB Yazılımı Ekran Görüntüleri




Şekil Ek-2.1. Görüntülerin ön işlenmesi



Şekil Ek-2.2. Görüntülerin segmentasyonu




Şekil Ek-2.3. Özellik çıkarımı




Şekil Ek-2.4. Sınıflandırma ve teşhis

EK-3 Alyuda NeuroIntelligence Programı Ekran Görüntüleri

US görüntüleri üzerinde yapılan görüntü işleme uygulamaları ile ortaya çıkan veri kümesi Graf yönteminin yanı sıra Alyuda NeuroIntelligence paket programı ile eğitilmiş ve sonuçları yine bu program test edilmiştir. Tez çalışması sırasında kullanılan bu programın ekran görüntüleri Şekil Ek-5-Ek-6'da gösterilmiştir.



Şekil Ek-3.1. Alyuda NeuroIntelligence sınıflandırma programı



Şekil Ek-3.2. Alyuda NeuroIntelligence sınıflandırma programı

EK-4. Görüntü Morfolojisi

Morfoloji (biçimbilim), en genel anlamıyla biyolojide hayvanlar ve bitkileri biçim ve yapıları ile ilgili olan bir bilim dalıdır. Aynı kelime matematiksel morfoloji bağlamında, görüntüdeki sınırlar, iskeletler ve dışbükey zarf gibi bölgesel şekillerin tanım ve temsilinde görüntü bileşenlerini elde edebilmek için kullanılacak teknik ya da teknikleri niteler (Gonzalez ve Woods, 2002).

Görüntü morfolojisi, matematiksel olarak geometrik nesnelere ilgili işlem ve analiz yapma teorisi ve tekniğidir. Morfoloji işlemleri genelde ikili ve gri seviye görüntüler üzerinde uygulanmaktadır. Literatürde en çok bilinen ve kullanılan morfolojik işlemler; Aşınma (Erosion), Genleşme (Dilation), Açınım (Opening), Kapanım (Closing), Rastgele Dönüşümler (Hit and Miss Transforms), İskeletler (Skeletonization), İnceltme (Thinning), Budama (Pruning), Kalınlaştırma (Thickening)'dir (Gonzalez ve Woods, 2002; Fisher ve ark., 2004).


Ek-4.1. Aşınma (Erosion)

Aşınma, görüntüde yer alan bölgesel alanların kenarlarında içe doğru daraltılmasını sağlayan matematiksel işlemidir. Genellikle ikili görüntülere uygulanan aşınma işlemi, gri seviye resimlere de uygulanabilmektedir (Jain, 1989). Aşınma işleminde giriş görüntüsü ve yapısal bileşen olmak üzere iki değişken kullanılır. Yapısal bileşen görüntü üzerinde gezdirilerek eşleşme anında merkez piksel işaretlenir (Gonzalez ve Woods, 2002).

1	1	1
1	1	1
1	1	1


Şekil Ek-4.1. Aşınma ve genleşme için kullanılan yapısal bileşen

Şekil Ek4.1’de görüldüğü gibi 3x3 lük bir matris yapısal eleman olarak kullanılabilir. Bu yapısal eleman genellikle küçük boyuttaki görüntüler için tercih edilir. Daha büyük formdaki yapısal elemanlar daha fazla aşınmaya sebep olurlar (Shapiro ve Haralick, 1992). Problemin durumuna göre yapısal elemanın boyutu belirlenebilir. Bu yöntemi bir örnek üzerinde açıklayalım. Şekil 5.5’de 3x3’lük bir yapısal eleman görüntü üzerinde gezdirilerek, merkez noktaları eşleştiği alanlar 1 yapılmış diğer alanlar 0 yapılmış ve sonuç görüntüsü elde edilmiştir (Fisher ve ark., 2004).



Şekil Ek-4.2. 3x3 yapısal bileşen kullanılarak aşınma etkisi (Fisher ve ark., 2004)

Gri seviye görüntülerde aşınma işlemi genellikle görüntüyü daha karanlık yapmaktadır. Bunun sebebi karanlık bölgeler tarafından çevrelenmiş aydınlık bölgeler daralmakta, aydınlık bölgeler tarafından çevrelenmiş karanlık bölgeler genişlemektedir (Vernon, 1991) (Şekil Ek-4.3).




Şekil Ek-4.3. Disk şeklinde yapısal eleman kullanılarak uygulanan gri seviye aşınma

Ek-4.2. Genleşme (Dilation)


Genleşme, görüntüde yer alan bölgesel alanların kenarlarından dışa doğru genişletilmesini sağlayan matematiksel işlemidir. Genellikle ikili görüntülere uygulanan genişleme işlemi, gri seviye resimlere de uygulanabilmektedir (Vernon, 1991).

Genişleme işleminde giriş görüntüsü ve yapısal bileşen olmak üzere iki değişken kullanılır. Yapısal bileşenin merkezi görüntü üzerinde eşleştiğinde tüm pikseller işaretlenir. Genleşme işleminde de yapısal eleman olarak Şekil Ek-4.1'deki gibi 3x3 lük bir matris kullanılır (Gonzalez ve Woods, 2002). Bu yöntemi bir örnek üzerinde açıklayalım. Şekil Ek-4.2'de 3x3'lük yapısal eleman görüntü üzerinde gezdirilerek, yapısal bileşenin merkez noktası eşleştiği anda tüm alanlar 1 yapılarak oluşturulmuş sonuç görüntüsü elde edilmiştir (Şekil Ek-4.4).



Şekil Ek-4.4. 3x3 yapısal bileşen kullanılarak genişleme etkisi (Fisher ve ark., 2004)

Gri seviye görüntülerde genişleme işlemi genellikle görüntüyü daha aydınlık yapmaktadır. Bunun sebebi karanlık bölgeler tarafından çevrelenmiş aydınlık bölgeler genişlemekte, aydınlık bölgeler tarafından çevrelenmiş karanlık bölgeler daralmaktadır (Shapiro ve Haralick, 1992) (Şekil Ek-4.5).




Şekil Ek-4.5. Disk şeklinde yapısal eleman kullanılarak uygulanan gri seviye genişleme

Ek-4.3. Açınım (Opening)

Açınım işlemi en basit şekilde, önce aşınma, ardından genişleme işlemlerinin aynı yapısal eleman kullanılarak arka arkaya uygulanması işlemidir (Vernon, 1991). Açınım işleminin temel etkisi, aşınmada olduğu gibi ön planda bulunan piksellerin kenar

bölgelerini aydınlık bölümlerini ortadan kaldırmak olarak tanımlanabilir. Ancak aşınmaya göre daha az yıkıcıdır. Diğer operatörlerde olduğu gibi çalışma sonucu kullanılan yapısal elemanın boyutuna göre değişmektedir. Yöntem, yapısal elemana benzerlik gösteren bölümlerini korurken, benzerlik göstermeyen alanları ise aşınmaya uğratmaktadır (Fisher ve ark., 2004).




Şekil Ek-4.6. On bir piksel çapında dairesel yapısal bileşen kullanılarak uygulanan açınım sonucu (Fisher ve ark., 2004)

Bir görüntü içerisindeki dairesel bölgelerin diğer kısımlardan arındırılması istendiği zaman açınım işlemi uygulamak en doğru sonucu verecektir. Yapılması gereken işlem, görüntü içerisindeki dairesel alanların boyutlarına uygun bir dairesel yapısal eleman belirlemek ve bu yapısal elemanı görüntü üzerinde dolaştırarak açınım işlemi uygulamaktır. Şekil Ek-4.6'da 11x11 piksel boyutunda dairesel bir yapısal eleman kullanılarak uygulanan açınım işlemi ve sonucu gösterilmiştir (Shapiro ve Haralick, 1992).

Ek-4.4. Kapanım (Closing)

Kapanım işlemi açınımın tersine, önce genişleme, ardından aşınma işlemlerinin aynı yapısal eleman kullanılarak arka arkaya uygulanması işlemidir (Gonzalez ve Woods, 2002). Kapanım işleminin temel etkisi, genişlemede olduğu gibi ön planda bulunan piksellerin kenar bölgelerini aydınlık bölümlerinin sınırlarını genişletmek olarak tanımlanabilir. Ancak genişlemeye göre daha az yıkıcıdır. Diğer operatörlerde olduğu gibi çalışma sonucu kullanılan yapısal elemanın boyutuna göre değişmektedir. Yöntem, yapısal elemana benzerlik gösteren bölümlerin boyutlarını artırırken, benzerlik göstermeyen alanları ise korumaktadır (Fisher ve ark., 2004).




Şekil Ek-4.7. Yirmi iki piksel çapında dairesel yapısal bileşen kullanılarak uygulanan kapanım sonucu (Fisher ve ark., 2004)

Bir görüntü içerisindeki dairesel bölgelerin, diğer dairesel kısımlardan arındırılması istendiği zaman açınım işlemi uygulamak en doğru sonucu verecektir. Yapılması gereken işlem görüntü içerisindeki istenilen dairesel alanların boyutlarına uygun bir dairesel yapısal eleman belirlemek ve bu yapısal elemanı görüntü üzerinde dolaştırarak kapanım işlemi uygulamaktır. Şekil Ek-4.7’de 22x22 piksel boyutunda dairesel bir yapısal eleman kullanılarak uygulanan kapanım işlemi gösterilmiştir. Sonuç olarak istenilen boyutta ve şekildeki nesnel görüntü üzerinde kalmış, diğer alanlar ise görüntüden çıkartılmıştır (Ballard ve Brown, 1982; Jain, 1989; Vernon, 1991; Shapiro ve Haralick, 1992).


Ek-4.5. Rastgele Dönüşümler (Hit and Miss Transforms)

Rastgele dönüşümler ikili görüntüler üzerinde ön plan-arka plan analizi gerçekleştirirler. Diğer morfolojik işlemler bu analiz sonucu türetilir. Dönüşümler yapılırken yapısal elemanların seçimi analizin yönünü belirler (Gonzalez ve Woods, 2002).



Şekil Ek-4.8. Köşe noktaları belirlemek için kullanılan yapısal bileşen (4 farklı açı ile)


Şekil Ek-4.8’de verilen yapısal bileşen görüntüde yer alan köşelerin belirlenmesi amacıyla kullanılır. 3x3 lük bu yapısal bileşen görüntü üzerinde eşleştiginde merkez piksel işaretlenir. Bu işlem görüntü üzerinde bileşenin 4 farklı açısından da tekrarlanır. Bu sayede görüntü içerisinde bulunan köşe noktalar ortaya çıkartılır. Şekil Ek-4.9’da köşe noktaları belirleme yapısal bileşeni uygulanmış görüntü ve sonucu görülmektedir (Jain, 1989; Vernon, 1991; Shapiro ve Haralick, 1992).



Şekil Ek-4.9. Köşe noktaları belirleme yapısal bileşeninin görüntüye etkisi (Fisher ve ark., 2004)

Ek-4.6. İskelet Çıkartımı (Skeletonization)

İskelete dönüştürme işlemi ikili görüntüde yer alan arka plan kısımların inceltilerek çizgisel hale getirilmesi işlemidir. Bunun için inceltme (thinning) işlemi kullanılır. Bi-tanjant dairelerinin merkez noktalarını birleştirme yöntemi de iskelete dönüştürme amacıyla kullanılabilir (Ballard ve Brown, 1982; Davies, 2004) (Şekil 5.13).



Şekil Ek-4.10. Teğet çemberlerin merkez noktaları ile iskelet çıkartma (Fisher ve ark., 2004)

Ek-4.7. İnceltme (Thinning)

İnceltme işleminde diğer morfolojik işlemlerde olduğu gibi yapısal bileşenler kullanılır. Bunlar rastgele dönüşümlerde (hit and miss transform) bahsedilen yapısal bileşenlerdir (Jain, 1989).

$$thin(I, J) = I - hit.and.miss(I, J) \quad (Ek-4.1)$$

Denklem Ek-4.1'deki çıkartma işlemi lojik çıkarmadır. Denklem Ek-4.2'de gösterilmiştir.

$$X - Y = X \cap NOT Y \quad (Ek-4.2)$$


Morfolojik olarak inceltme yapılarak iskelet çıkarma işlemi için kullanılan yapısal bileşenler Şekil Ek-4.11'de verilmiştir. Bu bileşenler 90° döndürülerek 4 yönde uygulanır. Eşleşme durumunda merkez piksel "0" yapılır (Shapiro ve Haralick, 1992).

0	0	0
	1	
1	1	1

	0	0
1	1	0
	1	

Şekil Ek-4.11. Morfolojik iskelet çıkartma işlemi için kullanılacak yapısal eleman


İskelet çıkartmanın sonuca ulaşması için seçilen yapısal elemanın boyutu oldukça önemlidir. Yapısal eleman boyutu giriş görüntüsünün boyutu ile doğru orantılı olmak zorundadır. Aksi takdirde thinning işlemi birkaç defa giriş görüntüsüne uygulanılarak iskelet çıkartma sağlanabilir. Morfolojik olarak inceltme yapılarak iskelet çıkarma işlemi uygulanmış görüntü örneği Şekil Ek-4.12'de verilmiştir (Davies, 2004; Fisher ve ark., 2004).



Şekil Ek-4.12. Basit bir ikili şeklin morfolojik incilmesi ile örnek iskeletleştirme (Fisher ve ark., 2004)

Ek-4.8. Budama (Pruning)

Morfolojik olarak inceltme yapılarak iskelet çıkarma işleminde çıkan sonuç görüntüde bazı bölgelerde istenmeyen çıkıntılarla karşılaşmaktadır (Şekil Ek-4.13). Bu çıkıntıları gidermek için iskeleti çıkarılmış yeni görüntüye farklı yapıda yapısal bileşenler uygulanır. Bu işlemler budama (pruning) olarak adlandırılırlar (Gonzalez ve Woods, 2002).



Şekil Ek-4.12. Thinnig işlemi sonucunda iskeleti çıkartılmış görüntü analizi (Fisher ve ark., 2004)

Budama işlemi için birkaç farklı yapısal eleman kullanılabilir. Bazı yapısal elemanlar sınır çizgilerini bulup budama işlemi yaparken, bazı yapısal elemanlar ise çıkıntıları gidermektedir. Bu yapısal elemanlar Şekil Ek-4.13'de gösterilmiştir. Şekil Ek-

4.13’de gösterilen 1. ve 2. yapısal elemanlar sınır çizgilerini bulan yapısal bileşenlerdir. 3a ve 3b yapısal elemanları ise çıkıntıları gideren yapısal bileşenlerdir. Her bileşen 90° döndürülerek 4 yönde uygulanır (Fisher ve ark., 2004).

1)	<table border="1" style="display: inline-table; text-align: center;"> <tr><td>1</td><td>1</td><td>1</td></tr> <tr><td>1</td><td>1</td><td>1</td></tr> <tr><td>1</td><td>1</td><td>1</td></tr> </table>	1	1	1	1	1	1	1	1	1
1	1	1								
1	1	1								
1	1	1								


2)	<table border="1" style="display: inline-table; text-align: center;"> <tr><td></td><td>1</td><td></td></tr> <tr><td>1</td><td>1</td><td>1</td></tr> <tr><td></td><td>1</td><td></td></tr> </table>		1		1	1	1		1	
	1									
1	1	1								
	1									

3a)	<table border="1" style="display: inline-table; text-align: center;"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>1</td><td>0</td></tr> <tr><td>0</td><td></td><td></td></tr> </table>	0	0	0	0	1	0	0		
0	0	0								
0	1	0								
0										

3b)	<table border="1" style="display: inline-table; text-align: center;"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>1</td><td>0</td></tr> <tr><td></td><td></td><td>0</td></tr> </table>	0	0	0	0	1	0			0
0	0	0								
0	1	0								
		0								

Şekil Ek-4.13. Pruning (budama) işlemi için kullanılan yapısal elemanlar

Budama işlemi görüntü içerisindeki gereksiz alanların giderilmesinde kullanılır. Genellikle iskelet çıkarım sonrasında ihtiyaç olmayan alanların giderilmesi için budama işlemleri yapılmaktadır. Şekil Ek-4.14’de budama işlemine bir örnek verilmiştir (Vernon, 1991).



Şekil Ek-4.14. Pruning (budama) işlemi a) 3x3 yapısal bileşenle genişletme (dilation) yapıldıktan sonra, b) 3 kez tekrar inceltme (thinning) işlemi yapıldıktan sonra, c) çıkıntılar alındıktan (pruning) sonra, d) 3 kez tekrar edilen çıkıntı alma (pruning) işleminden sonra oluşan görüntü (Fisher ve ark., 2004)

Ek-4.9. Kalınlaştırma (Thickening)

Kalınlaştırma işlemi arka plan kısmının genişletilmesi olarak yapılır. J yapısal bileşen kullanılan bir rastgele dönüşüm işlemi için Denklem Ek-4.3'deki eşitlik kullanılır (Jain, 1989).

$$thicken(I,J) = I \cup hit. and. miss(I,J) \quad (Ek-4.3)$$

Kalınlaştırma için kullanılan yapısal bileşenler Şekil Ek-4.15'ea belirtildiği gibidir. Bu bileşenler 90° döndürülerek 4 yönde (toplamda 8 yapısal bileşen) uygulanır (Shapiro ve Haralick, 1992).

1	1	
1	0	
1		0

	1	1
	0	1
0		1

Şekil Ek-4.15. Kalınlaştırma işleminde kullanılan yapısal bileşen

Ek-4.10. Histogram Eşitleme

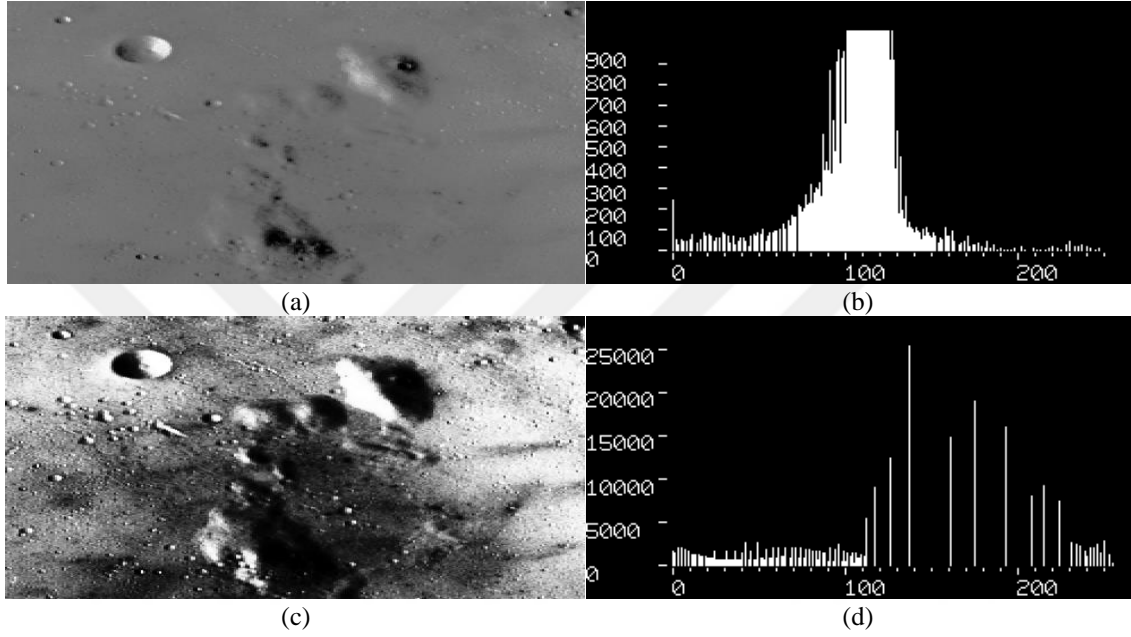
Histogram, sayısal bir resim içerisinde her renk değerinden kaç adet olduğunu gösteren grafikdir. Bu grafiğe bakılarak resmin parlaklık durumu ya da tonları hakkında bilgi sahibi olunabilir. Gri seviye bir resimde histogram grafiği 0-255 değeri arasında değişmektedir. Histogram eşitleme ise belirli bir ton etrafında toplanan histogram eğrisi (0-255) tonları arasına düzgün bir şekilde dağıtılarak resmin renk dağılımının homojen olarak yapılandırılması işlemidir (Şekil Ek-4.16).

Histogram eşitlemenin uygulama adımları şu şekildedir;

1. Resmin histogramı bulunur.
2. Histogramdan yararlanılarak kümülatif histogram bulunur. Kümülatif histogram, histogramın her değerinin kendisinden öncekiler ve kendisinin toplamı ile elde edilen değerleri içeren büyüklüktür.

3. Kümülatif histogram değerleri normalize edilip (toplam piksel sayısına bölünerek), yeni resimde olmasını istediğimiz maksimum renk değerleri ile çarpılır, çıkan değer tam sayıya yuvarlatılır. Böylelikle yeni gri seviye değerleri elde edilmiş olur.

Eski (Orijinal) gri seviye değerleri ile 3. adımda elde edilen gri seviye değerleri birbirine karşılık düşürülür ve yeni histogram grafiği çizilir.



Şekil Ek-4.16. Histogram eşitleme işlemi a) giriş görüntüsü, b) giriş görüntüsü histogram grafiği, c) histogram eşitleme yapılmış görüntü, d) histogram eşitleme sonucu oluşan histogram grafiği (Fisher ve ark., 2004)

Histogram eşitleme için kullanılan formül Denklem Ek-4.4'de verilmiştir. Denklemde kullanılan n , giriş görüntüsündeki toplam piksel sayısını ($n_0 + n_1 + \dots + n_{L-1} = n$, $n_j(n_k)$: j , gri seviyedeki piksel sayısını, L mümkün olan toplam gri seviye sayısını (8 bit renk derinliğinde 255 dir) ve s_k ise daha iyi kontrastlı bir görüntü elde etmek için gri seviye dönüşüm değerini belirtmektedir (Fisher ve ark., 2004).

$$S_k = \sum_{j=0}^k \frac{n_j}{n} * (L - 1) \quad (\text{Ek-4.4})$$

KAYNAKLAR

- Akiyama, K., Sakai, T., Koyanagi, J., Yoshikawa, H. ve Sugamoto, K., 2011, Evaluation of translation in the normal and dysplastic hip using three-dimensional magnetic resonance imaging and voxel-based registration, *Osteoarthritis and Cartilage*, 19 (6), 700-710.
- Aksu, N. ve Işıklar, Z. U., 2008, Kalça kırıkları, *TODBİD*, 7 (1-2), 8-19.
- Al-Bashir, A. K., Al-Abed, M., Abu Sharkh, F. M., Kordeya, M. N. ve Rousan, F. M., 2015, Algorithm for automatic angles measurement and screening for Developmental Dysplasia of the Hip (DDH), *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, 6386-6389.
- Allahverdi, N., 2002, Uzman sistemler: bir yapay zeka uygulaması, Atlas Yayın Dağıtım, p.
- Bache, C., Clegg, J. ve Herron, M., 2002, Risk factors for developmental dysplasia of the hip: ultrasonographic findings in the neonatal period, *J Pediatr Orthop B.*, 11 (3), 212-218.
- Ballard, D. H. ve Brown, C. M., 1982, Computer Vision, *Englewood Cliffs, N.J.*, Prentice-Hall, p.
- Baraldi, A. ve Parmiggiani, F., 1995, An Alternative Form of the Lee Filter for Speckle Suppression in SAR Images, *Graphical Models and Image Processing*, 57 (1), 75-78.
- Bayhan, A., 2007, İnstabil İntertrokanterik Femur Kırıklarında Proksimal Femoral Çivi Uygulamalarımız Ve Sonuçları, *Dissertation, TR Dr. Lütfi Kırdar Kartal Training and Research Hospital, 1st Clinic of Orthopedics and Traumatology, İstanbul.*
- Baykal, N. ve Beyan, T., 2004, Bulanık mantık: uzman sistemler ve denetleyiciler, Bıçaklar Kitabevi, p.
- Bodzioch, S. ve Ogiela, M. R., 2009, New approach to gallbladder ultrasonic images analysis and lesions recognition, *Comput Med Imaging Graph*, 33 (2), 154-170.
- Boran, G., 2006, Çanakkale ilinin ormanlık alanlarındaki değişimin uydu verileri ile belirlenmesi, *Çanakkale Onsekiz Mart Üniversitesi, Çanakkale*, 130.
- Cady, R. B. M. D., 2006, Developmental dysplasia of the hip: definition, recognition, and prevention of late sequelae, *Pediatric Annals*, 35 (2), 92-101.
- Chaichana, T., Yoowattana, S., Zhonghua, S., Tangjitkusolmun, S., Sookpotharom, S. ve Sangworasil, M., 2008, Edge detection of the optic disc in retinal images based on identification of a round shape, *Communications and Information Technologies, 2008. ISCIT 2008. International Symposium on*, 670-674.
- Chan, T. F., Sandberg, B. Y. ve Vese, L. A., 2000, Active contours without edges for vector-valued images, *Journal of Visual Communication and Image Representation*, 11 (2), 130-141.
- Chan, T. F. ve Vese, L. A., 2001, Active contours without edges, *Image Processing, IEEE Transactions on*, 10 (2), 266-277.
- Chen, H.-Y., Liu, X., Lu, H.-B., Wang, S.-Y. ve Dong, X.-Z., 2007, Application of segmentation and measurement in the treatment of developmental dysplasia of the hip, *Bioinformatics and Biomedical Engineering, 2007. ICBBE 2007. The 1st International Conference on*, 989-991.
- Chenyang, X. ve Prince, J. L., 1998, Snakes, shapes, and gradient vector flow, *Image Processing, IEEE Transactions on*, 7 (3), 359-369.
- Chesnaud, C., Réfrégier, P. ve Boulet, W., 1999, Statistical region snake-based segmentation adapted to different physical noise models, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 21 (11), 1145-1157.

- Chunming, L., Chenyang, X., Changfeng, G. ve Fox, M. D., 2005, Level set evolution without re-initialization: a new variational formulation, *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, 430-436.
- Ciecholewski, M. ve Chocholowicz, J., 2013, Gallbladder shape extraction from ultrasound images using active contour models, *Comput Biol Med*, 43 (12), 2238-2255.
- Çevik, K. K. ve Koçer, H. E., 2013, Parçacık sürü optimizasyonu ile yapay sinir ağı eğitime dayalı bir esnek hesaplama uygulaması, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 17 (2), 39-45.
- Davies, E. R., 2004, Machine vision: theory, algorithms, practicalities, *San Francisco USA*, Elsevier, p.
- Doğruel, H., Atalar, H., Yavuz, O. Y., Uras, İ., Günay, C. ve Şaylı, U., 2008, Türkiye’de gelişimsel kalça displazisi sıklığının ve tarama programlarının değerlendirilmesi, *Türkiye Klinikleri J Med Sci*, 28, 357-360.
- Duda, R. O. ve Hart, P. E., 1972, Use of the Hough transformation to detect lines and curves in pictures, *Communications of the ACM*, 15 (1), 11-15.
- Ege, R., 1994, Kalça cerrahisi ve sorunları, *Ankara*, Türk Hava Kurumu Basımevi, p.
- Ekşioğlu, M. F., Açar, H. İ. ve Tekdemir, İ., 2011, Kalça eklemının fonksiyonel anatomisi, *Türk Ortopedi ve Travmatoloji Birliği Derneği Dergisi*, 10 (1), 32-37.
- Elmas, Ç., 2003, Bulanık mantık denetleyiciler (Kuram, Uygulama, Sinirsel Bulanık mantık), *Seçkin Yayıncılık*, 35-40.
- Elmas, Ç., 2007, Yapay zeka uygulamaları, *Seçkin Yayıncılık, Ankara*.
- Emir, Ş., 2013, Yapay sinir ağı ve destek vektör makineleri yöntemlerinin sınıflandırma performanslarının karşılaştırılması: borsa endeks yönünün tahmini üzerine bir uygulama, *İstanbul Üniversitesi, İstanbul*.
- Fabry, G., Macewen, G. D. ve Shands, A. R., 1973, Torsion of the femur: A follow-up study in normal and abnormal conditions, *J Bone Joint Surg Am*, 55 (8), 1726-1738.
- Falliner, A., Hahne, H.-J. ve Hassenpflug, J., 2002, Sonographic investigation of anatomical specimens of infant hip joint, *Journal of Pediatric Orthopaedics B*, 11 (3), 192-203.
- Fisher, R., Perkins, S., Ashley, W. ve Erik, W., 2004, Image processing learning resources, <http://homepages.inf.ed.ac.uk/rbf/HIPR2/index.htm>: [01.12.2015].
- Frost, V. S., Stiles, J. A., Shanmugan, K. S. ve Holtzman, J., 1982, A model for radar images and its application to adaptive digital filtering of multiplicative noise, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-4 (2), 157-166.
- Fukiage, K., Yamasaki, N. ve Suzuki, S., 2014, Visualization of developmental dysplasia of the hip in infants by using three-dimensional magnetic resonance imaging, *Journal of Pediatric Orthopaedics B*, 23 (2), 107-111.
- Fuller, R., 1995, Neural fuzzy systems.
- Gent, E. ve Clarke, N. M., 2004, Joint replacement for sequelae of childhood hip disorders, *J Pediatr Orthop*, 24 (2), 35-240.
- Gonzalez, R. C. ve Woods, R. E., 2002, Digital image processing. New Jersey, Prentice Hall Upper Saddle River.
- Gökberk, B., 2014, Çok Ölçütlü Karar Verme Yaklaşımlarına Dayalı Tedarikçi Seçimi ve Bir Uygulama, *Gazi Üniversitesi, Ankara*, 190.
- Graf, R., 1983, New possibilities for the diagnosis of congenital hip joint dislocation by ultrasonography, *Journal of Pediatric Orthopaedics*, 3 (3), 354-359.

- Graf, R., 2006, Hip sonography: diagnosis and management of infant hip dysplasia, Springer Science & Business Media, p.
- Haciefendioğlu, Ş., 2012, Makine öğrenmesi yöntemleri ile glokom hastalığının teşhisi,, *Selçuk Üniversitesi*, Konya, 35-50.
- Hafizah, W. M. ve Supriyanto, E., 2011, Comparative evaluation of ultrasound kidney image enhancement techniques, *International Journal of Computer Applications*, 21 (7), 15-19.
- Harcke, H. T., Clarke, N. M., Lee, M. S., Borns, P. F. ve MacEwen, G. D., 1984, Examination of the infant hip with real-time ultrasonography, *J Ultrasound Med.*, 3 (3), 131-137.
- Harcke, H. T., 2005, Imaging methods used for children with hip dysplasia, *Clin Orthop Relat Res.*, 434, 71-77.
- Haykin, S., 1999, Neural Networks: A Comprehensive Foundation, *New Jersey*, Prentice Hall PTR, p.
- Haykin, S. S., 2008, Adaptive filter theory, Pearson Education India, p.
- Hebb, D. O., 1952, The organisation of behaviour: a neuropsychological theory, Wiley, p.
- Hedequist, D., Kasser, J. ve Emans, J., 2003, Use of an abduction brace for developmental dysplasia of the hip after failure of pavlik harness use, *Journal of Pediatric Orthopaedics*, 23 (2), 175-177.
- Henrikus, W. L., 1999, Developmental dysplasia of the hip: diagnosis and treatment in children younger than 6 months, *Pediatric Annals*, 28 (12), 740-746.
- Herring, J. A., 2003, Tachdjian's Pediatric Orthopaedics: From the Texas Scottish Rite Hospital for Children, 3, *Philadelphia, U.S.A.*, Elsevier-Saunders, p. 150-200.
- Hongbing, L., Zhengrong, L., Bin, L., Xiang, L., Jie, M. ve Xin, L., 2004, Mixture-based bone segmentation and its application in computer aided diagnosis and treatment planning, *Image and Graphics (ICIG'04), Third International Conference on*, 507-510.
- Hopfield, J. J., 1982, Neural networks and physical systems with emergent collective computational abilities, *Proceedings of the national academy of sciences*, 79 (8), 2554-2558.
- Hough, P. V. C., 1962, Method and means for recognizing complex patterns, Google Patents.
- Huang, Y. ve Van Genderen, J., 1996, Evaluation of several speckle filtering techniques for ERS-1&2 imagery, *Int. Arch. Photogramm. Remote Sensing*, 21 (B2), 164-169.
- Irha, E., Vrdoljak, J. ve Vrdoljak, O., 2004, Evaluation of ultrasonographic angle and linear parameters in the diagnosis of developmental dysplasia of the hip, *Journal of Pediatric Orthopaedics B.*, 13 (1), 9-14.
- Ishibuchi, H., Nozaki, K. ve Tanaka, H., 1992, Distributed representation of fuzzy rules and its application to pattern classification, *Fuzzy sets and systems*, 52 (1), 21-32.
- Ishibuchi, H., Tanaka, H. ve Okada, H., 1994, Interpolation of fuzzy if-then rules by neural networks, *International Journal of Approximate Reasoning*, 10 (1), 3-27.
- Jain, A. K., 1989, Fundamentals of digital image processing, *Englewood Cliffs, N.J.*, Prentice-Hall, Inc., p.
- Jouve, J.-L., Glard, Y., Garron, E., Piercecchi, M.-D., Dutour, O., Tardieu, C. ve Bollini, G., 2005, Anatomical study of the proximal femur in the fetus, *Journal of Pediatric Orthopaedics B*, 14 (2), 105-110.
- Kaastra, I. ve Boyd, M., 1996, Designing a neural network for forecasting financial and economic time series, *Neurocomputing*, 10 (3), 215-236.

- Kahramanlı, H., 2008, Hibrit Bulanık Sinir Ağını Kullanarak Bir Sınıflandırma Ve Kural Çıkarma Sisteminin Geliştirilmesi, *Selçuk Üniversitesi Konya*, 193.
- Kakıcı, A., 2009, Yapay Sinir Ağlarının Sınıflandırılması, <http://ahmetkakici.github.io/yapay-sinir-aglari/yapay-sinir-aglarinin-siniflandirilmesi/>: [20.04.2016].
- Kapıcıoğlu, S., Ömeroğlu, H., Köse, N., Sarısözen, B. ve Şenaran, H., 2006, 0-6 ay arası GKD ve PEV tanı ve tedavisi uygulamalı kursu kitapçığı, *Konya*, TOTBİD, p.
- Kass, M., Witkin, A. ve Terzopoulos, D., 1988, Snakes: Active contour models, *International Journal of Computer Vision*, 1 (4), 321-331.
- Kıyak, E. ve Kahvecioğlu, A., 2003, Bulanık Mantık ve Uçuş Kontrol Problemine Uygulanması, *Havacılık ve Uzay Teknolojileri Dergisi*, 1 (2), 63-72.
- Koçer, H. E., 2007, İris deseninin yapay zeka yöntemleri ile tanınması, *Selçuk Üniversitesi*, Konya.
- Kohonen, T., 1982, Self-organized formation of topologically correct feature maps, *Biological cybernetics*, 43 (1), 59-69.
- Köse, N., Ömeroğlu, H. ve Dağlar, B., 2013, Gelişimsel Kalça Displazisi Ulusal Erken Tanı ve Tedavi Programı, http://cocukergen.thsk.saglik.gov.tr/Dosya/Dokumanlar/Kitaplar/Gelisimsel_Kalca_Displazisi.pdf: [20.04.2016].
- Kuan, D. T., Sawchuk, A., Strand, T. C. ve Chavel, P., 1987, Adaptive restoration of images with speckle, *Acoustics, Speech and Signal Processing, IEEE Transactions on*, 35 (3), 373-383.
- Kutlu, A., 1984, Doğuştan kalça çıkığının konservatif tedavisi, *Selçuk Üniversitesi Tıp Fakültesi Dergisi*, 1 (2), 39-52.
- Kutlu, A., Memik, R., Mutlu, M., Kutlu, R. ve Arslan, A., 1992, Congenital dislocation of the hip and its relation to swaddling used in Turkey., *Journal of Pediatric Orthopaedics*, 12 (5), 678-702.
- Külcü, N. U., Orak, M. M., Gerenli, N., Sarı, E. ve Say, A., 2015, Bir Eğitim Hastanesinde Çocuk Hekimlerinin Gelişimsel Kalça Displazisi ile İlgili Bilgi Düzeyleri, *Journal of Current Pediatrics/Guncel Pediatri*, 13 (2).
- Lee, H.-M. ve Wang, W.-T., 1994, A neural network architecture for classification of fuzzy inputs, *Fuzzy sets and systems*, 63 (2), 159-173.
- Lehmann, H. P., Hinton, R., Morello, P. ve Santoli, J., 2000, Developmental dysplasia of the hip practice guideline: technical report, *American Academy of Pediatrics*, 105 (4), 1-25.
- Loupas, T., McDicken, W. ve Allan, P., 1989, An adaptive weighted median filter for speckle suppression in medical ultrasonic images, *Circuits and Systems, IEEE Transactions on*, 36 (1), 129-135.
- Luis-Garcia, R. ve Alberola-Lopez, C., 2006, Parametric 3D hip joint segmentation for the diagnosis of developmental dysplasia, *Engineering in Medicine and Biology Society, 2006. EMBS '06. 28th Annual International Conference of the IEEE*, 4807-4810.
- Luis-Garcia, R., Aja-Fernandez, S. ve Cardenes-Almeida, R., 2007, Analysis of ultrasound images based on local statistics. Application to the diagnosis of developmental dysplasia of the hip. 2007 IEEE Ultrasonics Symposium: 2531-2534.
- Luis-García, R. ve Alberola-López, C., 2005, Hip joint segmentation from 2D ultrasound data based on dynamic shape priors, *Proceedings of the 4th WSEAS international conference on Electronics, control and signal processing*, 245-250.

- Mahmood, N. H., Rusydi, M., Razif, M., Tajuddin, M. ve Gany, A. N., 2011, Comparison between Median, Unsharp and Wiener filter and its effect on ultrasound stomach tissue image segmentation for Pyloric Stenosis, *International Journal of Applied Science and Technology*, 1 (5), 218-226.
- Malladi, R., Sethian, J. ve Vemuri, B. C., 1995, Shape modeling with front propagation: A level set approach, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 17 (2), 158-175.
- Mamdani, E. H., 1974, Application of fuzzy algorithms for control of simple dynamic plant, *Proceedings of the Institution of Electrical Engineers*, 1585-1588.
- Mamdani, E. H. ve Assilian, S., 1975, An experiment in linguistic synthesis with a fuzzy logic controller, *International journal of man-machine studies*, 7 (1), 1-13.
- Mamdani, E. H., 1977, Application of fuzzy logic to approximate reasoning using linguistic synthesis, *Computers, IEEE Transactions on*, 100 (12), 1182-1191.
- McCulloch, W. S. ve Pitts, W., 1943, A logical calculus of the ideas immanent in nervous activity, *The bulletin of mathematical biophysics*, 5 (4), 115-133.
- Meuwly, J.-Y., Thiran, J.-P. ve Gudinchet, F., 2003, Application of adaptive image processing technique to real-time spatial compound ultrasound imaging improves image quality, *Investigative Radiology*, 38 (5), 257-262.
- Nabiyev, V. V., 2005, Yapay zeka: problemler-yöntemler-algoritmalar, Seçkin Yayıncılık, p.
- Nagao, Y., Aoki, H., Ishii, S.-J., Masuda, T. ve Beppu, M., 2008, Radiographic method to measure the inclination angle of the acetabulum, *Journal of Orthopaedic Science*, 13 (1), 62-71.
- Narayanan, S. K. ve Wahidabanu, R. S. D., 2009, A View on Despeckling in Ultrasound Imaging, *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 2 (3), 85-98.
- Novick, G., Ghelman, B. ve Schneider, M., 1983, Sonography of the neonatal and infant hip, *American journal of roentgenology*, 141 (4), 639-645.
- Osher, S. ve Sethian, J. A., 1988, Fronts propagating with curvature-dependent speed: Algorithms based on Hamilton-Jacobi formulations, *Journal of Computational Physics*, 79 (1), 12-49.
- Osher, S. ve Fedkiw, R., 2006, Level set methods and dynamic implicit surfaces, *New York, Springer Science & Business Media*, p.
- Overhoff, H., Lazovic, D., von Jan, U. ve Heinze, P., 1998, Computer-based determination of the newborn's femoral head coverage using three-dimensional ultrasound scans, In: *Medical Image Computing and Computer-Assisted Intervention — MICCAI'98*, Eds: Wells, W., Colchester, A. ve Delp, S.: Springer Berlin Heidelberg, p. 1024-1031.
- Overhoff, H. M., Lazovic, D. ve von Jan, U., 1999, Visualization of a newborn's hip joint using 3D ultrasound and automatic image processing, 1388-1395.
- Özkan, M. V., 2010, Matlab Görüntü İşleme Aracı Kullanarak Endometriozisi Hastalığının Ultrason Görüntülerinde Tespiti, *Fırat Üniversitesi, Elazığ*.
- Özmen, N., 2009, Image segmentation and smoothing via partial differential equations, *Middle East Technical University, Ankara*, 102.
- Öztemel, E., 2006, Yapay sinir ağları, Papatya, p.
- Perona, P. ve Malik, J., 1990, Scale-space and edge detection using anisotropic diffusion, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 12 (7), 629-639.
- Pınar, İ., 2014, Lazer kesim makineleri için görüntü işleme uygulamaları, *İstanbul Üniversitesi, İstanbul*, 99.

- Riad, J. P., Cundy, P., Gent, R. J., Piotta, L., Morris, L. ve Hirte, C., 2005, Longitudinal study of normal hip development by ultrasound., *J Pediatr Orthop.*, 25 (1), 5-9.
- Rizon, M., Haniza, Y., Puteh, S., Yeon, A., Shakaff, M., Abdul Rahman, S., Sugisaka, M., Sazali, Y., M Rozailan, M. ve Karthigayan, M., 2005, Object detection using circular Hough transform.
- Rosenblatt, F., 1958, The perceptron: a probabilistic model for information storage and organization in the brain, *Psychological review*, 65 (6), 386.
- Rosendahl, K., Markestad, T. ve Lie, R., 1994, Ultrasound screening for developmental dysplasia of the hip in the neonate: the effect on treatment rate and prevalence of late cases., *Pediatrics*, 94 (1), 47-52.
- Ross, T. J., 2009, Fuzzy logic with engineering applications, John Wiley & Sons, p.
- Rumelhart, G. E., Williams, D. E., Hinton, R. J. ve Hinton, G. E., 1986, Learning representations by back-propagating errors, *Nature*, 323, 533-538.
- Sağiroğlu, Ş., Beşdok, E. ve Erler, M., 2003, Mühendislikte yapay zeka uygulamaları-1: Yapay sinir ağları, *Ufuk Kitap Kırtasiye-Yayıncılık*, p.
- Sapiro, G., 2006, Geometric partial differential equations and image analysis, *New York, Cambridge university press*, p.
- Sarode, M. V. ve Deshmukh, P. R., 2011, Reduction of Speckle Noise and Image Enhancement of Images Using Filtering Technique, *International Journal of Advancements in Technology*, 2 (1), 30-38.
- Schünke, M., 2009, Prometheus-Lernatlas der Anatomie: Innere Organe; 118 Tabellen, *Stuttgart, Georg Thieme Verlag*, p.
- Segal, L. S., Schneider, D. J., Berlin, J. M., Bruno, A., Davis, B. R. ve Jacobs, C. R., 1999, The contribution of the ossific nucleus to the structural stiffness of the capital femoral epiphysis: a porcine model for DDH, *Journal of Pediatric Orthopaedics*, 19 (4), 433-437.
- Shapiro, L. ve Haralick, R., 1992, Computer and robot vision, *Reading: Addison-Wesley*, 8.
- Smergel, E., Losik, S. B. ve Rosenberg, H. K., 2004, Sonography of hip dysplasia, *Ultrasound Quarterly*, 20 (4), 201-216.
- Song, K. ve Lapinsky, A., 2000, Determination of hip position in the Pavlik harness., *Journal of Pediatric Orthopaedics*, 20 (3), 317-319.
- Söylemez, Ö. F., 2012, İnsan yüzü imgelerinde dairesel hough dönüşümü kullanılarak göz durumu tespiti, *Fırat Üniversitesi Elazığ*, 52.
- Sumathi, S. ve Paneerselvam, S., 2010, Computational intelligence paradigms: theory & applications using MATLAB, *CRC Press*, p.
- Suri, J. S., Kecheng, L., Singh, S., Laxminarayan, S. N., Xiaolan, Z. ve Reden, L., 2002, Shape recovery algorithms using level sets in 2-D/3-D medical imagery: a state-of-the-art review, *Information Technology in Biomedicine, IEEE Transactions on*, 6 (1), 8-28.
- Şaşmaz, H. H., 2011, Gelişimsel kalça displazisi tanısında sonografik tarama tekniklerinin karşılaştırılması, *Gaziantep Üniversitesi, Gaziantep, Türkiye*, 113.
- Şenaran, H., Özdemir, H. M., Ögün, T. C. ve Kapıcıoğlu, M., 2004, Value of limited hip abduction in developmental dysplasia of the hip, *Pediatrics international*, 46 (4), 456-458.
- Takagi, T. ve Sugeno, M., 1985, Fuzzy identification of systems and its applications to modeling and control, *Systems, Man and Cybernetics, IEEE Transactions on* (1), 116-132.
- Tekin, M., 2011, Femur Başı Avasküler Nekrozlarında Kor Dekompresyon Tedavisinin Fonksiyonel Sonuçları, *Çukurova Üniversitesi, Adana*, 62.

- Thangavel, K., Manavalan, R. ve Aroquiaraj, I. L., 2009, Removal of speckle noise from ultrasound medical image based on special filters: comparative study, *ICGST-GVIP Journal*, 9 (3), 25-32.
- Thompson, G. H., 2001, Bebeklerde sık görülen ortopedik problemler. In: nelson essentials of pediatrics (türkçe çeviri), *İstanbul*, Nobel Tıp Kitabevi, p. 750-753.
- Tosun, H. B., 2010, Gelişimsel kalça displazisi taraması için yapılan kalça ultrasonografisi sonuçlarının değerlendirilmesi, *Fırat Üniversitesi*, Elazığ, Türkiye, 100.
- Tuhanoğlu, Ü., 2008, Erişkin Asetabuler Displazili Olgularda Steel Tekniği İle Üçlü Pelvik Osteotomi Uygulamalarımızın Erken Dönem Sonuçları, *Baltalimanı Metin Sabancı Kemik Hastalıkları Eğitim Ve Araştırma Hastanesi*, İstanbul, 95.
- TUIK, 2015, Doğum İstatistikleri, <http://www.tuik.gov.tr/PreHaberBultenleri.do?id=18621>: [01.04.2016].
- Tunali, I. ve Kilic, E., 2013, Mass segmentation on mammograms using active contours, *Signal Processing and Communications Applications Conference (SIU), 2013 21st*, 1-4.
- Tuncay, I. C., Karaeminogullari, O., Demirors, H. ve Tandogan, N. R., 2005, Is prematurity important in ultrasonographic hip typing?, *Journal of Pediatric Orthopaedics B*, 14, 168-171.
- Tuncay, İ. C., 2004 Yenidoğan Kalça Ultrasonografisinin Değerlendirilmesi, *Türk Ortopedi ve Travmatoloji Birliği Derneği Dergisi*, 3 (1), 3-4.
- Tümer, Y. ve Ömeroğlu, H., 1997, Türkiye'de gelişimsel kalça displazisinin önlenmesi, *Acta Ortop Traumatol Turc*, 31 (1), 176-181.
- Türkoğlu, İ., Şengür, A. ve Toraman, S., 2003, Tıbbi görüntülerden istenen bir örüntünün ayrıştırılması, *Doğu Anadolu Bölgesi Araştırmaları*, 3, 97-101.
- Uğur, A. ve Kınacı, A. C., 2006, Yapay zeka teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması, *XI. Türkiye'de İnternet Konferansı (inet-tr'06)*, Ankara, 1-4.
- Uslu, H. S., Karatekin, G., Uslu, A., Kadioğlu, A. ve Nuhoglu, A., 2002, Yenidoğan döneminde gelişimsel kalça displazisine ait risk faktörlerinin değerlendirilmesi, *Türkiye Klinikleri J Pediatr*, 11 (3), 139-143.
- Ünal, Y., 2015, Makine öğrenmesi yöntemleriyle bel bölgesi rahatsızlıklarının tanısı, *Selçuk Üniversitesi*, Konya, 128.
- Vernon, D., 1991, Machine vision - Automated visual inspection and robot vision, *Englewood Cliffs, N.J.*, Prentice Hall, p.
- Wei, G. W., 1999, Generalized Perona-Malik equation for image restoration, *Signal Processing Letters, IEEE*, 6 (7), 165-167.
- Widrow, B. ve Hoff, M. E., 1960, Adaptive switching circuits, *IRE WESCON Convention record*, 96-104.
- Williams, D. J. ve Shah, M., 1992, A fast algorithm for active contours and curvature estimation, *CVGIP: Image understanding*, 55 (1), 14-26.
- Yalçın, N., 2012, Sezgisel algoritma öğrenmeli yapay sinir ağları ile epilepsi hastalığının teşhisi, Yüksek Lisans Tezi, *Selçuk Üniversitesi Konya*, 8-14.
- Yamakawa, T., 1993, A fuzzy inference engine in nonlinear analog mode and its application to a fuzzy logic control, *Neural Networks, IEEE Transactions on*, 4 (3), 496-522.
- Yen, J., Langari, R. ve Zadeh, L. A., 1995, Industrial applications of fuzzy logic and intelligent systems, IEEE press, p.
- Yokota, F., Okada, T., Takao, M., Sugano, N., Tada, Y. ve Sato, Y., 2009, Automated segmentation of the femur and pelvis from 3D CT data of diseased hip using

- hierarchical statistical shape model of joint structure, In: Medical Image Computing and Computer-Assisted Intervention–MICCAI 2009, Eds: Springer, p. 811-818.
- Young, I. T. ve Van Vliet, L. J., 1995, Recursive implementation of the Gaussian filter, *Signal processing*, 44 (2), 139-151.
- Zadeh, L., 1965, Fuzzy Sets, *Information and Control*, 8, 338-353.
- Zadeh, L. A., 1984, Making computers think like people: the term fuzzy thinking is pejorative when applied to humans, but fuzzy logic is an asset to machines in applications from expert systems to process control, *Spectrum, IEEE*, 21 (8), 26-32.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Kerim Kürşat ÇEVİK
Uyruğu : T.C.
Doğum Yeri ve Tarihi : Karaman/Merkez 21.01.1985
Telefon : 0(388)3114527
Faks : 0(388)3118437
e-mail : kcevik@nigde.edu.tr

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Anadolu Lisesi, Merkez, Karaman	2003
Üniversite	: Süleyman Demirel Üniversitesi Teknik Eğt. Fak.	2007
Yüksek Lisans:	Selçuk Üniversitesi Elektronik ve Bilgisayar Eğt.	2010
Doktora	: Selçuk Üniversitesi Bilgisayar Müh.	2016

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2003-2007	S.D.Ü. Bilgi İşlem D.B.	Yarı-Zaman Eleman
2007-2010	M.E.B. Ilgın Argıthanı Ç.P.L.	Bilgisayar Öğretmeni
2010-...	Niğde Üniversitesi Bor M.Y.O.	Öğretim Görevlisi

UZMANLIK ALANI

.NET Programlama, Görüntü İşleme, Yapay Zekâ, Sezgisel ve Evrimsel Algoritmalar, Mobil Programlama

YABANCI DİLLER

İngilizce	KPDS	62,5
-----------	------	------

YAYINLAR

Koçer Hasan Erdiñ, Çevik Kerim Kürşat (2011). Artificial neural networks based vehicle license plate recognition. Procedia Computer Science, 1(3), 1033-1037. (Yüksek lisans tezinden yapılmıştır)

Çevik Kerim Kürşat, Koçer Hasan Erdiñ, Şeyda Andaç (2016). Segmentation of the Ilium and Femur Regions from Ultrasound Images for Diagnosis of Developmental Dysplasia of the Hip. Journal of Medical Imaging and Health Informatics, 6(2), 449-457. (Doktora tezinden yapılmıştır)

Koçer Hasan Erdiñ, Çevik Kerim Kürşat, Sivri Mesut, Koplay Mustafa. Measuring the Effect of Filters on Segmentation of Developmental Dysplasia of the Hip. Iranian Journal of Radiology, Accepted. (Doktora tezinden yapılmıştır)

Çevik Kerim Kürşat, Koçer Hasan Erdiñ. Developmental Hip Dysplasia Segmentation of Ultrasound Images. 24th Signal Processing and Communications Applications Conference, 16-19 May 2016, Zonguldak. (Doktora tezinden yapılmıştır)