

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**DERİN ÖĞRENME TEKNİKLERİ İLE GELİŞİMSEL KALÇA ÇIKIKLIĞININ
ULTRASON GÖRÜNTÜLERİNDEN OTOMATİK TESPİTİ**

Muhammed Enes YILMAZ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**ANKARA
2024**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME TEKNİKLERİ İLE GELİŞİMSEL KALÇA ÇIKILIĞININ ULTRASON GÖRÜNTÜLERİNDEN OTOMATİK TESPİTİ

Muhammed Enes YILMAZ

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi İlyas Evrim ÇOLAK
Eş Danışman: Doç. Dr. Mehmet Serdar GÜZEL

Gelişimsel kalça displazisi, femur başı ile asetabulum arasındaki uyumsuzluktan kaynaklanan bir yapısal bozukluktur. Erken teşhis ve tedavi, uzuv kısalığı, topallama ve fonksiyonel özrürlük gibi olumsuz durumları önleyebilir. Bu rahatsızlık özellikle yenidoğan ve 0-3 aylık bebeklerde erken tanı konulması gereken bir durumdur. Tanıda gecikme durumunda, uzuv kısalığı gibi kalıcı sorunlar ortaya çıkabilir. Bu nedenle erken teşhis ve tedavi, yaşam kalitesini önemli ölçüde etkileyebilir. Tanıda iki temel yöntem olan fiziksel muayene ve ultrason ile görüntüleme yöntemi kullanılır. Özellikle ultrason görüntülerinin değerlendirilmesinde Graf yöntemi sıkça tercih edilir, ancak bu yöntemde uzman ve cihaz kaynaklı hatalar olabilmektedir. Günümüzde bilgisayar destekli tanı araştırmaları, tanı süreçlerini geliştirmek amacıyla yapılmaktadır. Ultrason görüntülerinin manuel işlenmesi, ölçümde zorluklara neden olabilir ve yanlış sonuçlara yol açabilir. Bu nedenle, bu çalışmada gelişimsel kalça displazisi tanısının ilk aşaması için farklı ağ mimarileri önerilmiştir: U-Net, Mask R-CNN ve YOLOv8. U-Net önerisi daha az veri ile ikili sınıflandırma olarak sunulmuştur, Mask R-CNN ve YOLOv8 ağ önerileri ise daha çok veriyle ve çok etiketli olarak eğitim süreçlerinden geçmişlerdir. Çalışmada öne çıkan YOLOv8, eğitim sonuçlarına göre en yüksek başarıya ulaşmıştır. Bölütleme, açılı ölçümü ve istatistiksel analiz kademeli olarak yapılmıştır. Açılı ölçümü için iki öneri sunulmuş ve sonuçlar uzman sonucu ile karşılaştırılmıştır. Önerilerin doğruluğu için Bland-Altman analizi ve sınıf içi korelasyon analizi (ICC) uygulanmış, istatistiksel analiz sonuçları tablolar halinde karşılaştırılmıştır. Sunulan önerilerin doğruluğu ve güvenilirliği değerlendirilmiştir.

Temmuz 2024, 76 sayfa

Anahtar Kelimeler: Gelişimsel Kalça Çıkığı, Ultrason, Yapay Zekâ, Derin Öğrenme, Evrişimli Sinir Ağları, Görüntü İşleme, İstatistiksel Analiz

ABSTRACT

Master Thesis

AUTOMATIC DETECTION OF DEVELOPMENTAL DYSPLASIA OF THE HIP FROM ULTRASOUND IMAGES WITH DEEP LEARNING TECHNIQUES

Muhammed Enes YILMAZ

Ankara University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering

Supervisor: Asst. Prof. Dr. İlyas Evrim ÇOLAK
Co-Supervisor : Assoc. Prof. Dr. Mehmet Serdar GÜZEL

Developmental hip dysplasia is a structural disorder arising from incongruity between the femoral head and the acetabulum. Early diagnosis and treatment can prevent adverse conditions such as limb shortening, limping, and functional impairment. This condition particularly necessitates early identification in newborns and infants aged 0-3 months. Delay in diagnosis can lead to persistent problems like limb shortening. Therefore, early diagnosis and treatment can significantly impact the quality of life. The two primary diagnostic methods are physical examination and imaging through ultrasound. The Graf method is commonly preferred, especially in the evaluation of ultrasound images, although it may be prone to expert and device-related errors. Contemporary research in computer-aided diagnosis aims to enhance diagnostic processes. Manual processing of ultrasound images can pose challenges in measurement and result in inaccuracies. Hence, this study proposes different network architectures for the initial stage of developmental hip dysplasia diagnosis: U-Net, Mask R-CNN, and YOLOv8. The U-Net proposal is presented as binary classification with less data, while the Mask R-CNN and YOLOv8 network proposals have undergone training processes with more data and multiple labels. The YOLOv8 model has achieved the highest success based on training results. Segmentation, angle measurement, and statistical analysis were conducted stepwise. Two suggestions for angle measurement are presented and the results are compared with the expert result. Bland-Altman and intraclass correlation analysis (ICC) were applied to assess the accuracy of the proposals, and the statistical analysis results were compared in tables. The accuracy and reliability of the suggestions presented were evaluated.

July 2024, 76 pages

Key Words: Developmental Dysplasia of the Hip, Ultrasound, Artificial Intelligence, Deep Learning, Convolutional Neural Networks, Image Processing, Statistical Analysis

ÖNSÖZ VE TEŞEKKÜR

Çalışmalarım sırasında kıymetli bilgi, birikim ve tecrübeleri ile bana yol gösterici ve destek olan değerli danışman hocam Dr. Öğr. Üyesi İlyas Evrim ÇOLAK'a, projeye kıymetli bilgi, birikim ve tecrübeleri ile bana yol göstermesinden dolayı değerli eş danışman hocam Doç. Dr. Mehmet Serdar GÜZEL'e, verilerin temin edilmesinde, işaretlenmesinde ve konunun anlaşılır olmasında desteğini esirgemeyen Doç. Dr. Aslıhan ONAY ÇOLAK'a, beni desteklemekten hiçbir zaman vazgeçmeyen, her zorlu anımda yanımda olan, her giriştiğim işte desteklerini bir an olsun eksiltmeden veren kıymetli; babam İlhan YILMAZ'a, annem Leyla YILMAZ'a ve kardeşim Furkan YILMAZ'a teşekkürlerimi ve saygılarımı sunarım.

Muhammed Enes YILMAZ
Ankara, Temmuz 2024

İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
ÖNSÖZ VE TEŞEKKÜR.....	iv
KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	x
1. GİRİŞ	1
2. KURAMSAL TEMELLER.....	3
2.1 Literatür Taraması	3
2.2 Kalçada İlgilendiğimiz Yapılar	9
2.2.1 Femur yapısı	9
2.2.2 Asetabulum	10
2.2.3 İlium	11
2.2.4 İskium.....	11
2.2.5 Labrum	12
3. MATERYAL VE YÖNTEM.....	13
3.1 Verilerin Toplanması.....	13
3.2 Görüntülerin Değerlendirilmesi ve Etiketlenmesi	14
3.3 Verilerin Ön İşlemesi	16
3.4 Model Yapıları.....	17
3.4.1 Yapay sinir ağları.....	17
3.4.2 Aktivasyon fonksiyonları.....	20
3.4.3 Optimizasyon algoritmaları	24
3.4.4 U-NET	27
3.4.5 Mask R-CNN	30
3.4.6 YOLO v8.....	33
4. ARAŞTIRMA BULGULARI	36
4.1 Model Eğitim Süreçleri.....	36
4.1.1 U-Net eğitim süreci.....	37
4.1.2 Mask R-CNN eğitim süreci	42

4.1.3 YOLOv8 eğitim süreci	45
4.2 Değerlendirme Metrikleri	49
4.2.1 Karışıklık matrisi (Confusion matrix)	50
4.2.2 Doğruluk (Accuracy)	50
4.2.3 Kesinlik (Precision)	51
4.2.4 Duyarlılık (Recall).....	51
4.2.5 Kesiştirilmiş bölgeler (IoU) (Jaccard index).....	52
4.2.6 F1 puan (F1 score) (Dice katsayısı).....	53
4.2.7 Genel ortalama kesinliği (mAP).....	53
4.3 Eğitim Sonrası İşlemler ve Açık Ölçümü	55
4.3.1 Açık ölçümü için sunulan öneriler	60
4.3.2 İstatistiksel değerlendirme	64
5. TARTIŞMA VE SONUÇ	68
KAYNAKLAR	71
ÖZGEÇMİŞ.....	76

KISALTMALAR DİZİNİ

Adam	Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation)
BDT	Bilgisayar Destekli Tanı
CAD	Bilgisayar Destekli Tasarım (Computer Aided Design)
CCA	Kanonik Korelasyon Analizi (Canonical Correlation Analysis)
CNN	Evrişimsel Sinir Ağları (Convolutional Neural Networks)
CVAT	Computer Vision Annotation Tool
DICOM	Digital Imaging and Communications in Medicine
FPN	Öznitelik Piramid Ağı (Feature Pyramid Network)
GKD	Gelişimsel Kalça Displazisi
GPU	Grafik İşlem Birimi (Graphics Processing Unit)
IoU	Kesiştirilmiş Bölgeler (Intersection over Union)
mAP	Genel Ortalama Kesinliği (Mean Average Precision)
MSE	Ortalama Kare Hatası (Mean Square Error)
NHBS	Neonatal Kalça Kemiği Bölütleme (Neonatal Hip Bone Segmentation)
OpenCV	Open Source Computer Vision Library
PSNR	Zirve Sinyal-Gürültü Oranı (Peak Signal to Noise Ratio)
PSO	Parçacık Sürüsü Optimizasyonu (Particle Swarm Optimization)
R-CNN	Bölge Tabanlı Evrişimli Sinir Ağı (Region-Based CNN)
ReLU	Düzeltilmiş Doğrusal Birim (Rectified Linear Unit)
ResNet	Artık Ağlar (Residual Network)
ROI	İlgi Alanı (Region of Interest)
RPN	Bölge Öneri Ağı (Region Proposal Network)
SGD	Stokastik Gradyan İniş (Stochastic Gradient Descent)
SLIC	Basit Lineer İteratif Kümeleme (Simple Linear Iterative Clustering)
SLS	İstatistiksel Seviye Seti (Statistical Level Set)
US	Ultrason
YOLO	You Only Look Once
YSA	Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

Şekil 2.1 Kalça ultrason bölgeleri. 1. Femur 4. Femur başı 7. Labrum 11. Asetabulum 12. İliumun osifiye ucu 13. İlium (Tuncay 2004).....	9
Şekil 2.2 Femur yapısı	10
Şekil 2.3 Asetabulum yapısı.....	11
Şekil 2.4 İlium.....	11
Şekil 2.5 İskium	12
Şekil 2.6 Labrum.....	12
Şekil 3.1 Örnek US ham görüntüsü	14
Şekil 3.2 CVAT programı ve etiketleme örneği.....	15
Şekil 3.3 İlgilenilen bölge ve ilgilendiğimiz anatomik yapılar.....	15
Şekil 3.4 Veri kümesi 1 yapısı.....	16
Şekil 3.5 Veri kümesi 2 yapısı.....	17
Şekil 3.6 İnsan nöron yapısı biyolojik gösterimi (Özcan 2020)	18
Şekil 3.7 Algılayıcı (Perceptron) model yapısı	19
Şekil 3.8 Gizli katmanı tek olan bir yapay sinir ağı gösterimi	20
Şekil 3.9 Basamak ve doğrusal fonksiyon grafikleri	22
Şekil 3.10 Sigmoid ve hiperbolik tanjant fonksiyon grafikleri.....	23
Şekil 3.11 ReLU ve Leaky ReLU fonksiyon grafikleri.....	24
Şekil 3.12 Gradyan iniş gösterimi	25
Şekil 3.13 Adam iniş gösterimi	27
Şekil 3.14 CNN temel gösterim.....	28
Şekil 3.15 Kullanılan U-Net ağ mimarisi	29
Şekil 3.16 RPN mimarisi	31
Şekil 3.17 RoI hizalama (He vd. 2017)	31
Şekil 3.18 FPN mimarisi	32
Şekil 3.19 Mask R-CNN maske dalı (He vd. 2017)	32
Şekil 3.20 Mask R-CNN mimarisi	33
Şekil 3.21 YOLO mimarisi (Redmon vd. 2016)	34
Şekil 3.22 YOLOv8 performans karşılaştırması (Jocher vd. 2023)	34
Şekil 3.23 YOLOv8 mimarisi (RangeKing/Github 2023).....	35
Şekil 4.1 İlgilenilen bölge, rastgele örnek görüntü ve maske gösterimi.....	36

Şekil 4.2 a) Veri kümesi 2 kümesinde olan rastgele bir görüntü. b) (a) görüntüsüne ait olan maske. c) Ön işlemede yapılan görüntü işlemlerine ait rastgele bir görüntü. d) (c) görüntüsüne ait olan görüntü işlenmiş maske.....	38
Şekil 4.3 Kullanılan U-Net mimarisi tüm ağ yapısı	39
Şekil 4.4 (a) U-Net model doğruluk sonucu. (b) U-Net model kayıp sonuçları.....	40
Şekil 4.5 U-Net model IoU sonucu	41
Şekil 4.6 a) Tahmin edilmesi için verilen görüntü. b) (a) görüntüsünün tahmini.....	41
Şekil 4.7 Colab'da kullanılan GPU özellikleri.....	42
Şekil 4.8 Mask R-CNN modelinde kullanılan veri kümesinden bir örnek.....	43
Şekil 4.9 Mask R-CNN model sonucuna göre tahmin edilen örnek görüntü	45
Şekil 4.10 YOLOv8 eğitim sonucuna göre oluşmuş karışıklık matrisi	46
Şekil 4.11 YOLOv8 eğitim model kayıp değerleri.....	47
Şekil 4.12 YOLOv8 eğitim metrik sonuçları. B: box, M: mask.....	47
Şekil 4.13 YOLOv8 box sonuç grafikleri.....	48
Şekil 4.14 YOLOv8 maske sonuç grafikleri	48
Şekil 4.15 a) Model eğitim sırasında yapılan bir tahmin örneği. b) Tahmin aşamasında elde edilmiş örnek bir görüntü	49
Şekil 4.16 IoU görselleştirilmiş hali	52
Şekil 4.17 Dice katsayısı görselleştirilmiş hali.....	53
Şekil 4.18 a) Örnek bir tahmin görüntüsü. b) (a) tahmin görüntüsünün sınırları bulunmuş hali	56
Şekil 4.19 a) Örnek US görüntüsü. b) (a) görüntüsüne ait model tahmin bölüt görüntüsü. c) (b) tahmin üzerine elde edilmiş bölüt sınır görüntüsü. d) (c) CCA ile hesaplanmış bölütlerin piksel boyutu.....	57
Şekil 4.20 a) Graf metodunda önerilen anahtar noktalar. b) Açılı ölçümü için olması gereken çizgiler	59
Şekil 4.21 a) Etiket ve bölge özellikleri b) Açılı için ilgilendirilen özellikler c) Alfa açısı için önemli çizgiler d) Beta açısı için önemli çizgiler	61
Şekil 4.22 a) Alfa açısının tespiti b) Beta açısının tespiti	62
Şekil 4.23 Matlab işlevsel arayüz tasarımı ve uygulaması	63
Şekil 4.24 Yöntem 1 için; a) UNET alfa b) UNET beta c) YOLO alfa d) YOLO beta	65
Şekil 4.25 Yöntem 2 için; a) UNET alfa b) UNET beta c) YOLO alfa d) YOLO beta	66

ÇİZELGELER DİZİNİ

Çizelge 3.1 Veri kümelerinin toplam veri kümelerine göre son durum karşılaştırılması	17
Çizelge 3.2 Derin öğrenmede bazı kilometre taşları (Schmidhuber 2022)	19
Çizelge 3.3 Bazı aktivasyon fonksiyonları.....	21
Çizelge 3.4 Gradyan iniş ve momentum karşılaştırma	26
Çizelge 4.1 U-NET hiper parametreler	40
Çizelge 4.2 Mask RCNN hiper parametreler	43
Çizelge 4.3 YOLOv8 hiper parametreler	46
Çizelge 4.4 Karışıklık matrisi	50
Çizelge 4.5 Doğruluk model karşılaştırma	51
Çizelge 4.6 Kesinlik model karşılaştırma	51
Çizelge 4.7 Duyarlılık model karşılaştırma	52
Çizelge 4.8 IoU model karşılaştırma.....	52
Çizelge 4.9 F1 Skor (Dice katsayısı) model karşılaştırması	53
Çizelge 4.10 mAP model karşılaştırması	54
Çizelge 4.11 U-Net sonuç değerleri	54
Çizelge 4.12 Mask R-CNN sonuç değerleri.....	54
Çizelge 4.13 YOLO v8 sonuç değerleri	55
Çizelge 4.14 Önerilmiş yöntemlerin karşılaştırılması (Chen vd. 2022).....	58
Çizelge 4.15 ICC sonuç tablosu	67

1. GİRİŞ

Gelişimsel kalça displazisi (GKD) kalça eklem bölgesinde eğilme, şekil bozukluğu ile ortaya çıkan yapısal bir bozukluktur. Genellikle femur başı ve asetabulum arasında uyumsuzluk olduğunda gözlemlenmektedir. GKD genellikle, kalça eklemine büyük bir kısmının, kırıkta halde olduğu yaşamın ilk zamanlarında başlar. GKD gelişimi öngörülemezdir; fakat erken tanı konulursa hastalığın zararlı sonuçları engellenebilir. Erken tanı konulduğunda GKD'nin tedavisi mümkündür. Ancak tanı ve tedavi gecikirse, bacaklarda boy farkı, yürüme güçlüğü ve işlevsel kısıtlılık gibi hareket sorunları ortaya çıkabilir. GKD tanısı koymak için uzmanlar fiziksel muayene ve Ultrason (US) görüntüleme gibi iki yöntemden yararlanır. Yenidoğan kalçası fizik muayene ve düz röntgenle pek anlaşılmazken, GKD'li vakalarda ultrason kalça eklemindeki küçük yapısal bozuklukları bile net bir şekilde gösterebilmektedir. Yeni doğan döneminde konulmuş erken tanı ve tedavi ile bebeklerin %96'sı normal kalça yapısına ve röntgen görüntüsüne kavuşabilmektedir (Tosun vd. 2010).

Son yıllarda GKD tanısında US tercih edilmektedir. Graf, yenidoğan kalçasının US ile incelenmesi için güvenilir bir yöntem geliştirdi (Graf 1984, Graf 2006). Yenidoğan kalçasının standart kesitini belirledi ve GKD'nin derecesini ölçmek için bir sınıflama sistemi önerdi. Graf, yöntemini bebeğin ve US başlığının nasıl konumlandırılması gerektiğini açıklayarak detaylandırdı ve çalışmasında izlediği yöntemi anlattı. Temel çizgi, kemik çatı çizgisi ve yumuşak doku örtüsü çizgisi olmak üzere üç çizgi kullandı. Bu çizgilerden iki açı elde edildi: alfa (α : kemik çatı açısı) ve beta (β : kırıkta çatı açısı). Bu iki açı, yenidoğan kalçasının farklı tiplerini ayırt etmek için kullanıldı (Graf 2006).

Alanında uzman doktorlar tarafından kullanılan graf sınıflandırması GKD teşhis edilmesi ve tedavi kararının verilmesinde değerli bir araç olmuştur. Ne yazık ki bu durum deneyim eksikliği, alfa ve beta açılarının yorumlanmasında gözlemciler arası teşhis ve karar farklılıklarına yol açabilir. Ultrason görüntüsü bu standartlara göre incelense de, bazı anatomik yapılar görüntüde net olarak belli olmayabilir. Örneğin bazı bölgeler yumuşak dokular tarafından gizlenebilir ve farklı şekillerde algılanabilir. Bunun ayrımını yapmak her zaman kolay değildir. Bu durumların önüne geçebilmek ve klinisyenlerin teşhis işini

kolaylařtırmak iin bilgisayar destekli karar verme sistemleri, birok durumun teřhis edilmesine yardımcı olmak amacıyla tıbbi grntlerin deęerlendirilmesi ve llmesinde yararlı aralar olarak kullanılmaktadır.

Hastalıęın yeni doęan ve bebeklik dnemlerinde herhangi bir zamanda ortaya ıkabileceęi gz nne alındıęında, uygulamada ve uygulama sıklıęında ortaya ıkabilecek zorluklar nlenecektir. Bilgisayar destekli teřhis sistemleri aracılıęıyla hastalık daha erken tanınır ve tedavi bařarımını artırılabilir.

2. KURAMSAL TEMELLER

Ülkemizde ve dünya genelinde GKD'nin erken tanı, tedavi çok önemlidir. Bunun için büyük çaba harcanmaktadır. Ancak GKD tanısında, farklı yöntemler, insan hataları ve teknik eksiklikler nedeniyle tam bir tanı konulamayabiliyor. Çalışmamız kapsamında radyoloji bölümünde uzman doktor ile yapılan değerlendirmeler neticesinde gözlemciye yardımcı bilgisayar destekli bir yapının geliştirilmesi ve ölçüm doğruluklarına katkı verilmesine karar verilmiştir. Doktorların GKD teşhisi koymak için kullandıkları görüntülerdeki ölçümler hatalı olabiliyor ve bu da göreceli kararlara yol açabiliyor. Bu da bilgisayar destekli bir teşhis sisteminin önemini ortaya koymaktadır. Bu çalışma, US cihazından elde edilen görüntüler üzerinde yapılan bölütlemeler ve ölçümlerle, teşhisin daha güvenilir olmasını sağlayarak, doktorların daha doğru sonuçlara ulaşmalarını mümkün kılacak eğitim sürecini ve elde edilen sonuçları içermektedir.

Çalışmada literatürde bulunan ağ yapıları araştırılmış, genellikle medikal görüntülerde görüntü bölütlemesi için tercih edildiği gözlenen U-Net (Ronneberger vd. 2015), Mask R-CNN (He vd. 2017), YOLOv8 (Jocher vd. 2023) gibi ağ yapıları ile eğitimler yapılmış ve görüntü bölütleme sonuçları alınmıştır. Farklı ağ yapılarıyla denenmesinde hangi yöntemin eğitim sürecinde daha başarılı olduğu karşılaştırılmış ve yüksek başarımla elde eden model yapısı sonuçlarıyla sunulmuştur. Tüm bu eğitimler için Python programlama dili tercih edilmiştir. Bu dilde derin öğrenme aşamasında ağ eğitimleri için yaygın kullanılan Tensorflow (Abadi vd. 2015), PyTorch (Paszke vd. 2019), Detectron2 (Wu vd. 2019) gibi kütüphanelere başvurulmuştur. Bu sistem, yeni doğanlara uygulanıp, uzman gözlemci, ölçüm ve görüntü kaynaklı hataları azaltarak, uzman gözlemciye yardımcı bir sistem olması amaçlanmıştır.

2.1 Literatür Taraması

Ultrason yöntemiyle yeni doğan kalça taraması yapmak, 1978'de Avusturyalı ortopedist Reinhard Graf vd. (1983) tarafından başlatıldı (Tuncay vd. 2005). Bu çalışmanın ilk yayını 1983'te çıktı ve tanı için kriterler belirlendi (Graf 1983). 1984 yılında bebek kalça displazisinin ultrasonografik tanısının temelleri Graf (1984) tarafından atılmıştır.

GKD teşhisi için ultrason kullanılarak gerçekleştirilen muayeneler, statik ve dinamik olmak üzere iki temel yöntemi içermektedir. Statik yöntem, Graf tarafından geliştirilmiştir ve kalçanın tek bir görüntüsü üzerinden anatomik özelliklerin morfolojik bir yaklaşımla değerlendirilmesine dayanmaktadır (Şaşmaz, 2011).

Graf yöntemi, kalçanın bir sonogramda standart pozisyonda görülmesi ve açılarla ölçülmesiyle kalça eklemi morfolojisinin şeklini sınıflandırmayla belirlenen bir yöntemdir. Kalçayı ultrasonla inceleme ve sınıflandırmada alfa ve beta açıları önemlidir (Graf, 2006).

Gelişen metodolojiler ile birlikte, Graf (2006) yönteminde belirtilmiş olan bölgeleri anlaşılır bir şekilde çıkarabilmek ve GKD metriklerinin değerlendirilmesi için hem ultrason görüntü uygunluğunun otomatik tespiti hem de alfa ve beta açılarının çıkarılmasını içeren yeni bir otomatik yaklaşım öneren Quader (2015) ve arkadaşları önermişlerdir. US görüntülerinde, ışın yansımasının bu yapıların hem öncesi hem de sonrası çok zayıf olduğu için, kemik ve kıkırdak sınırlarının faz simetrisi tepkileri Hacıhaliloglu vd. (2014) uyguladığı gibi iyi bir şekilde algılayabilir (Quader vd. 2015). Bu sayede elde edilen faz simetri tepki değerleri ile ultrason iletim modeli ve dizplazi metriklerinin çıkarılması aşamalarından geçirerek alfa ve beta açılarını elde etmişlerdir (Quader vd. 2015).

Golan (2016) ve arkadaşlarının graf yöntemini derin evrişimli sinir ağlarıyla GKD tanılması otomatik olarak uygulayan bir çalışma yapmışlardır. Derin evrişimsel sinir ağı yöntemini seçmiş ve graf yönteminde belirtilmiş olan bölgelerin bölütlenmesi için kullanmışlardır. Ağın çıktıları, biri ilium ve diğeri asetabular çatı için olmak üzere olasılık haritaları olarak değerlendirdiler. İlk önce çıktının gürültüsünü giderip, gürültüden arındırılmış bölgeler elde ettiler. Bu bölgelerde bir hat ve fonksiyon tanımlayarak çizgiler elde edip bu çizgilerden açı ölçümünü sağladılar (Golan vd. 2016).

Ultrason görüntülerine filtre uygulayarak GKD tanısında bölütleme performansını iyileştirmek için saf GKD görüntüleri elde edilmeli ve bunun için bir dizi işlem gerçekleştirilmelidir. Yedi filtre (Gauss, Wiener, Ortalama, Medyan, Perona ve Malik,

Lee, Frost) kullanılarak görüntüler işlenmiş ve sonuçları karşılaştırmışlardır (Cevik vd. 2016). Ham görüntülerin kalitesi zirve sinyal-gürültü oranı (PSNR) ve ortalama kare hatası (MSE) ölçütleri ile değerlendirmişlerdir. Aynı filtreler bölütleme öncesi görüntülere uygulanmış ve bölütleme sonrası sonuçları analiz etmişlerdir. GKD tanısında, ilium ve femoral bölgeler Aktif Kontur Modelleri ve Dairesel Hough Dönüşümleri teknikleri ile ayrıştırılmıştır. Çalışmanın bulguları, Wiener filtresinin hem ilium hem de femoral bölgede yüksek başarı oranları elde ettiğini göstermiştir (Cevik vd. 2016).

Graf yönteminde belirtilen alfa ve beta açıları, görüntü işleme teknikleri (İnceltme, Budama, İskelet Çıkarım ve Dal Noktası Belirleme) ile görüntüden hesaplanır. Bu açılarla Graf yönteminin sınıflandırması yapılır ve uzman görüşleriyle karşılaştırılarak yöntemin doğruluğu değerlendirilir. Alfa ve beta açılarından elde edilen temel çizgi/femur oranı gibi yeni özellikler kullanılarak, yapay zekâ algoritmaları ile GKD tanısı için alternatif bir sınıflandırma yöntemi sunulmuştur (Cevik 2016).

Kemik/kıkırdak yapılar genellikle komşu yapılarından belirgin bir şekilde daha hiper-ekoik olduğundan dolayı, kemik/kıkırdak sınırlarını yerleştirmek için genellikle yapılandırılmış faz simetrisi diye adlandırdıkları yöntemi kullanmaktadırlar (Quader vd. 2015). Bu yöntemin, görüntüdeki bozukluklara ve yön değişimlerine karşı dayanıklı olduğunu ve SPS ile elde edilen kemik/kıkırdak sınırlarının GKD tanısında etkili olduğunu gösterdiler. Sunulan yöntemleri yeni ve otomatik sınıflandırma sağladı (Quader vd. 2017).

Ultrason görüntüsünü çeşitli ölçeklerde superpiksellere bölünmüştür. Bunun için basit lineer iteratif kümeleme (SLIC) algoritması kullanılmıştır (Achanta vd. 2012). Bu algoritma, pikselleri görüntünün doğal sınırlarına göre anlamlı gruplara ayırır. Bu superpiksellere faydalanarak bir evrişimsel sinir ağı (CNN) modeli oluşturulmuş ve bunu görüntüleri sınıflandırmak için kullanılmıştır. Bölütleme sonunda apex noktası ve alfa açısı hesaplanmıştır (Hareendranathan vd. 2017).

Parçacık sürüsü optimizasyonunu (PSO) ve istatistiksel seviye seti (SLS) bölütleme yöntemini kullanan kademeli bir yapı geliştirildi. PSO yöntemiyle başlangıç konturunun

konumu ve ilgi alanı (ROI) belirlendi. ROI içinde SLS yöntemiyle anatomik yapıları bölütlenmiştir. Bu anatomik yapıların bilgisini kullanarak çizgi çizme ile alfa ve beta açıları hesaplanmıştır (Sezer ve Sezer 2019).

Hareendranathan (2021) ve arkadaşlarının sunmuş oldukları kalça ultrasonunda tarama kalitesini otomatik olarak değerlendirecek önerilerinde US görüntülerdeki bozukluklar doğru tanıya engel olabileceği için bunu ortadan kaldıran, görüntülerdeki bozuklukları otomatikleştiren bir yapay zekâ önerisi sunmuşlardır. İlium, labrum, femur başı ve ischium olmak üzere dört yer işaretinin görünürlüğü ölçen ve ultrason taraması kalitesini otomatik belirleyen bir yapay zekâ tekniği geliştirmişlerdir (Hareendranathan vd. 2021).

Araştırmalar, bilgisayar destekli görüntü analizlerinin tıbbi alanlarda nesneliliği ve üretkenliği büyük ölçüde artırdığını gösteriyor. GKD'ni ultrason görüntüleri aracılığıyla bilgisayar destekli teşhisin ortopedideki karşılaşılan bazı zorlukları çözebileceğini göstermektedir (Hwang vd. 2021). GKD tanısında kullanılan asetabulum-femur başı açısını ölçen, görüntü bölütleme için Mask R-CNN (He vd. 2017) kullanan ve derin öğrenme yöntemleriyle bebek kalça eklemine normal ya da normal olmayan durumunu belirleyen bir yapay zekâ algoritması geliştirmişlerdir (Hwang vd. 2021).

Derin öğrenme modellerinin medikal alanda kullanımlarının artmasıyla birlikte, GKD teşhisinde de kullanım örnekleri gözlenmeye başladı. Lee (2021) ve arkadaşları da Mask R-CNN (He vd. 2017) modeli ile dört temel anatomik yapıyı bölümlere ayırmak ve ilgili önemli noktaları çıkarmak için iki aşamalı bir eğitim süreci kullandılar. İki aşamalı olan model sürecinde ilk olarak görüntülerin derin ağda bölütlenmesi ardından ilk ağın çıktı sonuçlarını CVAT (2023) ile tekrar etiketlenerek anahtar nokta çoklu tespitine dayalı bir bilgisayar destekli tasarım (CAD) derin öğrenme modeli geliştirilmiştir. Geliştirilen sistem deneyimli tıp uzmanlarıyla karşılaştırılabilir şekilde performans gösterdi, böylece GKD tanısının etkinliğine ve hızına daha fazla yardımcı olunabildi. Bu nedenle, GKD taraması için yardımcı bir yöntem olarak kullanılabilir (Lee vd. 2021).

GKD değerlendirilmesinde, eklem nokta ve yapı öğrenimi temelli bir çalışmayı anatomik yapılar ve işaretler arasındaki ilişkileri birlikte öğrenmek ve GKD'nin otomatik değerlendirilmesi için çok görevli bir yaklaşım önerilmiştir (Hu vd. 2021). Bu yaklaşımda ilk olarak temel anatomik yapıları tespit etmek ve bölümlere ayırmak için Mask R-CNN kullanılmıştır. İkinci olarak, eksik anatomik yapı tahminini doğru ve güvenilir bir şekilde iyileştirmek amacıyla yeni bir şekil benzerliği (Yan vd. 2018) kaybı önerilmiştir. Üçüncü olarak, bölütlenmiş yapıdan ve tespit edilen işaretten tahmin edilen kemik kenarının tutarlılığını sağlamak için işaret-yapı tutarlılığı önceliğini de eklenmiştir. Yapmış oldukları deneyler ile önermiş oldukları yöntemin GKD'nin otomatik olarak değerlendirilmesinde etkili ve güvenilir olduğunu ve klinik alanda potansiyele sahip olduğunu göstermektedir (Hu vd. 2021).

Kalça eklemindeki ana yapıların otomatik olarak bölütlenmesi, sonografi uzmanlarına standart bir düzlem bulma yöntemi sunarak hata oranlarını düşürebilir. Fakat var olan otomatik bölümlendirme yöntemleri, sağlamlık ve doğruluk konusunda hala zorluklarla karşılaşmaktadır. Bu nedenle, yedi ana yapının bölütlenmesi için yeni bir neonatal kalça kemiği bölütleme ağı (NHBS-Net) geliştirilmiştir. Bu ağda, farklı yapıları ayırt etmeyi kolaylaştırmak için geliştirilmiş bir çift dikkat modülü, iki sınıflı bir öznitelik birleştirme modülü ve bir koordinat evrişim çıkış katmanı içeren üç iyileştirme kullanılmıştır. NHBS-Net, deneylerde de gösterildiği gibi, mevcut en iyi ağlardan daha yüksek performans doğruluğu ve genelleme yeteneği ile üstün bir başarı sağlamıştır (Liu vd. 2021).

Tanı sürecinde manuel müdahaleyi en aza indirmeyi hedefleyerek, Graf tip I ve tip II (Graf 2006) kalçalar için tam otomatik standart düzlem tespiti ve açı ölçümü yapabilen, GKD tanısı için derin öğrenme tabanlı bir bilgisayar destekli yöntem geliştirildi (Chen vd. 2022). Önerilen yöntem, anatomik yapı tespit modülü, standart düzlem puanlama modülü ve açı ölçüm modülü olmak üzere üç ana modülden oluşmaktadır. Bu yöntem, iki farklı klinik duruma uyum sağlamaktadır. İlk olarak, statik modda, verilen standart düzlem üzerinden ölçüm ve sınıflandırma yapılır. İkincisi, dinamik modda ultrason videosundan standart bir düzlemin belirlendiği ve ardından ölçüm ve sınıflandırma tamamlanmıştır (Chen vd. 2022). Önerilen yöntem, Graf yönteminin tüm ölçüm

aşamalarını otomatik olarak yapan Bilgisayar Destekli Tanı (BDT) yöntemidir. Yöntemin bir bebeğin kalçasının standart düzlemi ve açısını hızlı ve doğru bir şekilde algılayıp ölçebildiğini ve klinik kullanım için potansiyeli olduğunu göstermektedir (Chen vd. 2022).

Ultrason tarama kalitesini otomatik olarak değerlendirebilen bir yapay zekâ geliştirildi (Hareendranathan vd. 2022a). Bu yeni yapay zekâ yaklaşımı, ultrason muayenesi sırasında veya hemen sonrasında sonograflara tarama kalitesi hakkında geri bildirim sağlamak için kullanılabilir. Ayrıca, düşük kaliteli görüntüleri süzmek ve kalça ultrason muayenelerinin güvenilirliğini artırmak için yorumlama sistemlerinde bir ön işleme adımı olarak da yararlanılabilir (Hareendranathan vd. 2022a).


Kalça displazisi ultrasonunda tarama kalitesinin etkisini azaltmak ve kaliteli taramalar elde etmek için yapay zekâ değerlendirme sistemi geliştirildi ve bir puanlama sistemi önerildi. Bu öneride, puanlama sisteminin tarama kalitesini uygun bir şekilde tanımladığını yapay zekâ tarafından yanlış yorumlanması olası durumları belirttiği görülmüştür (Hareendranathan vd. 2022b).

U-Net ağı kullanarak panoramik radyograflarda diş örneklerinin bölümlenmesi ve sayılması için bir yöntem önerilmiştir (Helli ve Hamamcı 2022). Bu yöntemde görüntü bölütlemesi sonucu elde edilen tahminler üzerinden çeşitli morfolojik işlemler uygulayarak ilgilenilen bölgelerin sınırları belirlenmiştir. Daha sonraki işlemlerde Kanonik Korelasyon Analizi (CCA) yöntemi (Hardle ve Simar 2007) ile sınırları tahmin edilen yerler için piksel metriğinde ölçümleri yapılmıştır. Değerlendirmeler, yöntemin diş görüntülerinin daha ileri işlenmesi ve analizi için bir ön adım olarak hizmet ederek klinik uygulamaya yardımcı olma potansiyelini göstermektedir (Helli ve Hamamcı 2022).

GKD tanısı için derin öğrenme yöntemleri ile ultrasondan düzlem tespiti üzerine YOLO dahil çeşitli ağlar ile eğitimler yapılmış ve eğitim sonuçlarına göre ağların performans sonuçları değerlendirilmiştir (Çevik ve Andaç 2022).

2.2 Kalçada İlgilendiğimiz Yapılar

İnsan anatomisinde, vücudun ağırlığını taşıyan en büyük eklem kalça eklemidir. Kalça eklemi, femur (uyluk kemiği) ve pelvis (leğen kemiği) arasında bulunur. Bu eklem üst gövdeyi ve omurgayı sabit ve dengede tutarken, hareket etmeyi de sağlar. Kalça eklemi, asetabulum ve femur yapıdan oluşur. Asetabulum, kalça eklemine oluşturan leğen kemiği adı verilen kemik yapının sağ ve sol dış kenarlarında bulunan ve çukur halde bulunan yapıdır. İlium, iskium ve pubis kemiklerinin birleşmesi ile asetabulum oluşur. Femur yapısı, uyluk kemiği olarak da bilinen bu yapı kalça anatomisinin en önemli yapılarından biridir. Bu bölgede bulunan ve kalçada incelediğimiz yapılar; Femur yapısı, Asetabulum çatısı, İlium, İskium, Labrum.

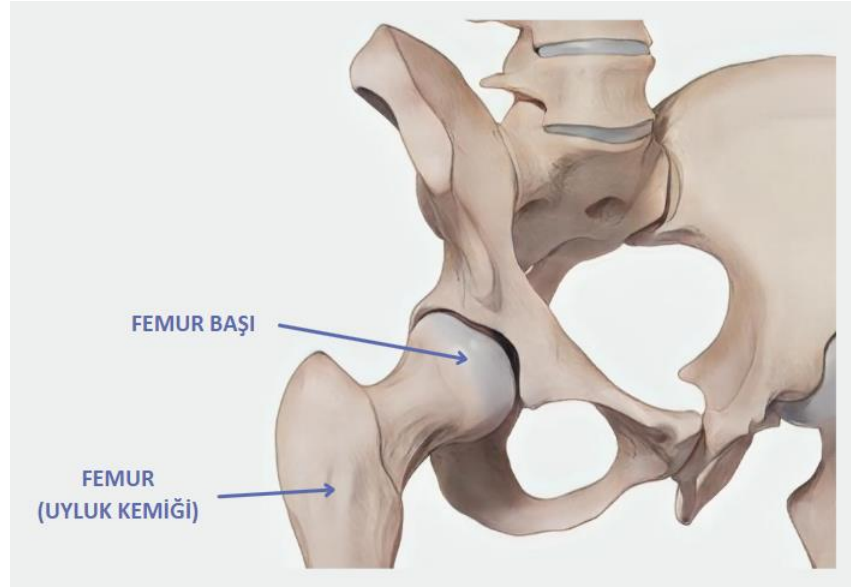


Şekil 2.1 Kalça ultrason bölgeleri. 1. Femur 4. Femur başı 7. Labrum 11. Asetabulum 12. İliumun osifiye ucu 13. İlium (Tuncay 2004)

2.2.1 Femur yapısı

Femur (uyluk kemiği), insan vücut iskeletinin en sağlam, en geniş ve en uzun kemiğidir. Femur, insanı ayakta durmasına ve hareket etmesinde yardımcı olan önemli bir yapıdır. Geniş bir kas dokusu ile bu yapı çevrelenmektedir. Femur yapısı; femur başı, boynu ve küçük yuvarlak çıkıntıları bulunan kemir yapısıdır.

Femur başı, küre şekline benzeyen ve bir kürenin ortalama 2/3'ü kadardır. Femur başı sfenoid (kama) ve bir bölümü de ovoid (yumurta) şekil yapıdadır. Femur başının kişiden kişiye göre eğimli yapısında farklılık gözükür. Pelvisin asetabulumuyla eklem hale gelir.

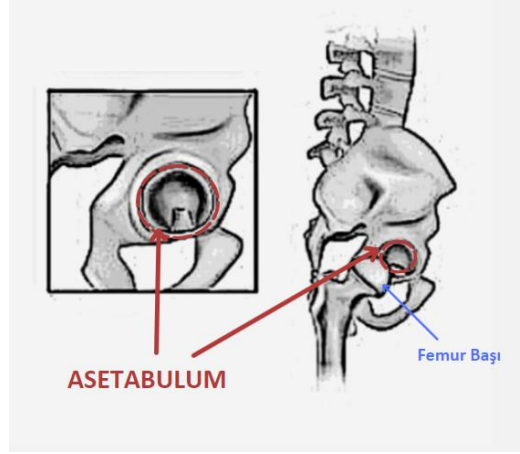


Şekil 2.2 Femur yapısı

2.2.2 Asetabulum

Asetabulum, kalça eklemine oluşturmak için femur başı ile eklem hale gelen ve çanak şeklinde bulunan bir yuvadır. Bu yapı kalça kemiğinin yan yüzünde bulunur. Üç pelvis kemiğinin birleşmesiyle asetabulum oluşur. Bu pelvis kemikleri; ilium, iskium, pubis. Asetabulumun üst sınırını ilium oluşturur ve asetabulumun arka duvarını iskium, ön duvarını ise pubis oluşturur. Asetabulum, kalça eklemi parçası olup, ağırlık taşıyan bir eklemdir. Kalça eklemi, femur başının asetabulumun kupa şeklinde bulunan yuvasının içinde oturduğu ve döndüğü için buna top-çukur eklemi denir.

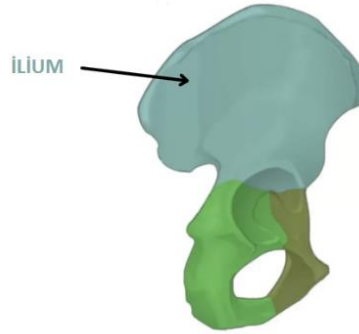
Kalça eklemi omurga üzerinden gelen ağırlığı asetabulumla ve alt ekstremitelere aktarır ve bu sayede, gerekli hareket aralığı sağlamış olur. Örneğin, yürüme, koşma ve zıplama gibi hareketlere olanak sağlar.



Şekil 2.3 Asetabulum yapısı

2.2.3 İlium

Pelvis ve kalça kemiğinin üst kısmını oluşturan yapıya ilium adı verilir. İlium, kalçanın en büyük ve en üstünde bulunan kemiğidir. Ayrıca, leğen kemiği içinde önem taşımaktadır. Ağırlık taşıma işlevi gören ilium, vücut dik konumda olduğunda omurganın desteklenmesini sağlar.

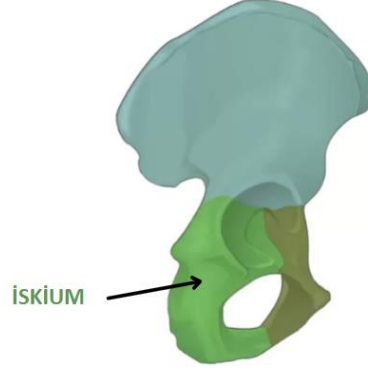


Şekil 2.4 İlium

2.2.4 İskium

İskium, ilium ve pubis kemikleri ile birlikte kalça kemiğini oluştururlar. İskium, gövde, alt ramus ve üst ramustan olmak üzere üç bölümden oluşur. Kalça kemiğinin alt ve arka


kısmını iskiium oluřturur. İskiium üzerinde, otururken ağırlığı desteklemeyi saęlayan iskiial tüberozite bulunur.



Őekil 2.5 İskiium

2.2.5 Labrum

Labrum, top-çukur ekleminin yuvasını çevreleyen çerçevedir. Kıkırdaktan oluřan labrum, kalça saęlığı ve hareket fonksiyonu için önemlidir. Labrum, özellikle kalçanın hareket aralığını rahatlatarak uyluk kemięinin her yöne dönmesine yardımcı olur. Ekleme destek ve esneklik saęlayan kıkırdak halkası kalça labrumudur. Hasar gören labrum da kalçanın hareket aralığı, hizalaması ve sinovyal sıvısı etkilenebilir. (Sinovyal sıvı: stresi ve sürtünmeyi azaltır. Top-çukur eklemi arasında düzgün hareket saęlar.)




Őekil 2.6 Labrum

3. MATERYAL VE YÖNTEM

GKD üzerine yapılan çalışmalar günümüzde gittikçe artış göstermiş ve farklı teknik ve yöntemler ile alanında uzman doktorlara yardımcı sistemler olma yönünde hızla ilerlemiştir. Çalışmamızda yapmış olduğumuz gibi yapılan diğer çalışmalarda da görüldüğü üzere teşhis süresini ve doğruluğunu arttırdıkları için bilgisayar destekli yardımcı sistem olarak tercih sebebi olmaya başlamışlardır. Bu bölümde çalışmamızda kullandığımız materyallerin elde edilmesinden, elde edilen materyallerin çeşitli işlemlere tabi tutulup işlenip değerlendirilmesine, uygulanan yöntemlerin teknikleri ve ağ yapılarının mimarilerinden, farklı derin öğrenme ağlarında eğitilmesinden ve eğitim sonrası yapılan işlemlere kadar birçok noktadan bahsedilmiştir.

3.1 Verilerin Toplanması

Tez çalışmamızda öz hazırlık süreci olarak US görüntülerin elde edilmesi süreci olmuştur. Öncelikle US görüntülerin temin edilebilmesi için bir etik kurulu süreci işlemiştir. Etik kurulu onayı alındıktan sonra görüntülerin temin süreci başlamıştır. Bu süreçte US görüntüler uzman radyolog tarafından temin edilmiştir. TOBB ETU Hastanesi'nde görüntüleme işlemleri için kullanılan US cihazı, Philips Medical Systems'e ait olan EPIQ 5G cihazıdır. US görüntüleri bu cihazdan alınmıştır. Buradan temin edilen görüntüler DICOM (Digital Imaging and Communications in Medicine) formatındadır. DICOM, medikal görüntüleme cihazlarıyla 2 veya 3 boyutlu bilimsel verileri saklamak, göstermek ve analiz etmek için kullanılan bir dijital veri formatıdır. Elde edilen DICOM görüntüler dcm uzantılı olup 2B (2 Boyutlu) görüntü tipinde ve her biri kesit olarak toplanmıştır. Tüm bu görüntüler bir araya getirilmiş ve bir görüntü havuzu oluşturulmuştur. Bu havuzda 2200 US görüntüsü bulunmaktadır. Her bir görüntü ham halde olduğu için elenmesi ve değerlendirilmesi gerekmektedir. Bazı görüntüler eğitimde kullanılamayacak kadar bozuk ve anlamlandırılmayacak kadar karmaşık haldedir, bu tipte olan görüntülerin elenmesi gerekmektedir. Şekil 3.1'de kullanıma uygun olan bir US ham görüntüsü örneği gösterilmektedir.



Şekil 3.1 Örnek US ham görüntüsü


3.2 Görüntülerin Değerlendirilmesi ve Etiketlenmesi

Uzman doktor gözetiminde, oluşturulan görüntü havuzundan, bakılacak bölgeye uygun, görüntü kalitesi ve açıları net olan görüntüler elenerek seçilmiştir. Görüntüleri ham hallerinden dışarıya aktarmak için RadiAnt DICOM Viewer adlı program kullanılmıştır. Dışarıya aktarılan görüntüler JPEG formatında ve gri seviye olarak aktarılmışlardır. Tüm görüntüler aktarıldıktan sonra ilgilenilen yapılar ortalayacak şekilde hizalanan görüntülerden uzman doktor onayında 640x640 piksel boyutunda olacak şekilde görüntüler kırılmışlardır. Elenme ve kırılma işlemlerinden sonra veri kümesi oluşturmak için kalan görüntü sayısı 452 adettir. Belirlenen bu görüntülerde GKD bulunmamaktadır. Tüm bu işlemlerde görsellerin eğitime uygunluk değerlendirmesi uzman doktorun ilgili bölgelerin görünürlüğü ve görüntülerde bozulma olmaması durumları dikkate alınarak uygulanmıştır.

Veri seçimi ve veri kümesi hazırlığı aşamaları tamamlandıktan sonra sıra veriyi etiketlemeye gelmiştir. Veri etiketlenmesi için tercih edilen program, başlangıçta Intel'in yapay zekâ birimi tarafından veri setlerinde etiketleme işlemlerini yapmak için açık kaynak olarak geliştirilmeye başlanmış daha sonraları OpenCV (Open Source Computer

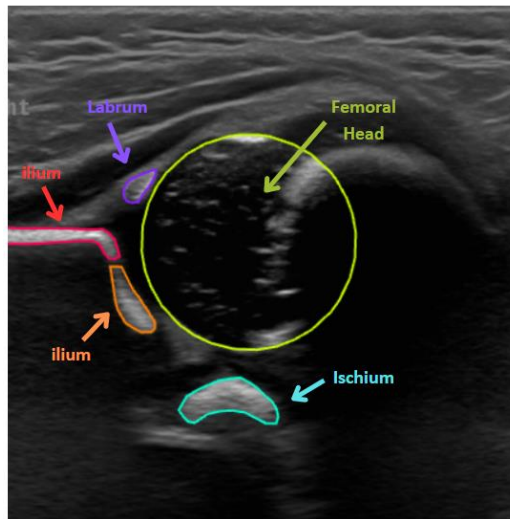
Vision Library) içerisine dahil edilmiş olan CVAT (Computer Vision Annotation Tool) olmuştur (CVAT 2023).

CVAT'da görüntüler 4 bölge (ilium, ishium, labrum ve acetabulum çatısı) için çokgen (polygon) etiket biçimi tercih edilmiş, 1 bölge (femur başı) için eliptik etiket biçimi olarak etiketlenmiştir. Şekil 3.2'de CVAT programının ve etiketlerin bir örneği gösterilmiştir.



Şekil 3.2 CVAT programı ve etiketleme örneği

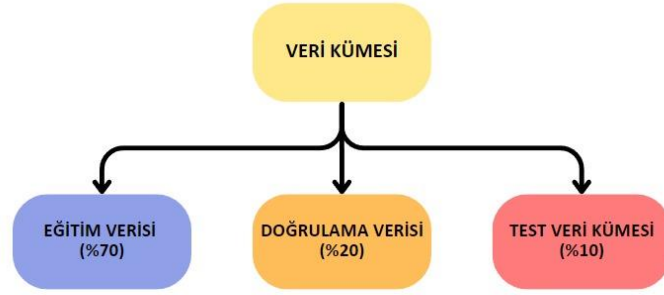
Bahsi geçen ilgililenen bölge ve anatomik yapılar şekil 3.3'de gösterilmiştir.



Şekil 3.3 İlgilenilen bölge ve ilgilendiğimiz anatomik yapılar

3.3 Verilerin Ön İşlemesi

Etiketlenmiş görüntüleri CVAT’da çeşitli veri kümesi biçimleri olarak dışarı aktarmak mümkündür. Bunlardan biri COCO (Common Objects in Context) (Lin vd. 2014) formatıyla bir veri kümesi ve bir diğeri CVAT’da bulunan “Segmentation Mask 1.1” formatıyla bir veri kümesi olmak üzere iki veri kümesi formatında çıktılar alınmıştır. Oluşturulan iki veri kümesinden COCO formatında olan ilkinin yapısı, %70 eğitim, %20 doğrulama ve %10 test olacak şekilde hazırlanmıştır (Şekil 3.4).



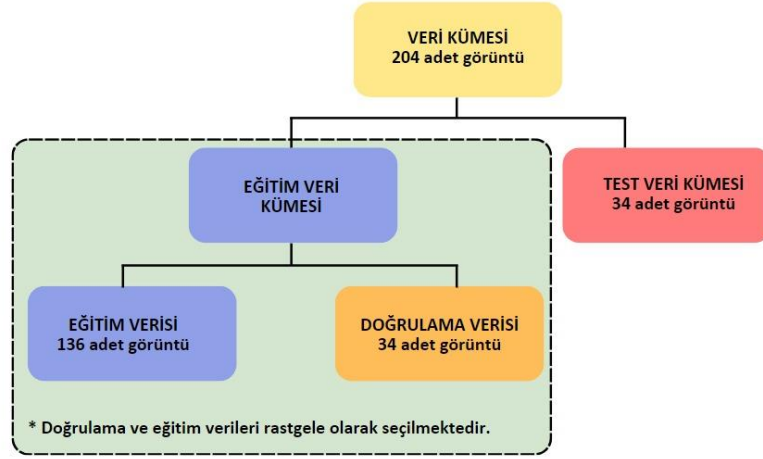
* Eğitim, Doğrulama ve Test kümeleri rastgele oluşturulmuştur.

Şekil 3.4 Veri kümesi 1 yapısı

Oluşturulmuş birinci veri kümesinde, eğitim öncesi, eğitim kümesi görüntüleri üzerinde çoğaltma işlemi uygulanmıştır. Bu çoğaltma işlemi eğitim örneği başına çıktı sayısı 2 ve parlaklık oranı %0 - %25 arası artırılması rastgele olacak şekilde gerçekleştirilmiştir. Yani eğitim veri kümesinde olan resimler orijinal halleri ve parlaklığı %25 artırılmış halleri bulunacak şekilde ayarlanmıştır. Son durumda veri kümesinde oranlar; %82 eğitim, %12 doğrulama ve %6 test olacak şekilde ayarlanmıştır.

CVAT “Segmentation Mask 1.1” formatında olan veri kümesinde ise görüntü azaltmaya gidilmiş görüntü sayısı 204’e indirilmiştir. Görüntü azaltmasında kriter; ilgilenilen bölgedeki anatomik yapıların herhangi bir çoğaltma işlemi yapmadan görüntü kalitesine dikkat ederek, tam ve eksiksiz seçilebiliyor olmasıdır. Görüntüler ve görüntülerin maskelerinden oluşan bu veri kümesi bölütleme çalışması için başlangıçta %84 eğitim ve

%16 test kümesi olarak ayarlanmış, model eğitim aşamasında eğitim kümesinden rastgele oluşacak şekilde %20 oranında bir doğrulama kümesi de oluşturulmuştur (Şekil 3.5).



Şekil 3.5 Veri kümesi 2 yapısı

Aşağıdaki çizelgede iki veri kümesinin karşılaştırılmalı yapısı gösterilmektedir.

Çizelge 3.1 Veri kümelerinin toplam veri kümelerine göre son durum karşılaştırılması


	Veri Kümesi 1		Veri Kümesi 2	
	Yüzde	Sayı	Yüzde	Sayı
Eğitim Veri Kümesi	%82	632	%68	136
Doğrulama Veri Kümesi	%12	91	%16	34
Test Veri Kümesi	%6	45	%16	34
Toplam Görüntü Sayısı	768 görüntü		204 görüntü	

3.4 Model Yapıları

3.4.1 Yapay sinir ağları

Zaman içerisinde teorik, yazılımsal ve donanımsal süreçlerden geçen yapay zekâ kavramı, insanların işten ve zamandan kazanım için makineleri otomatikleştirme çabalarıyla birlikte gelişim ve değişime uğramıştır. Teknolojinin ilerlemesi, teorik alt yapının güçlenmesi ve alana duyulan ilgi sayesinde yapay zekâ kavramında özelleşmeler

olmuş, makine öğrenmesi derin öğrenme gibi alt kümeler oluşmaya başlamıştır. Bu alt küme sistemleri mühendislik, tıp gibi pek çok bilimsel alanda yaygın olarak kullanılmaktadır. Bu sistemler, özellikle bir alanda uzmanlaşmış olmayı gerektiren karar verme süreçlerinde hem zaman kazandırmakta hem de insan kaynaklı hataları azaltmaktadır. Bu sistemlerde yer alan yapay sinir ağı modelleri (YSA), insan beyninin işleyişini taklit etmek için sinir sistemlerine dayanarak oluşturulmuş birimlerden oluşmaktadır. İnsan sinir sistemi, bir duruma tepki vermek için birbirleriyle iletişim halinde olan ‘nöron’ adlı hücrelerden oluşmaktadır. Şekil 3.6’da gösterildiği gibi bir nöronun temel yapısında; çekirdek, dentrit (giriş terminali) ve akson (çıkış terminali) vardır.



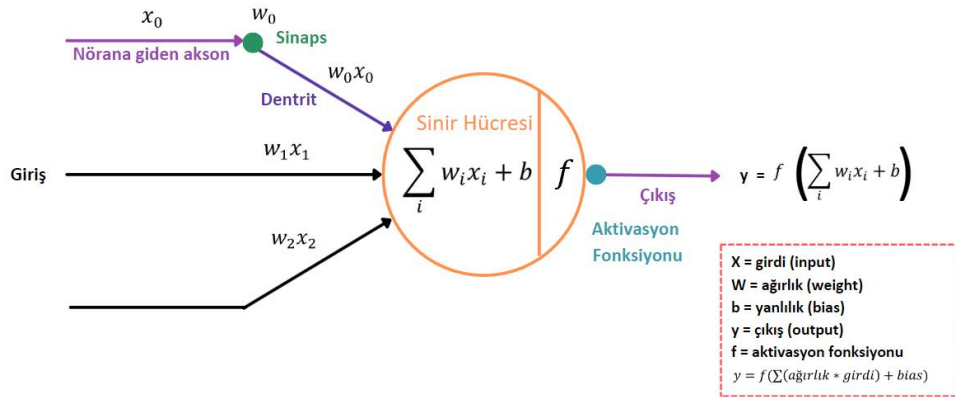
Şekil 3.6 İnsan nöron yapısı biyolojik gösterimi (Özcan 2020)

İngiliz matematikçi ve bilgisayar bilimcisi Alan Mathison Turing, 1950 yılında ‘bir makine akıl yürütebilir mi’ diye sormuştur (Turing 1950). Bu soru ile birlikte makinelerin belirli görevleri dış müdahale olmadan yapabilmesi için bilim insanları yöntemler aramaya başladılar. Çizelge 3.2’de verilmiş olan yapay zekâ ve derin öğrenmenin belirli bir tarihi incelendiğinde görüleceği üzere artarak ilerlediği görülmektedir. Çizelge 3.2’ye ek olarak 1943 yılında McCulloch-Pitts nöronları adında sinir ağının matematiksel modelini sunarak McCulloch vd. katkı sağlamışlardır. Tabloya ek olarak Kohonen 1982 yılında Kohonen ağlarını sunarak ve 1982 yılında John Hopfield, Hopfield ağlarını sunarak yapay zekâ ve derin öğrenmeye katkı sağlamışlardır. Yann LeCun ise el yazısı olan rakamları okuyarak ve gradyan tabanlı öğrenim ile yapay zekanın popülerliğini artmasına katkı sağlamıştır.

Çizelge 3.2 Derin öğrenmede bazı kilometre taşları (Schmidhuber 2022)

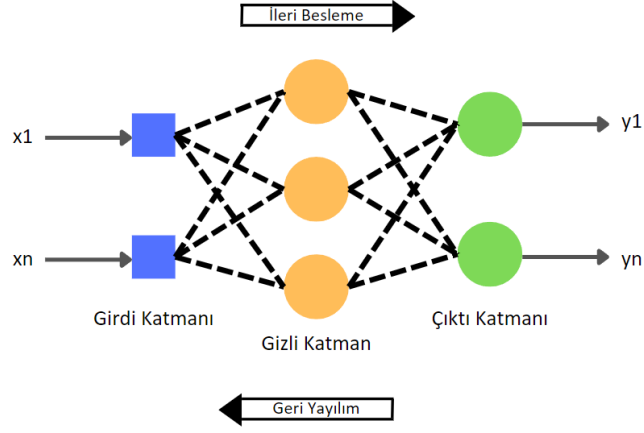
Yıl	Sunulan Yöntem İsmi	Yöntemi Geliştiren
1676	Zincir Kuralı	Gottfried Wilhelm Leibniz
1805	Doğrusal Sinir Ağı (En Küçük Kareler Yöntemi)	Adrien-Marie Legendre
1920'ler	İlk Tekrarlayan Ağ Mimarisi	Ernst Ising ve Wilhelm Lenz
1958	Çok Katmanlı İleri Beslemeli Sinir Ağı	Frank Rosenblatt
1965	İlk Derin Öğrenme	Alexey Ivakhnenko ve Valentin Lapa
1967	Stokastik Gradyan İnişiyle Derin Öğrenme	Shun-Ichi Amari
1970	Geri Yayılım	Seppo Linnainmaa
1979	İlk Derin Evrişimli Sinir Ağı	Kunihiko Fukushima
1990	Stokastik Delta Kuralı (Dropout)	S. J. Hanson
1991	Temel Sorun: Kaybolan Gradyanlar	Sepp Hochreiter
1997	Uzun Kısa Süreli Bellek (LSTM) tekrarlayan sinir ağı	Sepp Hochreiter
2014	Çekişmeli Üretici Ağlar	Ian Goodfellow

Yapay Sinir Ağı (YSA), çok sayıda işlem birimi olan nöronlardan oluşan bir yapıdır. Bu nöronlar birbirine bağlıdır ve her biri bir "w" ağırlığı ve bir "b" sapması (bias) ile ilişkilidir. Rosenblatt tarafından 1957 yılında öne sürülen, basit bir yapay nöron modeline "Algılayıcı" adı verilmiştir (Rosenblatt, 1957). Bir algılayıcı, gelen x verilerini w ağırlıkları ile çarpar ve sapma değeri eklenerek toplanır. Bu toplam, bir eşik değerinin üzerindeyse, nöron aktif olur ve bağlı olduğu diğer nöronları etkiler (Şekil 3.7).



Şekil 3.7 Algılayıcı (Perceptron) model yapısı

Bir YSA yapısında girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanı bulunmaktadır. Yapay sinir ağındaki gizli katman çoğaldıkça o ağa derin sinir ağı denir (Sazlı, 2006). Şekil 3.8’de bir YSA’nın yapısı görülmektedir.



Şekil 3.8 Gizli katmanı tek olan bir yapay sinir ağı gösterimi

3.4.2 Aktivasyon fonksiyonları

Aktivasyon fonksiyonu, YSA’nın doğrusal olmayan problemleri çözmesini sağlar. Bir YSA’da girişler x , ağırlıklar w olarak belirlenir ve bunların birleşimi olan $f(x)$ aktivasyon fonksiyonundan geçirilir, denklem 3.1’de belirtildiği gibi çıkış işlemi olarak aktivasyon fonksiyonuna tabi tutulur. Oluşan değer, sonuç veya başka bir katmana giriş olarak kullanılır. Aktivasyon fonksiyonu olmayan bir sinir ağı, sınırlı öğrenme kapasitesine sahip olup doğrusal regresyon gibi davranacaktır.

$$y = b + \sum_i w_i x_i \rightarrow f(y) \quad (3.1)$$

Evrişim katmanı tarafından üretilen giriş sinyallerinden daha karmaşık özelliklerin çıkarılması için, aktivasyon katmanının doğrusal olmayan özelliği gereklidir. (Sezer ve Sezer 2019). Çeşitli aktivasyon fonksiyonları bulunmaktadır (Çizelge 3.3).

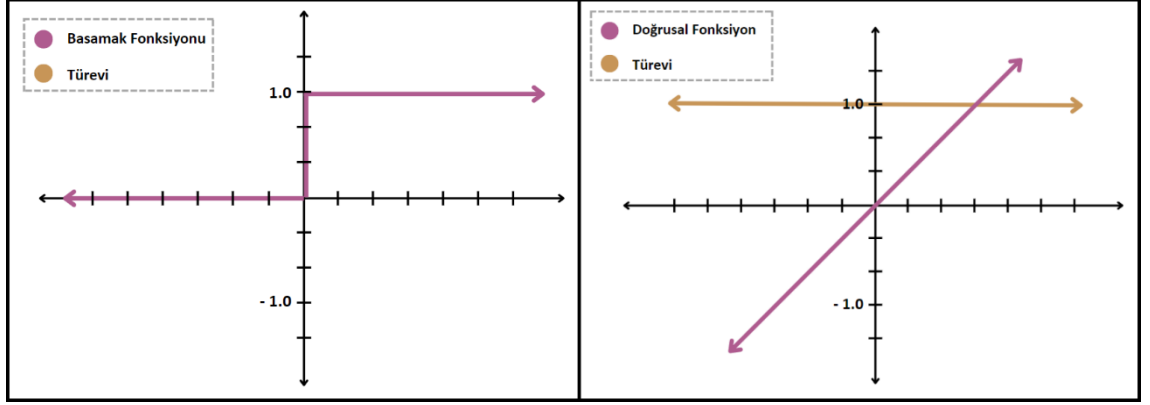
Çizelge 3.3 Bazı aktivasyon fonksiyonları

Aktivasyon Fonksiyonu	Denklem	Aralık
Doğrusal	$f(x) = x$	$(-\infty, \infty)$
Basamak	$f(x) = \begin{cases} 0, & \text{eğer } x < 0 \\ 1, & \text{eğer } x \geq 0 \end{cases}$	$\{0,1\}$
Sigmoid	$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	$(0,1)$
Hiperbolik Tanjant (tanh)	$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$(-1,1)$
Düzeltilmiş Doğrusal Birim (ReLU)	$f(x) = \begin{cases} 0, & \text{eğer } x < 0 \\ x, & \text{eğer } x \geq 0 \end{cases}$	$[0, \infty)$
Sızıntı (Leaky) ReLU	$f(x) = \begin{cases} 0.01x, & \text{eğer } x < 0 \\ x, & \text{eğer } x \geq 0 \end{cases}$	$(-\infty, \infty)$

Basamak fonksiyonu iki olası değer üreten bir fonksiyondur ve ikili sınıflama problemlerinde kullanılır. Bu nedenle çoğunlukla çıkış katmanında yer alır. Gizli katmanlarda ise türevinin öğrenme değerine katkısı olmadığı için önerilmez. Basamak fonksiyonun formülü denklem 3.2’de belirtilmiştir. YSA’larda aktivasyon fonksiyonu olarak doğrusal fonksiyon kullanıldığında birkaç sorunla karşılaşmaktayız. Bu fonksiyonun bir sorunu, türevinin değişmemesi, sabit olmasıdır. Geriye yayılım algoritması ile nöronlarda öğrenme işlemini gerçekleştirirken, bu algoritma türevlere dayanır. Bu durumda, değişken x ile ilişkinin kaybolmasına neden olur. Başka bir sorun da doğrusal fonksiyonların tüm katmanlarda kullanılmasıdır. Bu durum, giriş ve çıkış katmanları arasında her zaman aynı doğrusal ilişkinin oluşmasına yol açar. Doğrusal fonksiyonların kombinasyonu yine doğrusal bir fonksiyondur. Bu da ara katmanların işlevsiz halde olduğu anlamına gelir. Doğrusal fonksiyonun formülü denklem 3.3’de belirtilmiştir. Şekil 3.9’da basamak ve doğrusal fonksiyon gösterilmiştir.

$$\text{Basamak fonksiyonu: } f(x) = \begin{cases} 0, & \text{eğer } x < 0 \\ 1, & \text{eğer } x \geq 0 \end{cases} \quad (3.2)$$

$$\text{Doğrusal fonksiyon: } f(x) = x \quad (3.3)$$



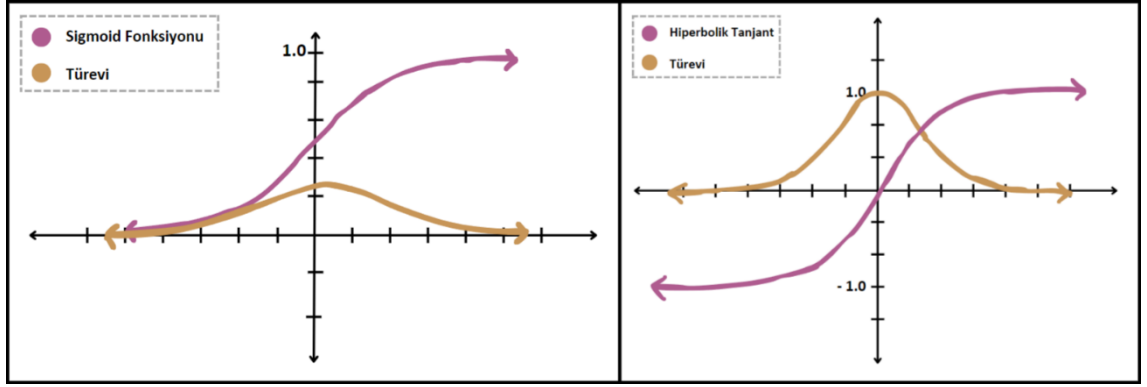
Şekil 3.9 Basamak ve doğrusal fonksiyon grafikleri

Sigmoid fonksiyonu genellikle ikili sınıflandırma problemlerinde çıkış katmanında kullanılan bir fonksiyondur. Bu fonksiyonun iki asimptotu vardır ve giriş değerlerini (0, 1) aralığına sıkıştırır. Giriş değeri artı sonsuza yaklaştığında fonksiyonun çıkışı 1'e, giriş değeri eksi sonsuza yaklaştığında ise fonksiyonun çıkışı 0'a yaklaşır (Turhan ve Talu 2022). Sigmoid fonksiyonun matematiksel ifadesi denklem 3.4'de belirtilmiştir. Bu fonksiyonda, x'teki küçük değişimler y'de büyük değişime neden olur. Bu durum, ikili sınıflandırmada iyi bir performans göstermesini sağlar. Y değerleri, x'teki değişikliklere çok az tepki gösterdiğinde, türev değerleri çok küçük olur ve neredeyse sifıra yaklaşır, bu duruma 'gradyanın ölmesi' denir ve öğrenme süreci minimum seviyede gerçekleşir. Yavaş bir öğrenme süreci, optimizasyon algoritmasının en düşük yerel değere takılmasını ve en düşük genel noktasını bulamamasını da beraberinde getirir. Bu, yapay sinir ağının verimliliğini azaltır.

Hiperbolik tanjant fonksiyonu, girdileri -1 ile 1 arasında bir değere indirger (Turhan ve Talu 2022). Sigmoid fonksiyonundan farklı olarak, türevi daha dik bir eğriye sahiptir ve daha fazla değer üretir. Bu da, daha hızlı öğrenme ve sınıflama yapabilmek için daha geniş bir aralık sunar. Fakat fonksiyonun uç noktalarında, gradyanların sifıra yaklaşması sorunu hâlâ devam eder. Hiperbolik tanjant fonksiyonun matematiksel ifadesi denklem 3.5'de belirtilmiştir.

$$\text{Sigmoid: } f(x) = \sigma(x) = \frac{1}{1+e^{-x}} \quad (3.4)$$

$$\text{Hiperbolik Tanjant: } f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.5)$$

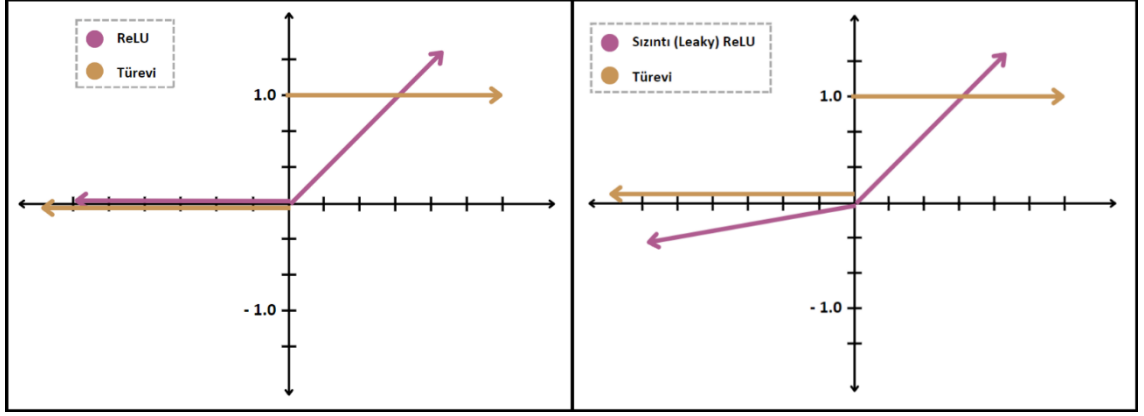


Şekil 3.10 Sigmoid ve hiperbolik tanjant fonksiyon grafikleri

Fukushima'nın 1969'da tanıttığı düzeltilmiş doğrusal birim (ReLU) sinir ağları için yeni bir soluk niteliğindedir (Fukushima 1969). 1975 ve 1980 yılında yaptığı yayınlarda da aktivasyon fonksiyonu olarak kullanılabileceği gösterilmiştir (Fukushima 1975). ReLU fonksiyonu, günümüzde çok kullanılan ve popüler bir aktivasyon fonksiyonudur. Biyolojik nöronların çalışma şekline benzer. Gelen değer negatifse, sıfır çıktısı verir (Sezer ve Sezer 2019). Gelen değer pozitifse, değişiklik yapmadan aynen aktarır. Bu sayede, tanh ve sigmoid gibi karmaşık hesaplamalar gerektirmeyen bir fonksiyondur. Bu da bilgisayarın daha hızlı çalışmasını sağlar. ReLU fonksiyonu, sigmoid ve hiperbolik tanjant fonksiyonlarından daha az hesaplama gerektirdiği için çok katmanlı ağlarda daha sık kullanılmaktadır (Helli ve Hamamcı 2022). ReLU negatif değerlerin öğrenilmesini önler ve bu durum bazı nöron değerlerinde gradyanların sıfıra yaklaşması sorununu doğurur. ReLU sıfır değerli bölgede hesaplama yapmadığı için hızlıdır. Ancak, bu bölgenin türevi de sıfırdır. Bu da o bölgede öğrenme olmadığı anlamına gelir. Bunun önüne geçebilmek için sızıntı (Leaky) ReLU fonksiyonu önerilmiştir. Leaky ReLU, negatif girdiler için sıfırdan farklı ama çok küçük bir çıktı verir. Böylece nöronlar tamamen ölmez ve geriye yayılım sırasında gradyan akışı sağlanır. Bu da negatif bölgede de öğrenme imkânı verir. ReLU ve Leaky ReLU fonksiyonlarının matematiksel ifadesi denklem 3.6'da ve denklem 3.7'de belirtilmiştir.

$$\text{ReLU: } f(x) = \begin{cases} 0, & \text{eğer } x < 0 \\ x, & \text{eğer } x \geq 0 \end{cases} \quad (3.6)$$

$$\text{Leaky ReLU: } f(x) = \begin{cases} 0.01x, & \text{eğer } x < 0 \\ x, & \text{eğer } x \geq 0 \end{cases} \quad (3.7)$$



Şekil 3.11 ReLU ve Leaky ReLU fonksiyon grafikleri

3.4.3 Optimizasyon algoritmaları

Leibniz'in (1676) zincir kuralıyla başlayan, optimal uçuş yollarının gradyan teorisi (Kelley 1960) ile şekil almaya gelişen ve sinir ağlarına uygulanmasıyla devam eden, günümüzde ise yaygın olarak kullanılan geri yayılım (backpropagation) algoritması ilk olarak Finli Seppo Linnainmaa tarafından modern anlamında yayınlandı (Linnainmaa 1970). Bir sinir ağının ağırlıklarını, bir kayıp fonksiyonunun değerini azaltacak şekilde güncelleyen en popüler algoritmalarından biri geriye yayılmadır (Hecht-Nielsen, 1992). Geriye yayılma, kayıp fonksiyonunun yerel bir minimum noktasına doğru adım adım ilerleyen gradyan inişi yöntemiyle yapılır. Ancak, basit gradyan inişi, derin bir ağı eğitmek için çok yavaş olduğundan sıkça kullanılmaz. Bu nedenle, araştırmacılar gradyan inişini daha hızlı yapan optimizasyon algoritmaları üzerinde çalışmaktadır.

Model ağırlıklarını kayıp fonksiyonunun gradyanlarına göre güncelleyerek optimizasyon yapan en basit algoritma gradyan iniştir. En uygun bias ve ağırlık değerlerini seçerek maliyet en düşük seviyeye çekilmeye çalışılır. Gradyan inişi, kapsamlı ve etkili bir optimizasyon yöntemidir (Ruder 2016). Makine öğrenmesinde gradyan inişi sıkça kullanılır, çünkü makine öğrenmesinin hedeflerinden biri, eğitim verisine göre en iyi doğruluğu sağlamak veya hatayı minimize etmektir (Denklem 3.8).

Gradyan inişi, “maliyet fonksiyonunu” küçültmek için minimum hatayı elde etmek için uygulanır. Gradyan inişini adım adım bakacak olursak:

- Bir $J(w,b)$ başlangıç noktası alınır.
- J 'nin değerlerini küçültmek için gradyan inişi adımları atılır. Bu yöntemin esas hedefi, tahminle ilişkili hatayı en aza indirmek için riski gradyan inişleriyle azaltmaktır. Her adımda ağırlıklar gradyanlara göre güncellenir.

Denklem 3.8, denklem 3.9, denklem 3.10, denklem 3.11, denklem 3.12, denklem 3.13 ve denklem 3.14’de adımlar matematiksel ifadeleriyle sırasıyla belirtilmiştir.

$$Maliyet(b, w) = \frac{1}{2m} \sum_{i=1}^m (b + wx_i - y_i)^2 \quad (3.8)$$

$$J(\theta_0, \theta_1) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2 \quad (3.9)$$

$$\underset{\theta_0, \theta_1}{\text{minimize}} J(\theta_0, \theta_1) \quad (3.10)$$


Türevi (parametrelerin güncellenmesi):

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m h_{\theta}(x^{(i)}) - y^{(i)} \quad (3.11)$$

$$\theta_1 := \theta_1 - \alpha \frac{1}{m} \sum_{i=1}^m h_{\theta}(x^{(i)}) - y^{(i)} \cdot x^{(i)} \quad (3.12)$$

$$\text{Tekrarla} \{ \theta_j \leftarrow \theta_j - \alpha \frac{\partial}{\partial \theta_j} J(\theta) \} \quad (3.13)$$

Şekil 3.12’de görüldüğü gibi minimum seviyeye ulaşana kadar bu durum tekrar eder.



Şekil 3.12 Gradyan iniş gösterimi

Gradyan inişi yönteminin bazı olumsuz yönleri vardır. Her adımda yapılan hesaplamaların miktarını daha dikkatli incelemeyi gerektirmektedir. Gradyan inişi, büyük veri kümelerinde fazla hesaplama yapar, çünkü her parametre değişikliğinde aynı örneklerin gradyanlarını tekrar tekrar bulur (Ruder 2016). Bu zorluğun önüne geçebilmek için Stokastik Gradyan İnişi (SGD) önerilmiştir. SGD ilk defa 1967 yılında Shun-Ichi Amari tarafından ortaya atılmıştır (Amari 1967). SGD her eğitim örneği $x^{(i)}$ ve etiket $y^{(i)}$ için bir parametre güncellemesi gerçekleştirir:

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta; x^{(i)}; y^{(i)}) \quad (3.14)$$

SGD, her adımda bir güncelleme yaparak bu gereksizliği giderir. Bu sayede gradyan inişe göre daha hızlı olur. SGD'de amaç fonksiyonun dalgalanmasına sebep olacak yüksek değişkenli güncellemeler yapar.

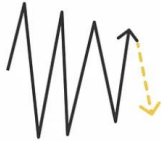
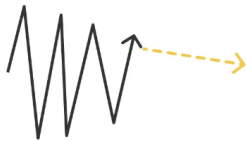
Momentum, SGD'yi ilgili yönde hızlandırmaya yardımcı olan ve salınımları söndüren bir yöntemdir (Qian 1999). Bunu, geçmiş zaman adımının güncelleme vektörünün kesrini mevcut güncelleme vektörüne ekleyerek yapar (Ruder 2016).

$$V_t = \beta V_{t-1} + (1 - \beta) dw_t \quad (3.15)$$

$$W_t = W_{t-1} - aV_t \quad (3.16)$$

Momentumun bu yöntemi sayesinde iniş daha hızlı gerçekleşir (Çizelge 3.4).

Çizelge 3.4 Gradyan iniş ve momentum karşılaştırma

Gradyan İnişi	Momentum
	

Günümüzde yaygın ve tercih edilen optimizasyon algoritması olan Adam, Momentum ve RMSProp algoritmalarını etkili bir şekilde birleştiren bir yaklaşım sunar. Bu başarıyı elde etmek için, sırasıyla hesaplanan gradyanlar ve kareli gradyanlar için üstel hareket eden ortalamaları izler (Kingma ve Ba 2014).


$$v_t = \beta_1 v_{t-1} + (1 - \beta_1) dw_t \text{ --- bias düzeltmesi ---} \hat{v}_t = \frac{v_t}{1 - \beta_1^t} \quad (3.17)$$

$$s_t = \beta_2 s_{t-1} + (1 - \beta_2) dw_t^2 \text{ --- bias düzeltmesi ---} \hat{s}_t = \frac{s_t}{1 - \beta_2^t} \quad (3.18)$$

Adam güncelleştirme kuralı:

$$w_t = w_{t-1} - \frac{a \hat{v}_t}{\sqrt{\hat{s}_t + \epsilon}} dw_t \quad (3.19)$$

Şekil 3.13’de Adam inişi gösterilmiştir.

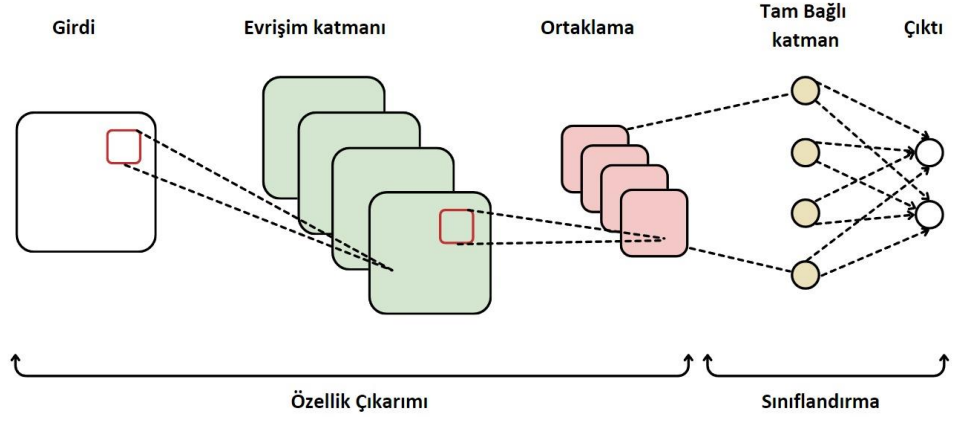


Şekil 3.13 Adam iniş gösterimi

Çalışmamızda kullanmış olduğumuz optimizasyon algoritmaları Stokastik Gradyan İniş (SGD) ve Uyarlanabilir Moment Tahmini (Adam) olmuştur.

3.4.4 U-NET

YSA'nın karmaşık verilerle iyi başa çıkmasına rağmen, neden alternatiflere ihtiyaç duyulmaktadır? Girdi olarak bir görüntü alan bir sinir ağını ele alalım, bu görüntünün piksel değerlerini kullanarak öznelik çıkarımı ve sınıflandırma yapar. Bu konuyu daha detaylı ele aldığımızda, bir görüntünün özelliklerinin yalnızca piksel değerleriyle sınırlı olmadığı, aynı zamanda pikseller arasındaki ilişkilerin, yani görüntüdeki kenarlar, çizgiler, köşeler ve temelde desenler gibi özelliklerin de önemli olduğunu görebiliriz. YSA, sınıflandırma için veriyi iyi bir şekilde temsil eden özellikleri belirlemelidir. Ancak, görüntü verileri için bu özellikleri seçmek kolay değildir. Bu yüzden evrişimsel sinir ağlarında bulunan evrişim katmanı bu tür özellikleri kolaylıkla gerçekleştirir. Evrişimli sinir ağları, derin öğrenme yöntemlerinden biridir ve görsel veriler gibi girdilerden verinin özelliklerini belirlemek için kullanılır (LeCun vd. 2015).



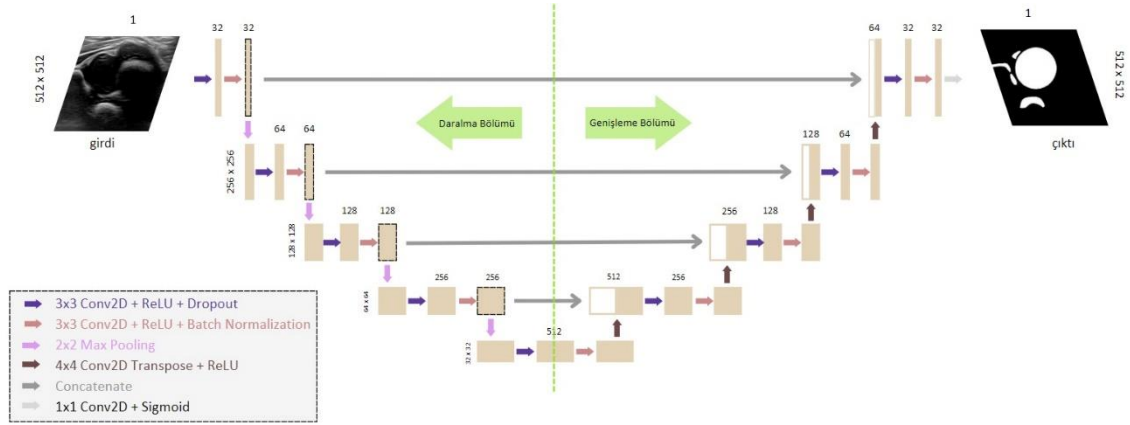
Şekil 3.14 CNN temel gösterim

Evrişimli sinir ağı katmanlarının özellikleri:

- Evrişim katmanı: Görüntüden özellikleri çıkarmakla görevlidir. Görüntüdeki belirli özellikleri bulmak ve tanımlamak için görüntüye bir filtre veya çekirdek uygulanarak giriş görüntüsü üzerinde bir konvolüsyon işlemi yapılır (Huang vd. 2017).
- Ortaklama katmanı: Evrişim katman tarafından üretilen öznetelik haritalarının uzamsal boyutlarını azaltma görevini üstlenir. Bu katman, öznetelik haritalarının boyutunu küçültmek ve hesaplama karmaşıklığını azaltmak amacıyla alt örnekleme işlemi gerçekleştirir (Huang vd. 2017).
- Tam bağlı katman: Bir önceki katmanın her bir nöronunun sonraki katmanın her bir nöronuna bağlanmasıyla olur. Evrişim ve ortaklama katmanları tarafından öğrenilen özellikleri birleştirerek nihai bir tahmin veya karar vermekten sorumludur (Huang vd. 2017).

Görüntü bölütlemesi, bir görüntüyü daha küçük parçalara bölerek görüntüyü basitleştiren ve her bir parçanın daha kolay işlenmesine veya incelenmesine olanak tanıyan bir işlemdir. Bölütlemenin temel amacı, görüntüdeki nesne veya diğer önemli bileşenleri piksel seviyesinde tanımlamaktır. Görüntü bölütleme, bilgisayarla görme alanının temel bir yapısıdır. Medikal görüntüleme, sürücüsüz araçlar ve yüz tanıma gibi pek çok alanda kullanılmaktadır (Minaee vd. 2021).

U-Net, biyomedikal görüntü bölütlemesinde geniş bir biçimde kullanılan bir mimari olarak bilinir. Sınırlı sayıda eğitim örneği üzerinde bile etkili tahminler yapabilme yeteneği sayesinde veri arttırmadan yüksek başarımlara ulaşabilmektedir (Ronneberger vd. 2015). Temelde 3 kısma ayrabileceğimiz U-Net mimarisi “Daralma”, “Dar Geçit” ve “Genişleme” şeklindedir. Simetrik bir ağ mimarisine sahiptir. Görünümünden dolayı “U” şeklindedir.



Şekil 3.15 Kullanılan U-Net ağ mimarisi

Evrişimli sinir ağında kullanılan yaygın bir katman olan ortaklama katmanı ile boyut azaltma işlemi, modelin ikinci yarısında boyut artırma tekniği ile tersine çevrilir, bu katmanlar, çıktı çözünürlüğünü artırmayı hedeflemektedir. Modelde yer alan yüksek çözünürlüklü özelliklerle örneklenen çıktı, lokalizasyon için birleştirilir. Evrişim katmanı bu bilgiye dayanarak daha hassas bir çıktı vermeye çalışır. Ağ boyunca girdi çeşitli aşamalardan geçmektedir. Şekil 3.15’de görüldüğü üzere 512x512 piksel boyutunda görüntüler ile çalışılmıştır. Daralma bölümünde görüntümüze evrişim (conv2D), ReLU, seyreltme (dropout), yığın normalizasyonu (batch normalization) gibi aşamalar uygulanmış ve ortaklama katmanlarıyla dar geçit kısmına ilerlenmiştir. Genişleme kısmında ise yine evrişim, ReLU, seyreltme, yığın normalizasyonu aşamalarına ek olarak tersine çevirme işlemi (transpose) ve birleştirme (concatenate) işlemleri de uygulanmıştır (Helli ve Hamamcı 2022). U-Net modeli, üst örnekleme tekniğini kullanarak her katmandaki girdinin çözünürlüğünü artırır. Bu sayede daha hassas çıktı yerelleştirme için yüksek çözünürlüklü özellikler çıkarılır ve birleştirilir. Ancak, U-Net modeli her evrişimin yalnızca geçerli kısmını kullanır. Bu, modelin hesaplama maliyetini azaltır ve

eđitim süresini kısaltır. U-Net'in başarısının temel nedenlerinden biri, atlama bađlantıları kullanmasıdır. Atlama bađlantıları, kodlayıcıdan sıđ ve düşük seviyeli özellikleri toplayarak bunları kod çözücüde aynı çözünürlüğü paylaşan derin ve yüksek seviyeli özelliklere dağıtır. Bu sayede, U-Net, görüntüdeki önemli bilgileri daha dođru bir şekilde öğrenebilir ve daha iyi sonuçlar üretebilir.

3.4.5 Mask R-CNN

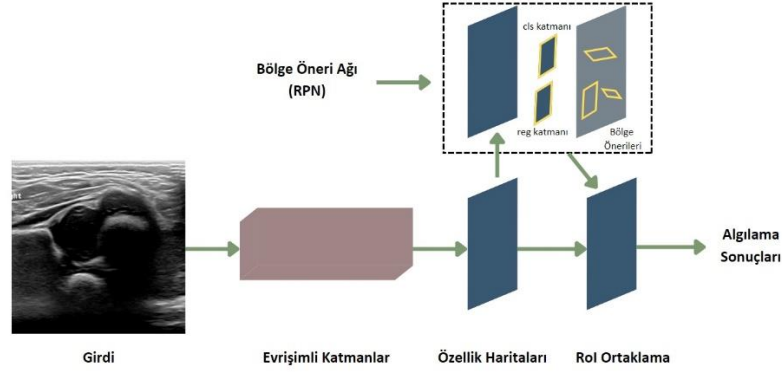
Basit CNN'lerde, görüntü sınıflandırması ve görüntüdeki tek bir nesneyle nesne tespiti için özelleştirilmiştir. Bir görüntüde birden fazla nesnenin olduđu daha yoğun bir durumda, basit bir CNN mimarisi optimal deđilse, farklı teknikler kullanmak ve karmaşık bir CNN mimarisi geliştirmek gereklidir. Bunun için 2017 yılında önerilen Mask R-CNN mimarisi önerilmiştir (He vd. 2017). Mask R-CNN mimarisine geçmeden önce Bölge Tabanlı Evrişimli Sinir Ađı (R-CNN) ve Hızlı R-CNN'ye değinmemiz gerekmektedir. R-CNN mimarisi, görüntü algılama görevlerinde kullanılması için tasarlanmış bir yaklaşım olup; nesne bölgelerini tanımlamak için sınırlayıcı kutuları kullanır. Evrişimsel ađları her İlgi Alanı (ROI) üzerinde bađımsız olarak deđerlendirerek bu bölgeleri önerilen sınıfa sınıflandırır ve sınıflandırmalar bađımsız olarak deđerlendirilir (Ren vd. 2015).

Hızlı R-CNN, R-CNN'nin daha hızlı ve dođru olması için geliştirilmiş hali olup, iki aşamada işlem yapar:

1. Bölge Öneri Ađı (RPN); görüntüdeki potansiyel nesnelerin yerini öneren bir Sinir Ađıdır.
2. Hızlı R-CNN (Fast R-CNN); önerilen bölgelerden özellikler çıkarır, ardından nesneyi sınıflandırma ve sınırlayıcı kutusunu regresyon eder. Bu adım, RoIPool adı verilen bir işlem kullanılarak gerçekleştirilir. RoIPool, algılamada her bir bölgeden küçük bir öznitelik haritasının çıkarılmasını sađlar.

Hızlı R-CNN'de evrişimli sinir ađına verilmesi için bölge önerilerinin tümüne ihtiyaç yoktur, evrişim işlemi görüntü başına yalnızca bir kez yapılır ve bundan bir öznitelik haritası oluşturulur (Ren vd. 2015). Hızlı (Fast) ve Daha Hızlı (Faster) R-CNN arasındaki


temel fark, Hızlı R-CNN'nin RoI oluşturmak için seçici aramayı kullanması, Hızlı R-CNN'nin ise bir RPN kullanmasıdır (Şekil 3.16).



Şekil 3.16 RPN mimarisi

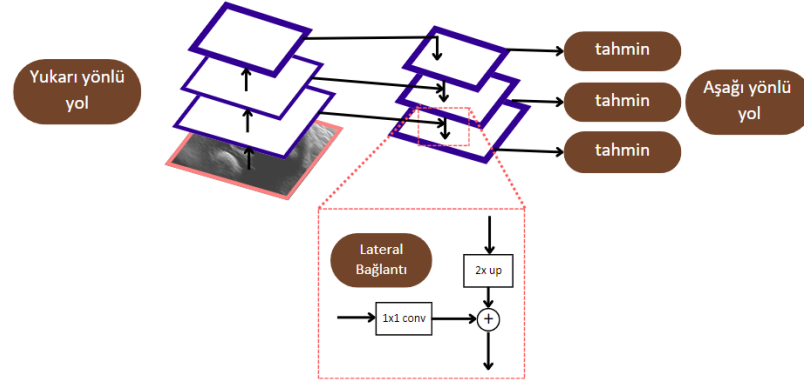
Mask R-CNN, Faster R-CNN modelinin geliştirilmiş bir sürümüdür ve nesne algılama ve bölütleme görevleri için kullanılır (He vd. 2017). Faster R-CNN'den farklı olarak getirdiği bazı önemli değişiklikler şunlardır:

1. ROIPool yerine ROIAlign kullanılması: ROIPool, Faster R-CNN modelinde kullanılan bir yöntemdir ve ilgi bölgesi (ROI) havuzlama işlemi sırasında giriş öznitelik haritası ile ROI arasında yanlış hizalanmalara yol açabilir. ROIAlign ise, bu yanlış hizalanmaları düzeltmek için tasarlanmış bir yöntemdir ve daha doğru sonuçlar elde edilmesini sağlar.
2. ROI havuzlama ızgarası: ROI havuzlama ızgarası, ROIAlign işleminin uygulandığı bir dizi hücredir. Bu ızgaranın boyutu, ROI'nin boyutuna göre belirlenir ve her hücre, ROI'nin belirli bir bölümüne karşılık gelir. ROI havuzlama ızgarası, nesnelerin farklı boyutlarına uyum sağlamak için esnek bir yapıya sahiptir.




Şekil 3.17 RoI hizalama (He vd. 2017)

3. Öznitelik Piramid Ağı (FPN): FPN, Mask R-CNN modelinde kullanılan bir öznitelik haritası mimarisidir. FPN, farklı ölçeklerdeki nesnelere daha iyi tespit etmek için, farklı ölçeklerdeki öznitelik haritalarını birleştirmeyi sağlar. Bu, nesnelerin farklı boyutlarına uyum sağlamak ve ölçek değişimlerinin ele alınmasını sağlamak için önemlidir.



Şekil 3.18 FPN mimarisi

4. Maske başlığı dalı: Maske başlığı dalı, Mask R-CNN modelinde nesnelerin piksel sınırlarını kesin bir şekilde bölümlendirmek ve tanımlamak için kullanılan bir ek dal olarak eklenir. Bu dal, ROI havuzlama ızgarasından elde edilen özellikleri işleyerek, her nesnenin piksel sınırlarını belirler.

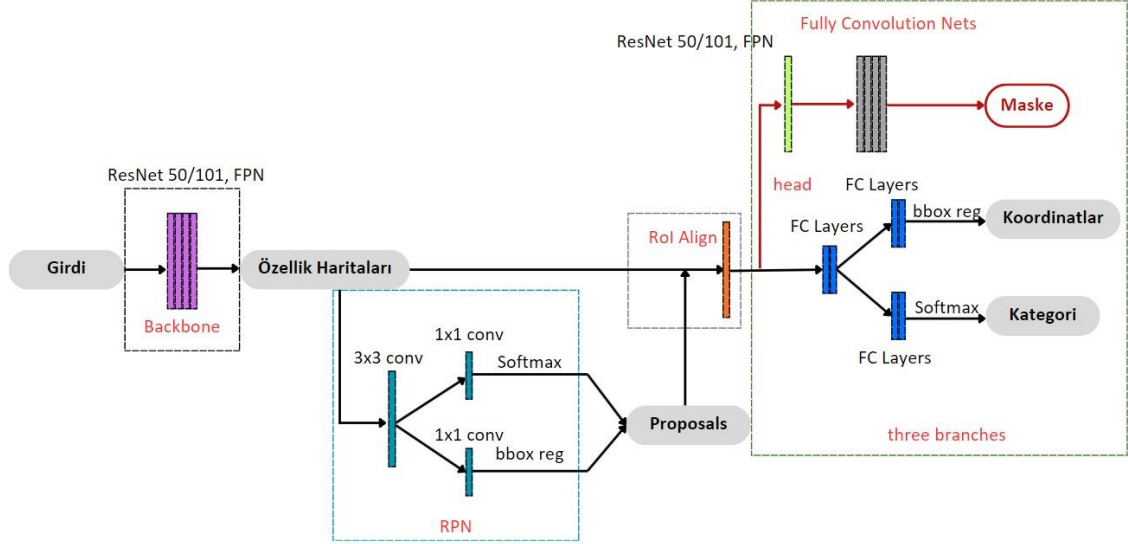


Şekil 3.19 Mask R-CNN maske dalı (He vd. 2017)

Mask R-CNN, nesne tespiti ve bölütleme görevlerinde daha iyi performans gösterdiği için, birçok farklı alanda yaygın olarak kullanılmaktadır.

Çalışmamızda Mask R-CNN mimarisinde öznitelik çıkartmak için omurga yapısı olarak ResNet tercih edilmiştir. ResNet, He (2016) ve arkadaşları tarafından ortaya atılmış ve

sağladığı kolaylıklar açısından yaygın olarak kullanılmakta olup, araştırmacılar tarafından tercih edilmiştir (He vd. 2016). Şekil 3.20’de Mask R-CNN mimarisi gösterilmiştir.



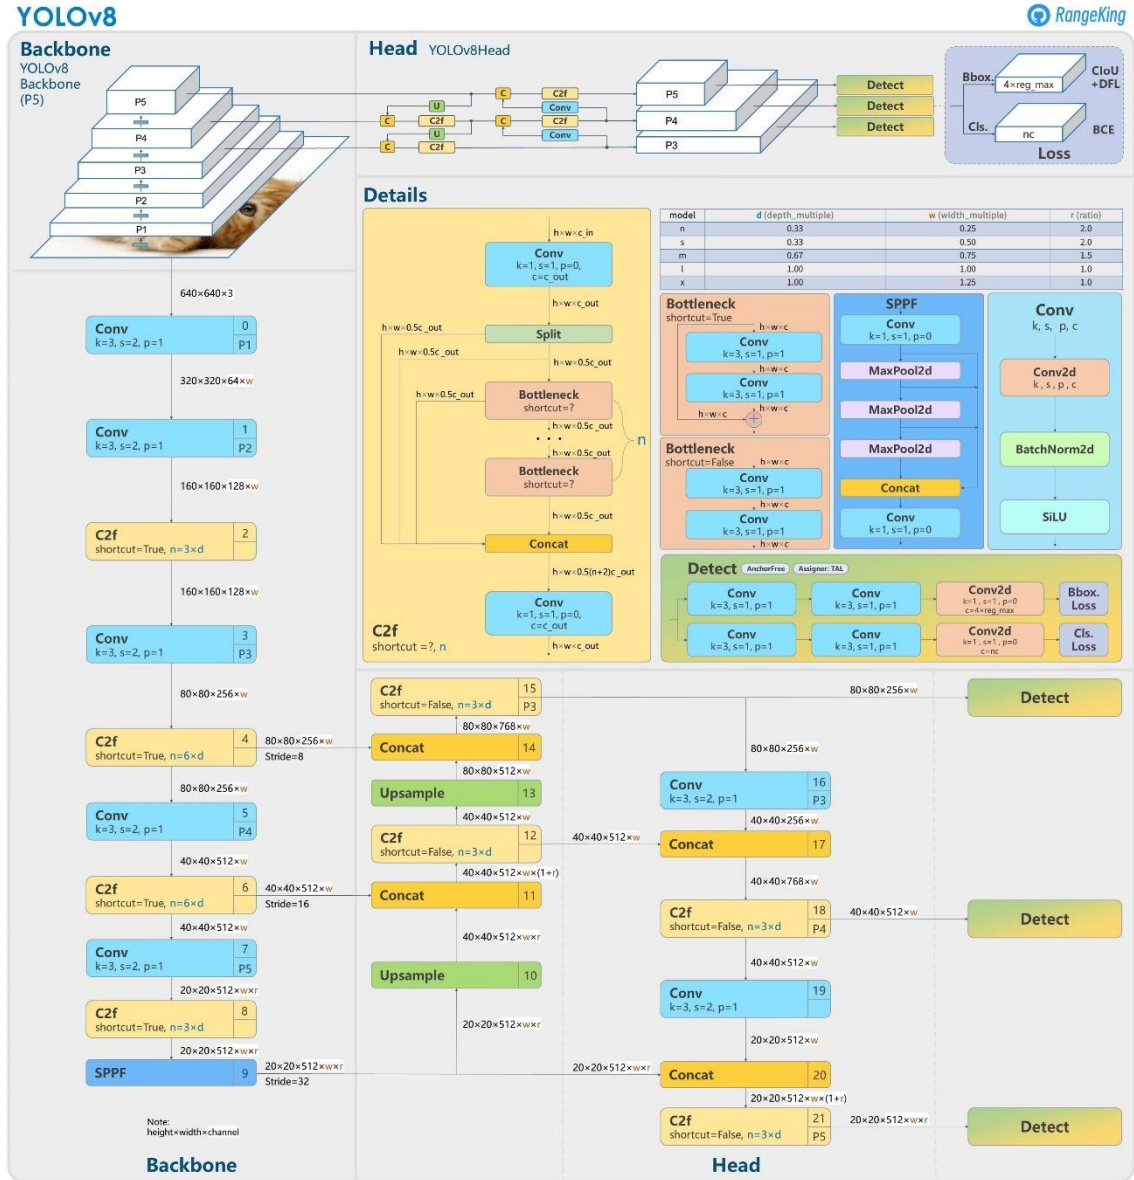
Şekil 3.20 Mask R-CNN mimarisi

3.4.6 YOLO v8

YOLO, nesne tespiti yapan bir evrimsel sinir ağı algoritmasıdır. Adı "You Only Look Once" ifadesinin kısaltmasıdır. Algoritma, resmin tamamını tek seferde nöral bir ağdan geçirerek nesne tespiti yapar. Bu durum, görüntüyü birçok küçük parçaya bölüp her parçayı ayrı ayrı işleme zorunluluğunu ortadan kaldırır. Bu sayede diğer algoritmalarından daha hızlı çalışır. YOLO algoritması, görüntüler üzerinde tespit ettiği nesnelerin çevresini sınırlayıcı kutular (bounding box) ile çevreler. Algoritma bunu, görüntüyü bir ızgaraya bölerek ve her ızgara hücresinin bir nesne içerip içermediğini belirleyerek yapar. Eğer bir hücre bir nesne içerdiğini düşünürse, o nesnenin sınıfını, merkez noktasını ve boyutlarını tahmin eder. Izgara yapısı bu tahminler ile o nesnenin çevresine sınırlayıcı kutuyu çizer (Redmon vd. 2016).

YOLO algoritması, birden fazla hücrenin aynı nesneyi tespit etmesini önlemek için Non-max Suppression algoritmasını kullanır. Bu algoritma, en yüksek güven değerine sahip


Şekil 3.23'de YOLOv8'in mimarisi gösterilmeye çalışılmıştır.



Şekil 3.23 YOLOv8 mimarisi (RangeKing/Github 2023)

4. ARAŞTIRMA BULGULARI

Materyal ve yöntem kısmında anlatıldığı üzere iki farklı veri kümesi hazırlanmıştır. Bu veri setleri üç farklı ağ mimarisinde kullanılmak üzere özelleştirilmiştir. U-Net mimarisinde kullanılmak için “Veri Kümesi 2” tercih edilmiştir. “Veri Kümesi 1” ise Mask R-CNN ve YOLOv8 mimarilerinde kullanılmak üzere tercih edilmiştir. Eğitim süreçleri iki farklı eğitim ortamında gerçekleştirilmiş ve değerlendirme metriklerinde bahsedilen sonuçlara ulaşılmıştır. Tüm bu işlemler sonucunda GKD ilgilenilen bölgelerin bölütlemesi gerçekleştirilmiştir. Şekil 4.1’de ilgilenilen bölgeler gösterilmiştir.



Şekil 4.1 İlgilenilen bölge, rastgele örnek görüntü ve maske gösterimi

4.1 Model Eğitim Süreçleri

Python, makine öğrenimi ve derin öğrenme alanlarında yaygın olarak kullanılan bir programlama dilidir. Açık kaynak geliştirilmiş kapsamlı kütüphaneleriyle önceden tanımlanmış birçok görevi kolayca gerçekleştirmenizi sağlar. Veri ön işleme, derin öğrenme sürecinin önemli bir parçasıdır. Çalışmamızda ön işleme, eğitim, değerlendirme


ve işlem sonrası adımlar Python dilinde yapılmış ve sonuç bulguları çalışmaya eklenmiştir.

4.1.1 U-Net eğitim süreci

U-Net eğitim sürecinde; veri kümesi belirleme sürecinin tamamı materyal ve yöntem kısmında bahsedilmiştir. U-Net eğitimi için “Veri Kümesi 2” kümesi seçilmiştir. Eğitim; Intel i5 13400F işlemci, Nvidia 3070 ekran kartı, 32GB ram olan bir bilgisayarda yapılmıştır. Nvidia CUDA aracı, grafik işlem birimi (GPU) kullanarak hızlandırılmış, yüksek performanslı uygulamaların oluşturulmasına yönelik bir geliştirme ortamıdır. CUDA aracının olması eğitim süresini kısalttığı için özellikle tercih edilmiştir. Eğitim sürecine gelindiğinde ise; programlama dili olarak Python, eğitim kütüphanesi olarak Tensorflow gibi açık kaynak kütüphaneler tercih edilmiştir.

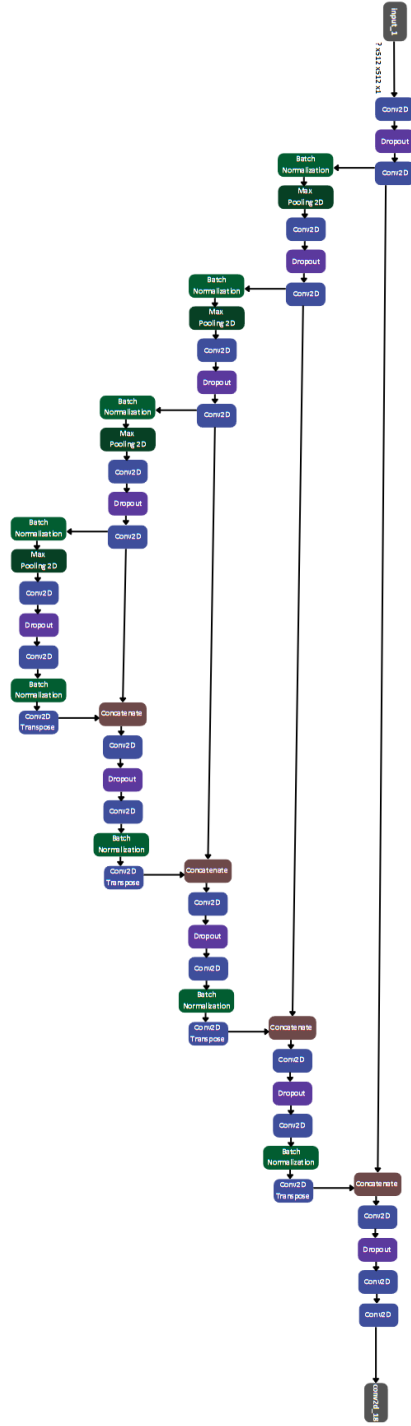
- Numpy
- Matplotlib
- Scikit-learn
- OpenCV
- Keras
- Tensorflow
- Albumentations
- Scipy

Bu kütüphaneleri kullanarak veri ön işleme işlemleri gerçekleştirildi. Veri ön işleme aşamasında 640x640 piksel boyutundaki görüntüler ve maskeler yeniden boyutlandırılarak 512x512 piksel boyutuna getirilmiştir. Bunu yapmamızın sebebi U-Net mimarimizin görüntü girdi boyutunun ve ağ yapısının 512x512 piksel boyutuna göre ayarlanmış olmamızdan dolayıdır. Yeniden boyutlandırma işleminden sonra görüntülerimiz eğitim ve test kümeleri olacak şekilde belirlenmiştir. Belirlenen eğitim kümesi “Albumentations” kütüphanesini kullanarak rastgele kırpma, parlaklık ve zıtlık değiştirme, döndürme, bulanıklaştırma ve gauss gürültüsü ekleme gibi bir dizi işlem görüntüler üzerine uygulanmıştır. Şekil 4.2’de görüntü aşamaları gösterilmiştir.



Şekil 4.2 a) Veri kümesi 2 kümesinde olan rastgele bir görüntü. b) (a) görüntüsüne ait olan maske. c) Ön işlemede yapılan görüntü işlemlerine ait rastgele bir görüntü. d) (c) görüntüsüne ait olan görüntü işlenmiş maske

Görüntü işlemlerini gerçekleştirdikten sonra U-Net modelimiz oluşturuldu. U-Net modeli toplamda; 19 adet evrişim katmanı, 4 adet transpoze edilmiş evrişim katmanı, 9 adet seyreltme (dropout) katmanı, 8 adet yığın normalizasyon katmanı, 4 adet maksimum ortaklama katmanı ve 4 adet birleştirme katmanı bulunmaktadır. Modelin son katmanı hariç tüm katmanlarında aktivasyon fonksiyonu olarak ReLU aktivasyon fonksiyonu seçilmiştir. Son katmanın aktivasyon fonksiyonu ise Sigmoid aktivasyon fonksiyonu olarak belirlenmiştir. Şekil 4.3'te tüm katmanlar gösterilmiştir.



Şekil 4.3 Kullanılan U-Net mimarisi tüm ağ yapısı

U-Net ağında oluşan parametre değerleri:


- Toplam parametre: 13.423.361 (51,21 MB)
- Eğitilebilir parametreler: 13.420.481 (51,20 MB)
- Eğitilemeyen parametreler: 2880 (11,25 KB), şeklinde oluşmuştur.

Çizelge 4.1’de görüldüğü üzere modelin hiper parametreleri çizelgede belirlendiği gibi ayarlanmış ve eğitim bu parametrelerle gerçekleşmiştir.

Çizelge 4.1 U-NET hiper parametreler

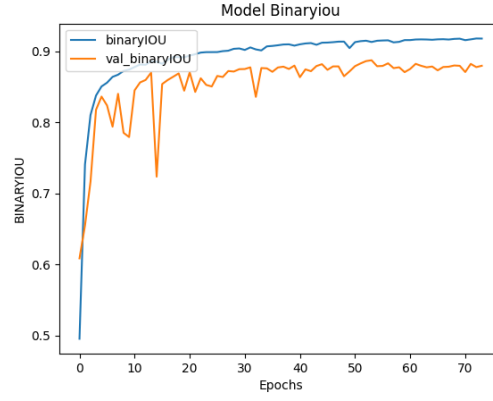
Eğitim Tur Sayısı (Epoch)	100 – Erken Durdurma (Early Stop = 74)
İterasyon	-
Yığın (Batch) Boyutu	2
Kayıp Fonksiyonu (Loss Function)	Binary Cross-Entropy (BCE)
Optimizasyon Fonksiyonu	Adam
Öğrenme Hızı (Learning Rate)	1e-3
Momentum	0,9

Eğitim parametresi olarak 100 olarak ayarladığımız eğitim tur sayısı (epoch) değerini erken durdurma (Early Stopping) eklediğimiz için modelimiz eğitim sırasında 74. epoch’a geldiğinde eğitimi tamamlamıştır. Model kontrol noktası metriğiyle en iyi ağırlık değerleri kaydedilmiştir. Bu model kaydı daha sonrasında model tahmin aşamasında kullanılmıştır. Eğitim sonuçlarında doğruluk değeri: 0,98305, doğrulama doğruluğu (validation accuracy): 0,96964, kayıp değeri: 0,01675 ve doğrulama kayıp değeri: 0,06421 olarak tespit edilmiştir. Şekil 4.4’te sonuçlar görselleştirilmiştir.




Şekil 4.4 (a) U-Net model doğruluk sonucu. (b) U-Net model kayıp sonuçları

Eđitimde bölütlemeyi arka plan ve maske olarak yaptığımız için IoU deęerini: 0,91790 ve doęrulama IoU deęerini: 0,87013 olarak tespit edilmiřtir. řekil 4.5'te görselleřtirilmiřtir.



řekil 4.5 U-Net model IoU sonucu

Keras'ın `model.predict()` fonksiyonunu alıřtırarak modelimiz için tahmin deęerleri oluřturuldu. řekil 4.4'te tahminler arasından bir örnek gösterilmiřtir.



řekil 4.6 a) Tahmin edilmesi için verilen görüntü. b) (a) görüntüsünün tahmini

U-Net modeli eđitim sonuçları:

- accuracy: 0,98305
- precision: 0,92798
- recall: 0,93314

- average precision puanı: 0,87408
- Confusion Matrix: [[7749939 78527]
[72499 1011931]]
- Jaccard Score: 0,87013
- F1 Score: 0,93055

Eğitim sonuçları değerlendirme metrikleriyle birlikte değerlendirme metrikler aşamasında anlatılmıştır.

4.1.2 Mask R-CNN eğitim süreci

Mask R-CNN eğitim sürecinde; veri kümesi belirleme sürecinin tamamı materyal ve yöntem kısmında bahsedilmiş ve bu eğitim için “Veri Kümesi 1” kümesi seçilmiştir. Modelin etiketleri COCO formatında olduğu için gerekli ayarlar (dosyaların istenilen klasörler altında düzenlenmesi) yapılmıştır. Eğitim; Google platformunun sağlamış olduğu Colab üzerinde yapılmıştır. Google Colab, Google'ın sunduğu ücretsiz bir bulut tabanlı kodlama ortamıdır. Colab ile kodu tarayıcı üzerinden çalıştırabilir ve kaydedilebilir. Colab ile Google Cloud altyapısını kullanarak GPU hesaplama kaynaklarına erişim sağlandı. Bu sayede çok daha kısa sürede ve daha verimli bir şekilde çalışmalar tamamlanabildi. Şekil 4.7’de eğitim için kullanılan GPU’nun özellikleri belirtilmiştir.


```

+-----+-----+-----+-----+-----+-----+
| NVIDIA-SMI 535.104.05                Driver Version: 535.104.05   CUDA Version: 12.2   |
+-----+-----+-----+-----+-----+-----+
| GPU  Name          Persistence-M | Bus-Id        Disp.A    | Volatile Uncorr. ECC |
| Fan  Temp   Perf          Pwr:Usage/Cap |      Memory-Usage | GPU-Util  Compute M. |
|                                           | MIG M.         |                       |
+-----+-----+-----+-----+-----+-----+
|  0   Tesla T4             Off          | 00000000:00:04:0  Off    |          0           |
| N/A   37C    P8             9W / 70W         |  0MiB / 15360MiB |          0%      Default |
|                                           | N/A            |                       |
+-----+-----+-----+-----+-----+-----+
| Processes:                               |
| GPU  GI    CI          PID  Type   Process name          | GPU Memory |
|   ID   ID                                 |            | Usage          |
+-----+-----+-----+-----+-----+-----+
| No running processes found              |
+-----+-----+-----+-----+-----+

```

Şekil 4.7 Colab'da kullanılan GPU özellikleri

Mask R-CNN modelinde Facebook yapay zekâ birimi tarafından geliştirilen Detectron2 kütüphanesi kullanılmıştır. Eğitim aşaması için Veri Kümesi 1’de belirtildiği gibi 632 görüntü bulunmaktadır. Bu eğitim “transfer learning” şeklinde gerçekleştirilmiş, temel olarak R-CNN FPN seçilmiş ve iskelet yapısı olarak ResNet-50 kullanılmıştır. Şekil 4.8’de gösterildiği üzere veri kümesinden örnek bir görüntü sunulmuştur.



Şekil 4.8 Mask R-CNN modelinde kullanılan veri kümesinden bir örnek

Çizelge 4.2’de görüldüğü üzere Mask R-CNN modelinin hiper parametreleri çizelgede belirlendiği gibi ayarlanmış ve eğitim bu parametrelerle gerçekleştirilmiştir.

Çizelge 4.2 Mask RCNN hiper parametreler

Eğitim Tur Sayısı (Epoch)	-
İterasyon	11000
Yığın (Batch) Boyutu	4
Kayıp Fonksiyonu (Loss Function)	Smooth L1
Optimizasyon Fonksiyonu	SGD with Momentum
Öğrenme Hızı (Learning Rate)	0,00025
Momentum	0,9
Sınıf Sayısı	6 (5 sınıf + arkaplan)


Mask R-CNN modelinin sonuç deęerleri;

- total_loss: Bu deęer, yineleme sırasında hesaplanan bireysel kayıpların aęırlıklı toplamıdır. (Wu vd. 2019)
- loss_cls: ROI kısmında sınıflandırma kaybı. Kutu sınıflandırması kaybını, yani modelin tahmin edilen bir kutuyu doęru sınıfla etiketlemede ne kadar iyi olduęunu ölçer. Kayıp fonksiyonu olarak Softmax Cross Entropy kullanır (Wu vd. 2019)
- lost_box_reg: ROI kısmında yerleştirme kaybı. Kutu yerleştirme kaybını ölçer (tahmin edilen konum ve gerçek konum). Kayıp fonksiyonu olarak Smooth L1 kaybını kullanır (Wu vd. 2019)
- lost_rpn_cls: RPN kısmının sınıflandırma kaybı. "Nesnelik" kaybını, yani RPN'nin bağlantı kutularını ön plan veya arka plan olarak etiketlemede ne kadar iyi olduęunu ölçer. Fonksiyon çıktısı olarak sınıflandırma kaybını döndürür (Wu vd. 2019).
- lost_rpn_loc: RPN kısmının yerleştirme kaybı. RPN'de tahmin edilen bölgelerin lokalizasyonuna yönelik kaybı ölçer (Wu vd. 2019).
- lost_mask: Maske kısmının kaybı. Tahmin edilen ikili maskelerin ne kadar "doęru" olduęunu ölçer (Wu vd. 2019).

Mask R-CNN model eğitim sonucunda:

- fast_rcnn/cls_accuracy: 0,97832
- fast_rcnn/false_negative: 0,04934
- fast_rcnn/fg_cls_accuracy: 0,95065
- loss_box_reg: 0,11488
- loss_cls: 0,04671
- loss_mask: 0,11495
- loss_rpn_cls: 0,00016
- loss_rpn_loc: 0,01101
- mask_rcnn/accuracy: 0,94949
- mask_rcnn/false_negative: 0,04513
- mask_rcnn/false_positive: 0,05360
- total_loss: 0,29208

Şekil 4.9’da, Detectron2 kütüphanesinin DefaultPredictor() sınıfını kullanarak yaptığımız tahmin sonucu görülmektedir.



Şekil 4.9 Mask R-CNN model sonucuna göre tahmin edilen örnek görüntü

Eğitim sonuçları değerlendirme metrikleriyle birlikte değerlendirme metrikler aşamasında anlatılmıştır.

4.1.3 YOLOv8 eğitim süreci


YOLOv8 eğitim sürecinde; yine veri kümesi belirlemesi materyal ve yöntem kısmında yapılmıştır. Bu eğitim için yine “Veri Kümesi 1” kümesi seçilmiştir. Diğerlerinden farklı olarak etiketlerimiz COCO formatından YOLO’ya uygun format dönüşümü yapılmış ve kodda veri kümesinin eğitim, doğrulama ve test ayrışması sağlanmıştır. Eğitim kullanım kolaylığı ve kod akışı verimli olduğu için yine Google platformunun sağlamış olduğu Colab üzerinde yapılmıştır.

YOLOv8s-seg özeti: 261 katman, 11.792.031 parametre, 11.792.015 gradyan, 42,7 GFLOPs şeklinde oluşmuştur. Çizelge 4.3’te görüldüğü üzere YOLOv8 modelimizin hiper parametreleri çizelgede belirlendiği gibi ayarlanmış ve eğitim bu parametrelerle gerçekleştirilmiştir.

Çizelge 4.3 YOLOv8 hiper parametreler

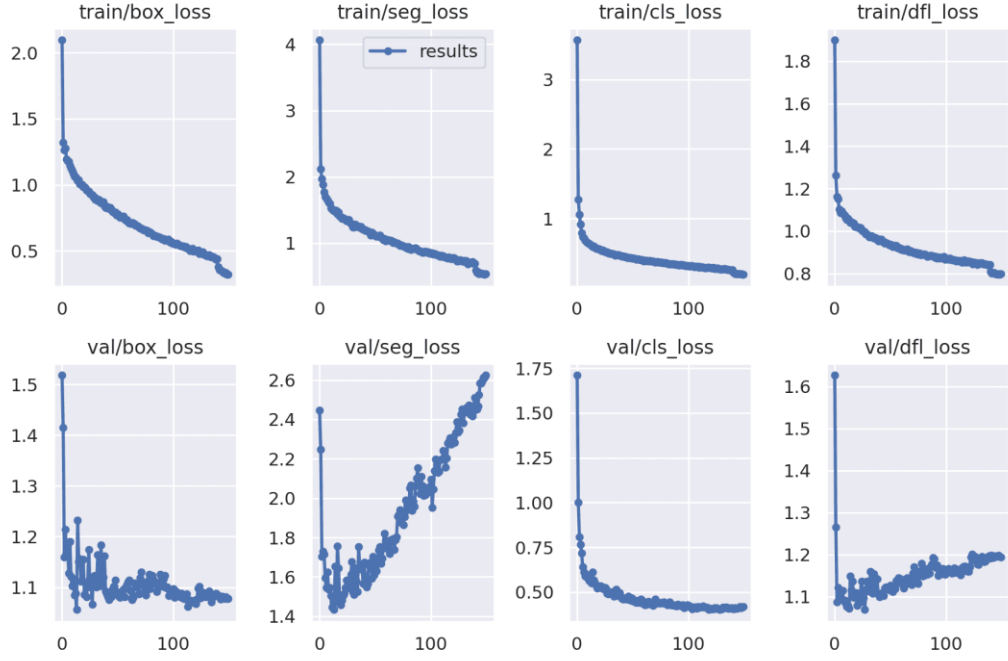
Eğitim Tur Sayısı (Epoch)	150
İterasyon	-
Yığın (Batch) Boyutu	16
Kayıp Fonksiyonu (Loss Function)	BCE- DFL
Optimizasyon Fonksiyonu	SGD
Öğrenme Hızı (Learning Rate)	0,01
Momentum	0,937

Eğitim sonucunda etiketlerimize göre oluşmuş karışıklık matrisinde de görüleceği gibi modelin arka plan görüntüsü ile labrum'u birbirinden ayırmakta zorluk çekmektedir. Bunun temel sebebi labrumun arka plana çok benzer görüntüsü olmasından kaynaklanmaktadır (Şekil 4.10).




Şekil 4.10 YOLOv8 eğitim sonucuna göre oluşmuş karışıklık matrisi

Şekil 4.11 ve şekil 4.12’de kayıp değerleri ve metrik sonuçları gösterilmiştir.




Şekil 4.11 YOLOv8 eğitim model kayıp değerleri




Şekil 4.12 YOLOv8 eğitim metrik sonuçları. B: box, M: mask

Şekil 4.13'te eğitim sonucunda oluşan box metriğine ait grafikler gösterilmiştir.



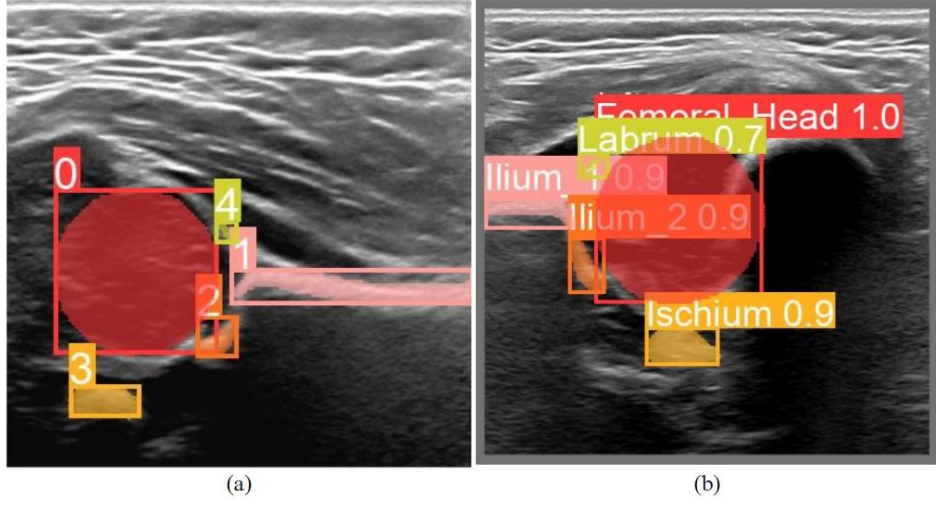
Şekil 4.13 YOLOv8 box sonuç grafikleri

Şekil 4.14'te eğitim sonucunda oluşan maske metriğine ait grafikler gösterilmiştir.



Şekil 4.14 YOLOv8 maske sonuç grafikleri

Şekil 4.15'te YOLOv8 modeline ait tahmin örneği gösterilmiştir.



Şekil 4.15 a) Model eğitim sırasında yapılan bir tahmin örneği. b) Tahmin aşamasında elde edilmiş örnek bir görüntü

Eğitim sonuçları değerlendirme metrikleriyle birlikte değerlendirme metrikler aşamasında anlatılmıştır.

4.2 Değerlendirme Metrikleri

Görüntü bölütleme, bir görüntüyü anlamlı bölgelere ayıran bir işlemdir. Bölütleme algoritmalarının ne kadar iyi çalıştığını değerlendirmek için çeşitli metrikler vardır. Bu metrikler, bölütleme sonuçlarının doğruluğunu, tutarlılığını ve kalitesini ölçer. Ayrıca, bölütleme algoritmalarının hangi uygulamalara uygun olduğunu, neleri iyi yaptığını ve neleri geliştirmesi gerektiğini gösterir. Değerlendirme metrikleri sayesinde, farklı bölütleme algoritmaları objektif bir şekilde karşılaştırılabilir ve en iyi algoritma seçilebilir. Ayrıca, algoritmaların performansındaki değişimler zaman içerisinde izlenebilir ve iyileştirme stratejilerinin sonuçlarını değerlendirmeyi mümkün kılar. Değerlendirme metrikleri, geliştirilen bu yöntemlerin güvenilir ve doğru bir şekilde çalışmasını sağlamak için olmazsa olmazdır.

4.2.1 Karışıklık matrisi (Confusion matrix)

Karmaşıklık matrisi (Confusion matrix), sınıflandırma modellerinde performans durumlarını değerlendirmek ve tahminlerdeki sonuçların gerçek değerleriyle karşılaştırıldığı metriktir.

Çizelge 4.4 Karışıklık matrisi

		Tahmin edilen durum	
		Negatif (0)	Pozitif (1)
Gerçek durum	Negatif (0)	TN	FP
	Pozitif (1)	FN	TP

TP: (True positive) Doğru Pozitif
FP: (False positive) Yanlış Pozitif
TN: (True negative) Doğru Negatif
FN: (False negative) Yanlış Negatif

4.2.2 Doğruluk (Accuracy)

Doğruluk, gözlemlerin olduğu belirli bir ölçüm kümesinde, çıkan sonuçların gerçek değerlerine ne kadar yakın olduğunu ifade eder. Doğruluk, modelin başarısını ölçmek için kullanılan bir metriktir ancak, tek başına kullanıldığı zaman yeterli gelmediği tespit edilmiştir. Doğruluk değerini hesaplamak için modelde çıkan sonuçlardan doğru tahmin edilen alanların, veri kümesinde bulunan toplam değerlere oranı ile hesaplanmaktadır.

$$\text{Doğruluk (Accuracy)} = \frac{TP+TN}{TP+TN+FP+FN} \quad (4.1)$$

Çizelge 4.5 Doğruluk model karşılaştırma

	Doğruluk (Accuracy)
U-NET	0,98305
Mask RCNN	0,94949

4.2.3 Kesinlik (Precision)

Kesinlik, pozitif olarak tahmin edilen değerlerin aslında gerçekte kaç tanesinin pozitif olduğunun göstergesidir. Ayrıca kesinlik de çıkan ölçüm sonuçlarının birbirine ne kadar yakın olduğunun cevabını da alabiliriz. Model seçimlerinde yüksek kesinlik değerleri önemli bir kriterdir.

$$Kesinlik (Precision) = \frac{TP}{TP+FP} \quad (4.2)$$

Çizelge 4.6 Kesinlik model karşılaştırma

	Kesinlik (Precision)
U-NET	0,927987
YOLO v8	0,976

4.2.4 Duyarlılık (Recall)

Duyarlılık, pozitif tahmin edilmesi beklenen işlemlerin ne kadarında pozitif tahmin sonuçlarının elde edildiğini gösteren bir metriktir.

$$Duyarlılık (Recall) = \frac{TP}{TP+FN} \quad (4.3)$$

Çizelge 4.7 Duyarlılık model karşılaştırma

	Duyarlılık (Recall)
U-NET	0,933145
YOLO v8	0,968

4.2.5 Kesiştirilmiş bölgeler (IoU) (Jaccard index)

Kesiştirilmiş Bölgeler (IoU), görüntü algılama modellerinde nesnelerin kesişmiş bölgelerinin doğruluğunu ve hatalarını hesaplamak için kullanılan ölçüm yöntemidir. Kesişim bölgesinin büyüklüğü IoU değerinin de büyük olmasına neden olur.

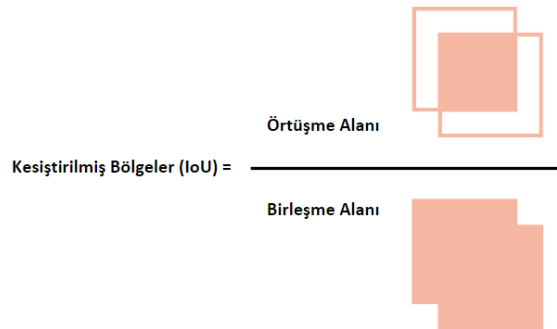
$$IoU (\text{Kesiştirilmiş Bölgeler}) = \frac{TP}{TP+FP+FN} \quad (4.4)$$

Çizelge 4.8 IoU model karşılaştırma

	IoU
U-NET	0,870136

Şekil 4.5'te IoU'nun temsili görseli bulunmaktadır.

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|}$$



Şekil 4.16 IoU görselleştirilmiş hali

4.2.6 F1 puan (F1 score) (Dice katsayısı)


Kesinlik ve duyarlılık değerleri birleştirilip hesaplanmasıyla F1 puan elde edilir. Düşük duyarlılık değeri olan ve yüksek kesinlik değeri olan veya tam tersi durumlardaki iki modeli karşılaştırmak için F1 puanı kullanılır.

$$F1 \text{ Puan (F1 Score)} = 2 \times \frac{\text{Kesinlik (Precision)} \times \text{Duyarlılık (Recall)}}{\text{Kesinlik (Precision)} + \text{Duyarlılık (Recall)}} \quad (4.5)$$

Çizelge 4.9 F1 Skor (Dice katsayısı) model karşılaştırması

	F1 Puan
U-NET	0,930558
YOLO v8	0,971983

Şekil 4.6’da Dice katsayısının temsili görseli bulunmaktadır.



Şekil 4.17 Dice katsayısı görselleştirilmiş hali

4.2.7 Genel ortalama kesinliği (mAP)

mAP, toplu şekilde bir modelin doğruluğunun ölçümünü sağlar. Nesne tespiti için tercih edilen değerlendirme ölçütüdür. YOLOv8 ve Mask R-CNN gibi ağ mimarilerinin değerlendirilmesinde mAP kullanılır. Bir modelin performansı hakkında değerlendirme yapmak için kesinlik-duyarlılık dengesine dikkat eder.

$$AP = \sum_{k=0}^{k=n-1} [recalls(k) - recalls(k + 1)] \cdot precisions(k) \quad (4.6)$$

$$mAP = \frac{1}{n} \sum_{k=1}^{k=n} AP_k \quad (4.7)$$

Çizelge 4.10 mAP model karşılaştırması

	mAP
U-NET	0,874081
Mask RCNN	0,97042
YOLO v8	0,98

U-Net'e ait sonuç değerlerinin olduğu çizelge aşağıda verilmiştir (Çizelge 4.11).

Çizelge 4.11 U-Net sonuç değerleri

Sınıf	Sonuçlar					
	Doğruluk (A)	Kesinlik (P)	Duyarlılık (R)	F1 Puan (Dice Katsayısı)	Jaccard (IoU)	mAP
İkili Sınıflandırma	0,98305	0,927987	0,933145	0,930558	0,870136	0,874081

Mask R-CNN'e ait sonuç değerlerinin olduğu çizelge aşağıda verilmiştir (Çizelge 4.12).

Çizelge 4.12 Mask R-CNN sonuç değerleri

Sınıf	Görüntüler	Örnekler	Box		Maske	
			AP	AP50	AP	AP50
Tümü	45	225	63,586	97,786	59,483	97,042
Femur Başı	45	45	83,240	-	83,240	-
İlium_1	45	45	81,311	-	70,685	-
İlium_2	45	45	58,411	-	55,056	-
İskium	45	45	60,866	-	55,056	-
Labrum	45	45	34,101	-	32,197	-


YOLOv8'e ait sonuç değerlerinin olduğu çizelge aşağıda verilmiştir (Çizelge 4.13).

Çizelge 4.13 YOLO v8 sonuç değerleri

Sınıf	Görüntü	Örnek	Box				Maske			
			P	R	mAP50	mAP50-95	P	R	mAP50	mAP50-95
Tümü	91	454	0,973	0,965	0,972	0,703	0,976	0,968	0,98	0,652
Femur Başı	91	91	0,995	1	0,995	0,894	0,995	1	0,995	0,881
İlium_1	91	91	0,996	1	0,995	0,831	0,996	1	0,995	0,724
İlium_2	91	91	1	0,999	0,995	0,67	1	0,999	0,995	0,601
İskium	91	90	1	0,972	0,995	0,706	1	0,972	0,995	0,664
Labrum	91	91	0,876	0,854	0,88	0,416	0,89	0,868	0,92	0,389

4.3 Eğitim Sonrası İşlemler ve Açı Ölçümü

U-Net modelimizin eğitim ve tahmin işlemlerini gerçekleştirdikten sonra modele ait tahmin görüntülerini kaydedildi. Tahmin görüntülerine ait asıl görüntüler gri seviye görüntülere dönüştürüldü. Asıl US görüntüleri 640x640 piksel boyutuna sahip oldukları için tahmin görüntülerini OpenCV kütüphanesinin yeniden boyutlandırma fonksiyonu olan cv2.resize() fonksiyonu ile enterpolasyon (interpolation) değerini Lanczos filtresi kullanılarak, OpenCV kütüphanesinin cv2.INTER_LANCZOS4 yöntemine göre belirlenip, dönüştürüp, kaydedildi. Kaydedilen görüntüler üzerine tahmin görüntüsü bir numpy dizisine dönüştürülüp cv2.threshold fonksiyonu ile görüntülerde eşik değeri belirlendi. Belirlenen bu eşik değeri ile cv2.findContours() yöntemi sayesinde bölütleme bölgelerinin sınırları belirlendi. Belirlenen sınır değerleri orijinal US görüntümüz üzerine cv2.drawContours() yöntemiyle çizildi. Şekil 4.18'de olduğu gibi bir tahmin görüntüsünün sınırları belirlenmiş şekli gösterilmiştir.



Şekil 4.18 a) Örnek bir tahmin görüntüsü. b) (a) tahmin görüntüsünün sınırları bulunmuş hali

Kanonik korelasyon analizi (CCA), her biri en az iki değişken içeren iki değişken kümesi arasındaki ilişkiyi inceleyen bir analiz yöntemidir. Bu analizde, değişken kümelerinden biri nedensel veya bağımsız değişkenler olarak tanımlanırken, diğeri sonuç veya bağımlı değişkenler olarak tanımlanır. Açıklayıcı değişkenler, bağımlı değişkenleri açıklamaya yöneliktir (Hardle ve Simar 2007).

CCA yöntemi ile iki resim arasındaki ilişkiyi analiz ederek hem ilgilenilen bölgenin sayısı tahmin etmek hem de o bölgelerin piksel bazlı boyutlarının hesaplanması yapılmıştır. Bunu yapmak için OpenCV kütüphanesinden yararlanılmış ve aşağıdaki işlemler sırasıyla gerçekleştirilir (Helli ve Hamamcı 2022).


- Orijinal görüntü ve tahmin görüntüleri alınır bölüt bölge sayısının daha iyi tahmin edilmesi için görüntüler ön işleme adımlarından geçirilir. Bu adımlar şunlardır:
 - Açma (morphologyEx) işlemi: Bu işlem, görüntünün arka plan gürültüsünü azaltmaya yardımcı olur.
 - Keskinleştirme işlemi: Bu işlem, bölütleme kenarlarının daha belirgin hale getirilmesine yardımcı olur. Keskinleştirme çekirdeği denklem 4.8'de verilmiştir.
 - Aşındırma işlemi: Bu işlem, bölütleme boyutunu küçültmeye yardımcı olur.
- İşlenen görüntüler gri tonlamalı hale getirilir ve ardından görüntüler üzerinde eşikleme işlemi uygulanır. Bu işlem, bölütlerin bulunduğu alanları diğer alanlardan ayırmaya yardımcı olur.

Çizelge 4.14’te gösterildiği üzere GKD üzerine yapılmış bazı çalışmalar ortak bir tablo olarak gösterilmiştir.

Çizelge 4.14 Önerilmiş yöntemlerin karşılaştırılması (Chen vd. 2022)

Amaç	CAD Türü	Algoritma	Uygulanabilir Veriler	Referans	
Standart Düzlem Değerlendirmesi	Geleneksel CAD	Rastgele orman sınıflandırıcısı	3B Veri	(Quader vd. 2021)	
		Manuel yöntem	2B standart düzlem	(Hareendranathan vd. 2021)	
	Derin Öğrenme tabanlı CAD	CNN	3B Veri	(Paserin vd. 2017)	
		LSTM	3B Veri	(Paserin vd. 2018)	
		3D U-Net	3B Veri	(El-Hariri vd. 2021)	
Açı Ölçümü	Geleneksel CAD	Morfolojik ve geometrik özellikler	2B standart düzlem	(Quader vd. 2017)	
			3B Veri	(Quader vd. 2021)	
		Seviye seti	2B standart düzlem	(Sezer ve Sezer 2019)	
	Derin Öğrenme tabanlı CAD	FCN	2B standart düzlem	(Golan vd. 2016)	
		CNN	2B standart düzlem	(Hareendranathan vd. 2016)	
		2D U-Net	2B standart düzlem	(El-Hariri vd. 2019)	
		Çoklu Mask R-CNN	2B standart düzlem	(Hu vd. 2021)	
		Mask R-CNN + FCN	2B standart düzlem	(Lee vd. 2021)	
	Graf Tipi Sınıflandırması	Derin Öğrenme tabanlı CAD	CNN	2B standart düzlem	(Sezer ve Sezer 2020)
			DNN + Rastgele orman sınıflandırıcısı	2B standart düzlem	(Gong vd. 2021)

GKD için önerilen Graf yönteminde açı ölçümünü yapabilmek için ilgilenilen anahtar noktalar şekil 4.20’de gösterilmiştir (Graf 2006).



Şekil 4.20 a) Graf metodunda önerilen anahtar noktalar. b) Açılı ölçümü için olması gereken çizgiler

GKD, Graf yöntemine göre açılı ölçümü için yapılan çalışmalarda; 2B US görüntüsünde geleneksel yöntemler kullanarak morfolojik ve geometrik özellikler ve de işlemler üzerinden açılı ölçümü yapılmıştır (Quader vd. 2017). PSO ve SLS ile bölütleme yönteminde; PSO, görüntülerdeki anatomik yapılar için başlangıç konturlarını belirlemek için kullanan, daha sonra, kritik anatomik yapıların bölütlemesi için SLS yöntemi uygulandı. Bu anatomik yapıların bilgilerinden yararlanarak çizgiler çizildi ve alfa-beta açılarını tanımladı (Sezer ve Sezer 2019). Derin öğrenme ağlarına geçildiğinde ise açılı ölçümü için yöntem olarak FCN (Golan vd. 2016), CNN (Hareendranathan vd. 2016), U-Net (El-Hariri vd. 2019), Çoklu Mask R-CNN (Hu vd. 2021) ve Mask R-CNN + FCN (Lee vd. 2021) önerilmiş ve Graf (2006) önerisinden bulunan açılı ölçümleri sağlanmıştır.

Sunmuş olduğumuz çalışmamızda bölütleme, açılı ölçümü ve istatistiksel sonuçlar olmak üzere işlemlerimiz sırasıyla kademeli olarak gerçekleştirilmiştir. İlk olarak veri kümesinden derin öğrenme ile farklı modellerde bölütleme sonuçlarını elde edilmiştir. Bölütleme sonucu elde edilen eğitim ağırlık değerlerimiz test kümesine uygulanmıştır. Burada önemli nokta ise ister ikili sınıflandırma olarak eğittiğimiz UNET, isterse de çoklu etiket olarak eğittiğimiz Mask R-CNN ve YOLOv8 olsun, test işlemleri sırasında test sonucu görüntülerini ikili maske olarak elde ettik. Tüm bu maskeleri kademeli olarak görüntü işleme uygulamalarıyla birlikte, açılı ölçümü için, sunduğumuz iki farklı açılı ölçüm

tekniđi ile açıların sonuçlarını elde ettik. Uzman radyolog ölçüm sonuçları ve sunmuş olduğumuz yaklaşımları bir tabloya ekledik. Elde edilen bu sonuçları istatistiksel yaklaşımlar ile açı ölçüm önerilerin doğrulukları ve güvenilirlikleri karşılaştırılmıştır.

4.3.1 Açı ölçümü için sunulan öneriler


Derin öğrenme sonucu elde ettiğimiz ağırlıkları test görüntülerinde bölütleme ve görüntüler üzerinde açı ölçümü yaparak analizini hedefleyen bir dizi işlemle detaylandırılmıştır. İlk olarak, eğitim süreci tamamlanmış bir bölütleme modeli kullanılarak test verileri üzerinde tahminler gerçekleştirilmiştir. Elde edilen bölütleme maskeleri, yeniden boyutlandırma ve ikili maske haline getirme işlemlerinden geçmiştir. İkili maskeler üzerinde bölge özellikleri hesaplanmış ve bu özellikleri detaylı analizler için grafiksel olarak görselleştirilmiştir. Ayrıca, belirli bölgelerin yönelimlerini ve açılarını hesaplamak amacıyla Hough dönüşümü kullanılmış ve tespit edilen doğruların konumsal ilişkileri incelenmiştir. Bu süreçlerin sonunda, tıbbi görüntülerdeki yapısal ilişkilerin ve konumsal oryantasyonların detaylı bir şekilde analiz edilmesi sağlanmıştır.

Başlangıçta, eğitim süreci tamamlanmış bir bölütleme modeli yüklenmiştir. Bu model, test verileri üzerinde tahminlerde bulunarak bölütleme maskeleri oluşturur. Bölütleme maskeleri, tıbbi görüntülerdeki belirli yapıları tanımlamak için kullanılır. Modelin bu maskeleri üretme süreci, eğitimde öğrenilen parametreler kullanılarak gerçekleştirilir. Tahminler, test veri kümesindeki her bir görüntü için ayrı ayrı yapılır ve sonuçlar, bir numpy dizisi olarak saklanır. Modelin tahmin ettiği bölütleme maskelerinden biri seçilir ve bu maske yeniden boyutlandırılır. Yeniden boyutlandırma işlemi, Lanczos interpolasyonu kullanılarak gerçekleştirilir ve böylece görüntüdeki detayların korunması sağlanır. Daha sonra, yeniden boyutlandırılan görüntü ikili bir maske haline getirilir. Bu işlemde, belirli bir eşik değeri kullanılarak pikseller iki kategoriye ayrılır: eşik değerinin üzerindeki beyaz, altındaki siyah olarak belirlenir.

Elde edilmiş ikili maske üzerindeki farklı bölgeler bir Python kütüphanesi olan Scikit-image kütüphanesi kullanılarak tespit edilir ve bu bölgelerin çeşitli özellikleri hesaplanır. Bu tespit ve hesaplama işlemleri için bu kütüphanenin bir fonksiyonu olan “label” ve


“regionprops” fonksiyonu kullanılmıştır. Label fonksiyonu, bir görüntüdeki bağlantılı bileşenleri (nesneleri) tanımlamak için kullanılır. Girdi olarak ikili bir görüntü alır ve her bağlantılı bileşene benzersiz bir etiket atar. Bu işlem, bir görüntüdeki ayrı nesneleri tanımlamak ve saymak için faydalıdır. Regionprops fonksiyonu, etiketlenmiş bir görüntüdeki her bağlantılı bileşen hakkında çeşitli özellikleri hesaplar. Tespit edilen ve hesaplanan bu özellikler arasında; bölgelerin merkez noktası, yönelimi, ana eksen uzunluğu ve ikincil eksen uzunluğu bulunmaktadır. Bu bilgiler, bölütleme maskesinin geometrik ve yönelimsel analizini yapmak için kullanılır. Bu analiz, tıbbi görüntülerdeki anormalliklerin tespiti ve karakterizasyonu için kritik öneme sahiptir.

Bölge özelliklerinin anlaşılabilirliği artırmak için, bu özellikler grafiksel olarak görselleştirilir. Görselleştirme işlemi sırasında, her bölgenin merkez noktası, yönelimi ve eksen uzunlukları görüntü üzerine çizilir (Şekil 4.21). Bu görselleştirmeler, bölgelerin konumsal dağılımını ve yönelimlerini daha iyi anlaşılmasını sağlar. Belli bölgeler seçilerek, bu bölgelerin yönelimleri ve eksen uzunlukları kullanılarak alfa ve beta açılarının ölçümü için önemli çizgiler belirlenir. Görselleştirme işlemi, bu açılarının daha net bir şekilde anlaşılmasını sağlar (Şekil 4.21).



Şekil 4.21 a) Etiket ve bölge özellikleri b) Açı için ilgilenilen özellikler c) Alfa açısı için önemli çizgiler d) Beta açısı için önemli çizgiler

Açı ölçümünde birinci öneri olarak; görselleştirme sonucu istenilen bölgelerin çizgilerini kullanarak, görüntü işleme ve düz çizgi tespitinde kullanılan hough dönüşümü ile açılar bulunmuştur. Hough dönüşümü, görüntüdeki doğrusal özelliklerin tespit edilmesi için kullanılır. Bu dönüşüm, kenar tespit algoritmaları ile belirlenen kenar noktalarını kullanarak, görüntüdeki doğruların belirlenmesini sağlar. Hough dönüşümü ile tespit edilen doğruların açıları hesaplanır ve bu açıların farkları belirlenir. Hough dönüşümü ile tespit edilen doğrular, orijinal görüntü üzerine çizilerek görselleştirilir (Şekil 4.22). Bu görselleştirme, doğruların konumsal dağılımını ve açılarını anlamak için görsel bir araç sağlar.

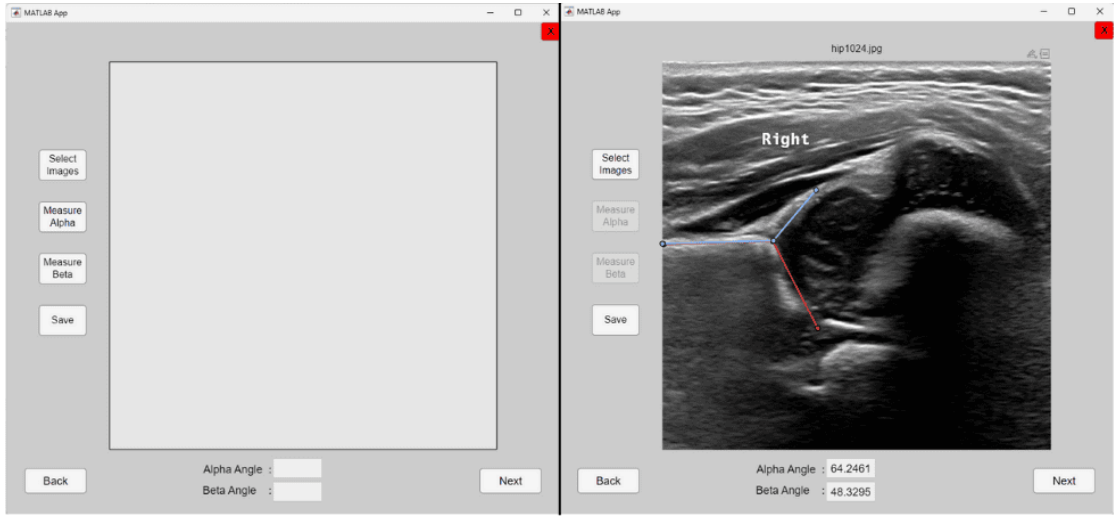


Şekil 4.22 a) Alfa açısının tespiti b) Beta açısının tespiti

Açı ölçümünde ikinci öneri olarak; birinci öneriden farklı hough dönüşümü yerine, regionprops fonksiyonundan elde edilen yönelim özellikleri ve ilgilenilen bölgelerin merkez noktası bilgileri kullanılarak açı ölçümü yapılmıştır. Bu işlemde merkez noktası bilgisi koordinat düzleminde bir nokta bilgisini temsil etmekte ve yönelim ise regionprops fonksiyonundan gelen bir açı değerini temsil etmektedir. Bir noktası ve açı değeri bilinen bir doğru denklemi ve denklemin eğimi elde edilmiştir. İlgilendiğimiz açı değeri iki doğru

arasında kaldığından, bulunan eğim bilgileri kullanılarak doğrular arasında kalan açı değeri hesaplanmıştır. Bu adımlar tüm test kümesine uygulanmış ve elde edilen değerler tabloya eklenmiştir.

Açı ölçümü için önerdiğimiz iki yöntemi karşılaştırmak için bir uzman radyolog ölçümlerine ihtiyaç duyulmuştur. Bunun için elimizdeki test kümesinin ölçümlerini uzman radyoloğa yaptırmak amacıyla MATLAB programının uygulama tasarım aracı tercih edilmiş, alfa ve beta açılarını ölçmek amacıyla uygun bir arayüz tasarlanmıştır. Tasarlanan arayüz, kullanıcıların görüntüler üzerinde alfa ve beta açılarını hesaplamalarına ve bu hesaplamaları bir metin dosyasına kaydetmelerine olanak tanımaktadır. Geliştirilen arayüz, kullanıcının görüntü seçmesine, alfa ve beta açılarını hesaplamasına ve sonuçları kaydetmesine olanak tanıyan bir dizi buton ve metin kutusundan oluşmaktadır (Şekil 4.23).



Şekil 4.23 Matlab işlevsel arayüz tasarımı ve uygulaması

Arayüz uygulaması, kullanıcıya görüntü seçme, ileri-geri butonları ile görüntüler arasında geçiş yapma, alfa/beta açılarını ölçme ve ölçülen açılar bir dosyaya kaydetme imkânı sunar. Ölçülen açılar uygulama arayüzünde görüntülenir ve kaydet butonuna basılarak istenilen dosyaya kaydedilir. Uygulama, kullanıcıya işlemin başarılı veya başarısız olduğunu bildiren uyarılar da gösterir. Bu arayüz ile elde edilen uzman değerleri ile açı ölçümü için sunulan öneri değerleri karşılaştırılmıştır.

4.3.2 İstatistiksel değerlendirme

Yapmış olduğumuz çalışmanın doğruluğunu ve ne oranda doğru olduğunu bulabilmek için deneysel sonuçları istatistiksel olarak analiz edildi. Bunun için SPSS adlı programı kullanıldı. İki farklı analiz yaklaşımında bulunuldu, bunlar Bland-Altman grafiği ve sınıf içi korelasyon katsayısı (ICC) uygulandı. Bland-Altman analizi, ölçüm tekniklerinin karşılaştırılması ve uygunluğunun değerlendirilmesi için etkili bir yöntemdir. Bu analiz, iki farklı yöntem veya araçla alınan ölçümler arasındaki farkların ve tutarsızlıkların ayrıntılı olarak incelenmesini sağlar. Bland-Altman'ın kullanım nedenleri ise; tutarlılık değerlendirmesi yapmak, ölçüm yöntemlerinin doğruluğu, güvenilirliği hakkında bilgi edinmek ve ölçümler arasındaki farkları görselleştirip tutarsızlıkları hızlıca tespit etmek için tercih edilir.

Bland-Altman grafiğini çizerken izlenmesi gereken adımlar;

1. Ortalama farkın hesaplanması:

$$\text{Ortalama fark} = \frac{1}{n} \sum_{i=1}^n (Yöntem1_i - Yöntem2_i) \quad (4.9)$$

2. Standart sapmanın hesaplanması:

$$\text{Standart sapma} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n [(Yöntem1_i - Yöntem2_i) - \text{Ortalama fark}]^2} \quad (4.10)$$

3. Güven aralığının belirlenmesi:

$$\text{Alt sınır} = \text{Ortalama fark} - (1.96 \times \text{Standart sapma}) \quad (4.11)$$

$$\text{Üst sınır} = \text{Ortalama fark} + (1.96 \times \text{Standart sapma}) \quad (4.12)$$

4. Saçılım grafiği ile bland-altman grafiğinin çizidilmesi:

Yatay eksen: İki yöntemle yapılan ölçümlerin ortalamaları.

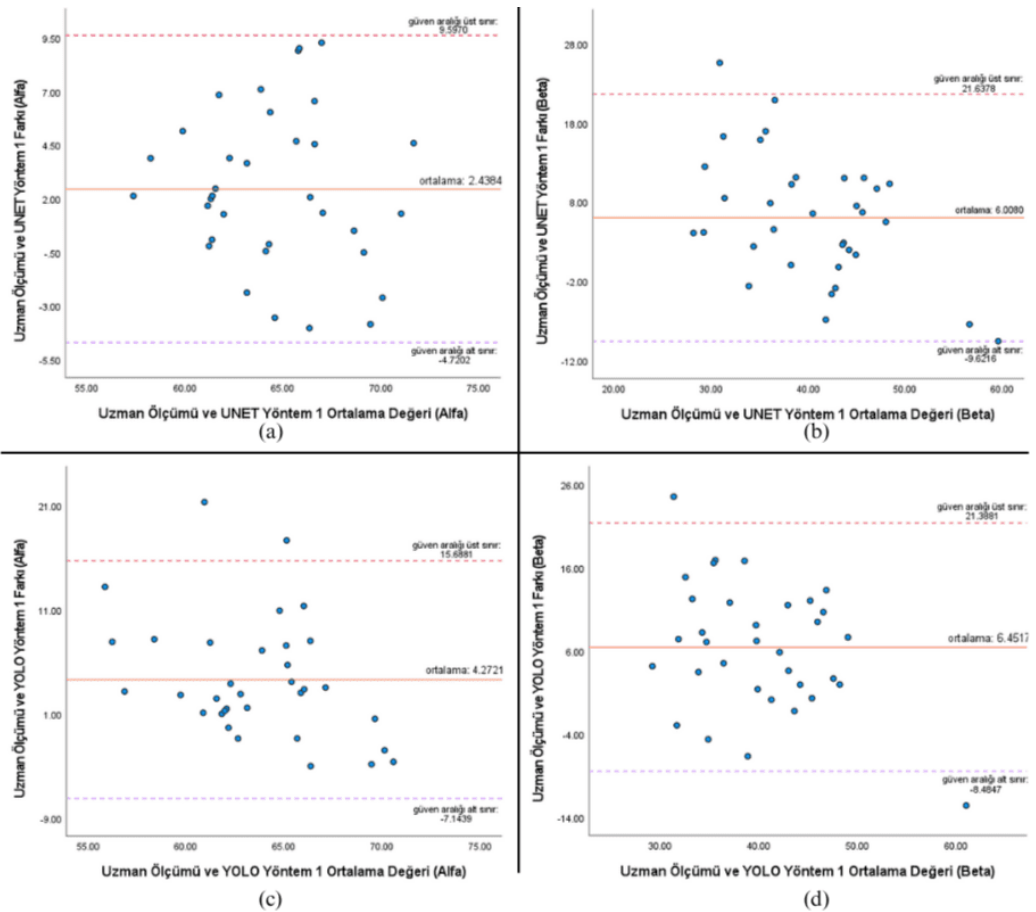
Dikey eksen: İki yöntem arasındaki farklar.

Sınıf içi korelasyon veya ICC, gruplar halinde düzenlenmiş birimler üzerinde yapılan nicel ölçümler için kullanılan tanımlayıcı bir istatistiksel ölçüdür. Özellikle, birden fazla değerlendiricinin aynı ölçümü yapması durumunda, bu ölçümlerin ne kadar tutarlı olduğunu belirlemek için kullanılır. ICC, bir grup içindeki varyansın toplam varyansa oranını ölçer. Bu ölçüm, aynı gruptaki birimlerin birbirlerine ne kadar benzediğini açıklar. ICC'nin yüksek olması, ölçüm yöntemlerinin veya ölçüm zamanlarının tutarlı olduğunu

ve deęişkenlięin büyük ölçüde gerçek deęişkenlikten kaynaklandığını gösterir. Bunun yanı sıra, ICC'nin düşük olması, ölçümler arasında büyük farklılıklar olduğunu ve bu farklılıkların gerçek deęişkenlikten ziyade ölçüm hatalarından kaynaklandığını gösterebilir. ICC'nin hesaplanması ve yorumlanması, kullanılacak modele ve verilere göre deęişiklik gösterebilir. ICC hesaplanması:

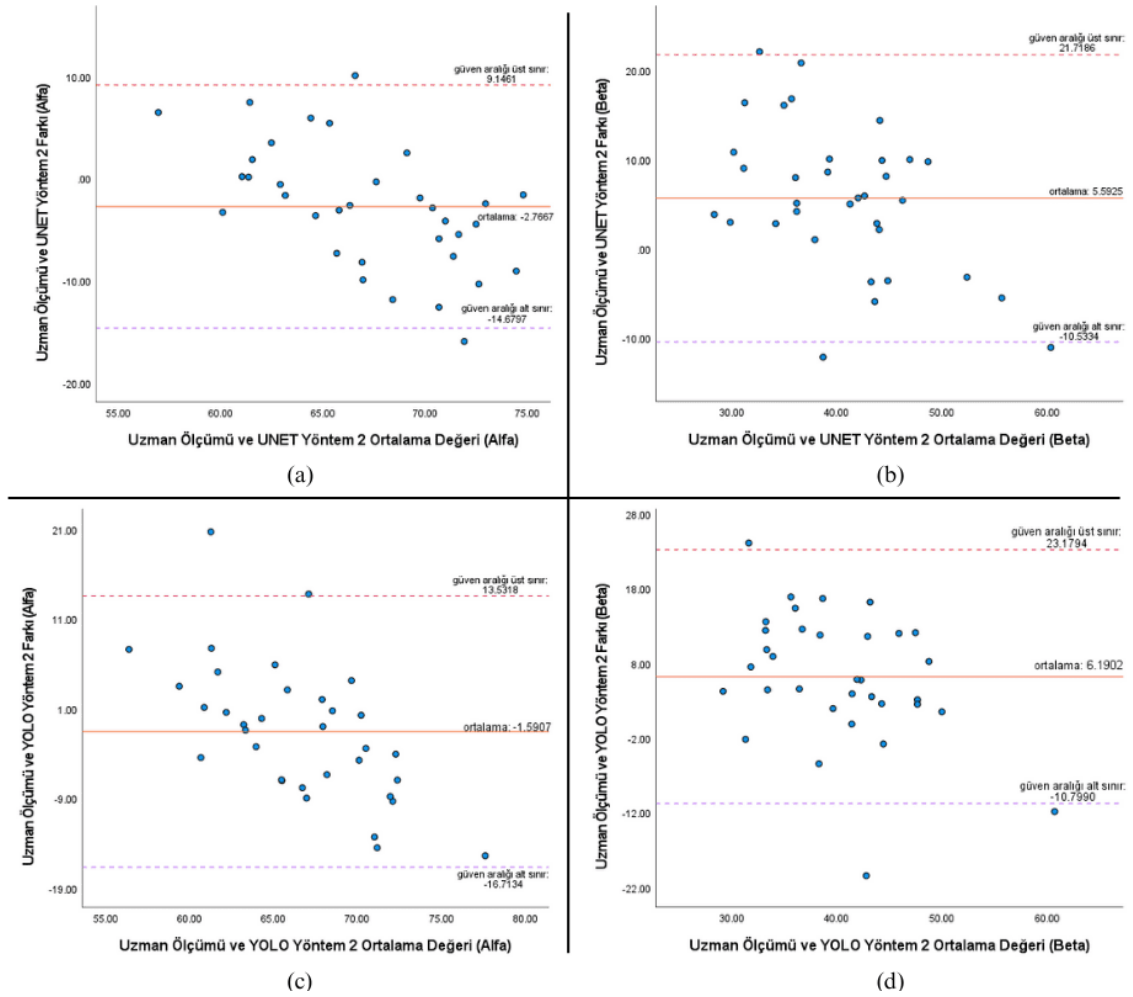
1. Verilerin Düzenlenmesi: Veriler genellikle deęerlendiriciler sütunlar ve özneler satırlar olacak şekilde düzenlenir.
 2. ICC Hesaplanması: $\sigma_{\text{özneler}}^2$: *özneler arası varyans* ve σ_{hata}^2 : *hata varyansı*
- $$ICC = \frac{\sigma_{\text{özneler}}^2}{\sigma_{\text{özneler}}^2 + \sigma_{\text{hata}}^2} \quad (4.13)$$
3. ICC'nin Yorumlanması: 0 ile 1 arasında bir deęer alır. 0'a yakın deęerler düşük güvenilirlięi, 1'e yakın deęerler ise yüksek güvenilirlięi gösterir.

Yöntem 1 sonuçları uzman ölçümlerine karşılık öneri yönteminin ve açılı türünün bland-altman grafikleri elde edilmiştir (Şekil 4.24).



Şekil 4.24 Yöntem 1 için; a) UNET alfa b) UNET beta c) YOLO alfa d) YOLO beta

Şekil 4.25'te ise yöntem 2 için sonuçlar, uzman ölçümlerine karşılık öneri yönteminin ve açı türünün bland-altman grafikleri elde edilmiştir.



Şekil 4.25 Yöntem 2 için; a) UNET alfa b) UNET beta c) YOLO alfa d) YOLO beta

ICC ölçümü, aynı gruptaki birimlerin birbirlerine ne kadar benzediğini açıkladığından yöntemler tek tek değerlendirildiğinde ve birlikte değerlendirildiklerinde farklı sonuç değerleri ortaya çıkmaktadır. ICC karşılaştırmasını gerçekleştirirken sunmuş olduğumuz öneri yöntemlerini temel alarak ilerlenmiştir. Bunun için istenilen açıya ait uzman ölçümü ve yöntemlerin o açı türü cinsinden elde edilmiş değerleri ortak olarak alınmıştır. Örneğin; uzman ölçüm alfa değeri ile UNET yöntem 1 alfa ve YOLO yöntem 1 alfa değeri ortak olarak değerlendirilmiş ve yöntem 1'e ait bir ICC değerine ulaşılmıştır. Bu işlem tüm açı ve yöntemler için uygulanmış ve ortaya çizelge 4.15'te verilen değerler çıkmıştır.

Çizelge 4.15 ICC sonuç tablosu

Sınıf İçi Korelasyon Katsayısı				
	Ortalama Ölçümler (ICC)	%95 Güven Aralığı	F testi p Değeri	Kullanılan Değişkenler
Yöntem 1 Alfa Açısı	0,728	Alt Sınır: 0,519 Üst Sınır: 0,855	< 0,001	Uzman Ölçümü Alfa UNET Yöntem 1 Alfa YOLO Yöntem 1 Alfa
Yöntem 2 Alfa Açısı	0,769	Alt Sınır: 0,592 Üst Sınır: 0,877	< 0,001	Uzman Ölçümü Alfa UNET Yöntem 2 Alfa YOLO Yöntem 2 Alfa
Yöntem 1 Beta Açısı	0,846	Alt Sınır: 0,729 Üst Sınır: 0,918	< 0,001	Uzman Ölçümü Beta UNET Yöntem 1 Beta YOLO Yöntem 1 Beta
Yöntem 2 Beta Açısı	0,837	Alt Sınır: 0,713 Üst Sınır: 0,913	< 0,001	Uzman Ölçümü Beta UNET Yöntem 2 Beta YOLO Yöntem 2 Beta

Çizelgeden anlaşılacağı üzere; alfa açısı için sunulan yöntemlerden yöntem 2 daha iyi sonuç vermiş ve beta açısı için ise yöntem 1 daha iyi sonuç vermiştir. Örneğin; yöntem 1 alfa açısı için 0,728 değeri yüksek bir uyumu işaret eder. Güven aralığı 0,519 ile 0,855 arasında, bu da ICC değerinin güvenilir bir tahmin olduğunu gösterir. Alfa açısı için elde edilmiş yöntem 2 önerisi ICC değeri iyi ($>0,7$) ve beta açısı için elde edilen yöntem 1 önerisi ICC değeri iyi ($>0,7$) olarak belirtilmiştir. F testi sonucunda verilen p-değeri istatistiksel anlamlılığı ifade eder. P-değeri, test edilen hipotezin doğru olma olasılığını gösterir. ICC analizinde F testi, ölçüm hatalarının varyansının, değerlendiriciler veya ölçüm yöntemleri arasındaki varyanstan anlamlı derecede farklı olup olmadığını değerlendirir. $p < 0.05$ ise istatistiksel olarak anlamlıdır. Bu durumda, değerlendiriciler veya ölçüm yöntemleri arasında anlamlı bir uyum olduğu sonucuna varılır. ICC değeri anlamlı kabul edilir. $p \geq 0.05$ olması ise istatistiksel olarak anlamlı değildir. Bu durumda, değerlendiriciler veya ölçüm yöntemleri arasında anlamlı bir uyum olmadığı sonucuna varılır. ICC değeri anlamlı kabul edilmez. Tüm bunlar göz önüne alındığında ve yine tüm değerlere bakıldığında ICC değerimizin, güven aralığının ve F testi önem değeri olan p değerimizin istatistiksel olarak anlamlı olduğunu gösterilmiştir.

5. TARTIŞMA VE SONUÇ

Kalça çıkığı veya gelişimsel kalça displazisi denilen rahatsızlık, femur başının ve asetabulumun etken olduğu iki yapının uyumsuzluğu sonucu oluşan yapısal bozukluktur. Kalça çıkığı erken teşhis ile tedavi edilebilir bir durumdur. Ancak, tanı ve tedavide gecikme uzuv kısalığı, topallama ve fonksiyonel özürlülük gibi durumlara neden olabilir. Özellikle yenidoğan ve 0-3, 0-6 ve 0-12 aylık bebeklerde, varsa rahatsızlığın erken teşhisi ve tedavisi kritik derecede önemlidir. İlerleyen yaşlarda tanıda gecikilen vakalarda tam tedavi şansı azalmaktadır. Erken tanı ve tedavinin önemi göz önüne alındığında, iki tanı yöntemi kullanılır: fiziksel muayene ve Ultrason (US) ile görüntüleme yöntemidir. US görüntüleme yönteminde tanı için Graf yöntemi çok sık olarak kullanılmaktadır. Graf yönteminde uzmandan, cihazdan ve uzman deneyiminden kaynaklı hatalar oluşabilir.

Kalça çıkığı teşhisi için CAD araştırmalar yapılmaktadır. US görüntülerinin alınması ve üzerinde işlem yapılması manuel olduğundan ölçümde zorlanmaya neden olmaktadır. Bu zorluklar yanlış sonuçlara yol açabilir. Bir CAD tanı yöntemiyle zorluklar giderilebilir ve ölçümden kaynaklı hatalar azaltılabilir. Bu çalışmada US görüntüleri üzerinde GKD tanısının ilk aşaması olan ilgili bölgelerin bölütlenmesi farklı mimari çözümler sunulmuştur. Bu sayede tanıda bulunan uzman doktora yardımcı bir sistem hedeflenmiştir.

Bu çalışmada GKD teşhisinde bulunabilmek için 3 farklı ağ mimarisi yaklaşımında bulunulmuştur. Bunlar sırasıyla U-Net, Mask R-CNN ve YOLOv8 yöntemleridir. Burada amaç bu mimari yöntemleri kullanarak ilgili bölgelerde bölütleme gerçekleştirmek ve açı ölçümü için bölüt alanını çıkartmaktır. Önerilen U-Net mimarisinde görüntüler gri seviye ve maskeler ise renkli maskeden yalnızca kırmızı kanalı tercih edilip tek kanal görüntü olarak ağa sunulmuştur. Model yapısı gereği bölütleme ilgili bölgeler ve arka plan olacak şekilde ikili bölütleme olarak yapılmıştır. Eğitilen ağ sonuçlarına göre; IoU değeri: 0,8701, dice katsayısı: 0,9305 ve AP değeri: 0,8740 olarak belirlenmiştir. Eğitim için diğer ağ mimarimiz olan Mask R-CNN'de yapılan eğitim sonucunda 5 etiketimizde öğrenme gerçekleştirmiş ve sonuçları tablolar halinde değerlendirme metrikleri aşamasında sunulmuştur. Bu mimarinin sonuçları değerlendirildiğinde labrum bölgesinin öğrenme

değerlerinin düşük olduğu gözlenmiş ve bunun sebebi olarak labrumun arka plana benzemesi yüzünden olduğu görülmüştür. Mask R-CNN maske kolunun eğitim sonuçları; mAP: 59,483 ve mAP50: 97,042 olarak tespit edilmiştir. Mask R-CNN box kolunun eğitim sonuçları; mAP: 63,586 ve mAP50: 97,786 olarak tespit edilmiştir. Son önerimiz olan YOLOv8 mimarisinde ise; maske kolunun eğitim sonuçları, mAP50: 0,980 ve mAP50-95: 0,652 olarak tespit edilmiştir. Box kolunun eğitim sonuçları; mAP50: 0,972 ve mAP50-95: 0,703 olarak tespit edilmiştir. Tüm bu sonuçlar göstermektedir ki; önerilerimiz arasında en yüksek başarıma ulaşan mimari YOLOv8 olmuştur.

Çalışmamızda bölütleme, açı ölçümü ve istatistiksel analizler kademeli olarak gerçekleştirilmiştir. İlk olarak, veri kümesinden derin öğrenme modelleriyle bölütleme yapılmış, ardından eğitim ağırlıkları test kümesine uygulanmıştır. UNET, Mask R-CNN ve YOLOv8 modelleri ile test sonuçları ikili maske olarak elde edilmiştir. Bu maskeler, iki farklı açı ölçüm tekniğiyle analiz edilmiştir. Uzman radyolog ölçümleri ve yaklaşımlarımız tabloya eklenmiş, sonuçlar istatistiksel olarak doğruluk ve güvenilirlik açısından karşılaştırılmıştır.

Açı ölçüm sürecinde ise; eğitim süreci tamamlanmış bir bölütleme modeli yüklenerek test verileri üzerinde tahminlerde bulunulmuş ve bölütleme maskeleri oluşturulmuştur. Bu maskeler, Lanczos interpolasyonu kullanılarak yeniden boyutlandırılmış ve ikili maskeye dönüştürülmüştür. Scikit-image kütüphanesi ile maskeler üzerindeki bölgeler tespit edilerek özellikleri hesaplanmıştır. Bu özellikler, bölütleme maskesinin geometrik ve yönelimsel analizinde kullanılmıştır. Görselleştirme ile bölgelerin yönelimleri ve eksen uzunlukları görüntü üzerine çizilmiş ve alfa ile beta açıları ölçülmüştür.

Açı ölçümü için iki yöntem önerilmiştir: Hough dönüşümü ve regionprops fonksiyonunun yönelim özellikleri. Birinci yöntemde Hough dönüşümü ile ilgilenilen bölgelerin açıları hesaplanmış ve görselleştirilmiştir. İkinci yöntemde ise yönelim ve merkez noktası bilgileri kullanılarak açı ölçümü yapılmıştır. Her iki yöntem de test kümesine uygulanmış ve sonuçlar karşılaştırılmıştır. Açı ölçümlerinin doğruluğunu değerlendirmek için uzman radyolog ölçümleri alınmış ve MATLAB'da tasarlanan bir arayüz kullanılarak kaydedilmiştir. Uzman ölçümleri ile önerilen yöntemlerin sonuçları karşılaştırılmıştır.

Yapılan çalışmanın doğruluğunu değerlendirmek için deneysel sonuçlar istatistiksel olarak analiz edilmiştir. SPSS programı kullanılarak Bland-Altman grafiği ve sınıf içi korelasyon katsayısı ile iki farklı analiz yapılmıştır. Bland-Altman grafiklerinden de görüldüğü üzere açı ölçümü için sunulan yöntemlerin değerlerinin büyük kısmının saçılım grafiğinde güven aralığında kaldığı görülmüştür. Bu da önerilen yöntemlerin doğruluğunu desteklemiştir. ICC karşılaştırması yapılırken, önerilen yöntemler üzerinden ilerlenmiş ve istenen açı türü için uzman ölçümleri ile yöntemlerin elde ettiği değerler karşılaştırılmıştır. Alfa açısı için yöntem 2 daha iyi performans gösterirken, beta açısı için ise yöntem 1 daha iyi sonuç vermiştir.

Açı ölçümü açısından ICC sonuçlarına literatürde bakıldığında Chan vd. (2022) tarafından yapılmış çalışmada alfa açısı için 0,85 ICC değeri ve beta açısı için 0,73 ICC değeri elde etmişlerdir. Bir diğer çalışmada ise Lee vd. (2021) alfa açısı için 0,764 ICC değeri ve beta açısı için 0,743 ICC değeri elde etmişlerdir. Bu çalışmada; alfa açısı için sunulan yöntemlerden yöntem 2 daha iyi sonuç verip 0,769 ICC değeri elde edilmiştir. Beta açısı için ise sunulan yöntemlerden yöntem 1 daha iyi sonuç verip 0,846 ICC değeri elde edilmiştir. Yapılan F testi sonucunda elde edilen p-değeri, test edilen hipotezin doğruluğunu ifade etmektedir. Tüm veriler göz önüne alındığında, ICC değeri, güven aralığı ve F testi p değeri istatistiksel olarak anlamlı bulunmuştur, bu da yöntemlerin ölçüm doğruluğu ve güvenilirliğini desteklemiştir.

KAYNAKLAR

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jozefowicz, R., Jia, Y., Kaiser, L., Kudlur, M., Levenberg, J., Mané, D., Schuster, M., Monga, R., Moore, S., Murray, D., Olah, C., Shlens, J., Steiner, B., Sutskever, I., Talwar, K., Tucker, P., Vanhoucke, V., Vasudevan, V., Viégas, F., Vinyals, O., Warden, P., Wattenberg, M., Wicke, M., Yu, Y., & Zheng, X. (2015). TensorFlow, Large-scale machine learning on heterogeneous systems [Computer software].
- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., & Süsstrunk, S. (2012). SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE transactions on pattern analysis and machine intelligence*, 34(11), 2274–2282.
- Amari, S. I., (1967). A theory of adaptive pattern classifier, *IEEE Trans*, EC-16, 279-307
- Anonymous. 2023. Web Sitesi: <https://github.com/ultralytics/ultralytics/issues/189> Erişim Tarihi: 01.09.2023.
- Cevik, K. & Kocer, H., E. & Andac, S. (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. 449-457.
- Cevik, K.K. (2016). Görüntü İşleme Teknikleri ile Gelişimsel Kalça Displazisi Teşhisi. Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalını, Konya.
- Chen, T., Zhang, Y., Wang, B., Wang, J., Cui, L., He, J., & Cong, L. (2022). Development of a Fully Automated Graf Standard Plane and Angle Evaluation Method for Infant Hip Ultrasound Scans. *Diagnostics (Basel, Switzerland)*, 12(6), 1423.
- CVAT.ai Corporation. (2023). Computer Vision Annotation Tool (CVAT) (Version 2.8.2) [Computer software]. <https://github.com/opencv/cvat> Erişim Tarihi: 02.01.2023.
- Çevik, K.K., Andaç, Ş., (2022). Detection of Standard Plane From Ultrasound Scans by Deep Learning Methods for the Diagnosis of Developmental Hip Dysplasia, *Journal of Engineering Sciences and Design*, 10(3), 1014-1026.
- El-Hariri, H., Hodgson, A.J., Mulpuri, K., Garbi, R., (2021). Automatically Delineating Key Anatomy in 3-D Ultrasound Volumes for Hip Dysplasia Screening. *Ultrasound Med. Biol.* 2021, 47, 2713–2722.
- El-Hariri, H., Mulpuri, K., Hodgson, A., Garbi, R., (2019). Comparative evaluation of hand-engineered and deep-learned features for neonatal hip bone segmentation in ultrasound. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*; Springer: Cham, Switzerland, 2019; pp. 12–20.
- Fukushima, K., (1969). Visual feature extraction by a multilayered network of analog threshold elements. *IEEE Transactions on Systems Science and Cybernetics*. 5 (4): 322-333.

- Fukushima, K., (1975). Cognitron: A self-organizing multilayered neural network. *Biological Cybernetics*, 20(3), 121-136.
- Golan, D., Donner, Y., Mansi, C., Jaremko, J., Ramachandran, M., on behalf of CUDL. (2016). Fully Automating Graf's Method for DDH Diagnosis Using Deep Convolutional Neural Networks. In: Carneiro, G., et al. *Deep Learning and Data Labeling for Medical Applications. DLMIA LABELS 2016* 2016. *Lecture Notes in Computer Science()*, vol 10008. Springer, Cham.
- Graf R. (1983). New possibilities for the diagnosis of congenital hip joint dislocation by ultrasonography. *Journal of pediatric orthopedics*, 3(3), 354–359.
- Graf R. (1984). Fundamentals of sonographic diagnosis of infant hip dysplasia. *Journal of pediatric orthopedics*, 4(6), 735–740.
- Graf R., (2006). *Hip sonography: Diagnosis and management of infant hip dysplasia*. Berlin/Heidelberg: Springer
- Hacihaliloglu, I., Guy, P., Hodgson, A. J., & Abugharbieh, R. (2014). Volume-specific parameter optimization of 3D local phase features for improved extraction of bone surfaces in ultrasound. *The international journal of medical robotics + computer assisted surgery: MRCAS*, 10(4), 461–473.
- Hardle, W., Simar, L., (2007). *Canonical Correlation Analysis*. In: *Applied Multivariate Statistical Analysis*. Springer, Berlin, Heidelberg.
- Hareendranathan, A.R., Zonoobi, D., Mabee, M., Cobzas, D., Punithakumar, K., Noga, M.L., & Jaremko, J.L. (2017). Toward automatic diagnosis of hip dysplasia from 2D ultrasound. *2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*, 982-985.
- Hareendranathan, A. R., Chahal, B. S., Zonoobi, D., Sukhdeep, D., & Jaremko, J. L. (2021). Artificial Intelligence to Automatically Assess Scan Quality in Hip Ultrasound. *Indian journal of orthopaedics*, 55(6), 1535–1542.
- Hareendranathan, A. R., Mabee M., Chahal B.S., Dulai S. K., Jaremko J. L., 2022. Can AI Automatically Assess Scan Quality of Hip Ultrasound? *Applied Sciences*. 12(8):4072.
- Hareendranathan, A. R., Chahal, B., Ghasseminia, S., Zonoobi, D., & Jaremko, J. L. (2022). Impact of scan quality on AI assessment of hip dysplasia ultrasound. *Journal of ultrasound*, 25(2), 145–153.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- He, K., Gkioxari, G., Dollár, P., & Girshick, R.B. (2017). Mask R-CNN. *2017 IEEE International Conference on Computer Vision (ICCV)*, 2980-2988.
- Hecht-Nielsen, R. (1992). Theory of the backpropagation neural network. In *Neural networks for perception* (pp. 65-93). Academic Press.

- Helli, S., & Hamamcı, A. (2022). Tooth Instance Segmentation on Panoramic Dental Radiographs Using U-Nets and Morphological Processing. *Düzce Üniversitesi Bilim Ve Teknoloji Dergisi*, 10(1), 39-50.
- 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.
- Hu, X., Wang, L., Yang, X., Zhou, X., Xue, W., Cao, Y., Liu, S., Huang, Y., Guo, S., Shang, N., Ni, D., & Gu, N. (2021). Joint Landmark and Structure Learning for Automatic Evaluation of Developmental Dysplasia of the Hip. *IEEE Journal of Biomedical and Health Informatics*, 26, 345-358.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- Hwang, Sm., Park, HJ., Lee, Jh. (2021). A Study on a Mask R-CNN-Based Diagnostic System Measuring DDH Angles on Ultrasound Scans. In: Singh, M., Kang, DK., Lee, JH., Tiwary, U.S., Singh, D., Chung, WY. (eds) *Intelligent Human Computer Interaction. IHCI 2020. Lecture Notes in Computer Science()*, vol 12616. Springer, Cham.
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). YOLO by Ultralytics (Version 8.0.0) [Computer software] <https://github.com/ultralytics/ultralytics> , Erişim Tarihi: 01.09.2023.
- Kelley, H.J. (1960). Gradient Theory of Optimal Flight Paths. *ARS Journal*, 30, 947-954.
- Kingma, D.P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. *CoRR*, abs/1412.6980.
- Kohonen, T. (1982) Self-organized formation of topologically correct feature maps. *Biol. Cybern.* 43, 59–69.
- LeCun, Y., Bengio, Y. & Hinton, G., (2015). Deep learning. *Nature* 521, 436–444.
- Lee, S. W., Ye, H. U., Lee, K. J., Jang, W. Y., Lee, J. H., Hwang, S. M., & Heo, Y. R. (2021). Accuracy of New Deep Learning Model-Based Segmentation and Key-Point Multi-Detection Method for Ultrasonographic Developmental Dysplasia of the Hip (DDH) Screening. *Diagnostics (Basel, Switzerland)*, 11(7), 1174.
- Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., ... & Zitnick, C. L. (2014). Microsoft COCO: Common objects in context. In *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part V 13* (pp. 740-755). Springer International Publishing.
- Linnainmaa, S., (1970). The representation of the cumulative rounding error of an algorithm as a Taylor expansion of the local rounding errors (Masters) (in Finnish). University of Helsinki. pp. 6–7.

- Liu, R., Liu, M., Sheng, B., Li, H., Li, P., Song, H., Zhang, P., Jiang, L., & Shen, D. (2021). NHBS-Net: A Feature Fusion Attention Network for Ultrasound Neonatal Hip Bone Segmentation. *IEEE transactions on medical imaging*, 40(12), 3446–3458.
- McCulloch, W.S., Pitts, W. (1943) A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics* 5, 115–133.
- Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., & Terzopoulos, D. (2021). Image segmentation using deep learning: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 44(7), 3523-3542.
- Neubeck, A., & Van Gool, L. (2006, August). Efficient non-maximum suppression. In 18th international conference on pattern recognition (ICPR'06) (Vol. 3, pp. 850-855). IEEE.
- Özcan, A. R. (2020). EEG İşaretlerinde Evrişimli Sinir Ağları İle Epileptik Nöbet Tahmini. Doktora Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli, 10326915.
- Paserin, O., Mulpuri, K., Cooper, A., Hodgson, A.J., Abugharbieh, R., (2017). Automatic near real-time evaluation of 3D ultrasound scan adequacy for developmental dysplasia of the hip. In *Computer Assisted and Robotic Endoscopy and Clinical Image-Based Procedures*; Springer: Cham, Switzerland, pp. 124–132.
- Paserin, O., Mulpuri, K., Cooper, A., Abugharbieh, R., Hodgson, A.J., (2018). Improving 3D ultrasound scan adequacy classification using a three-slice convolutional neural network architecture. *CAOS 2018*, 2, 152–156.
- Paserin, O., Mulpuri, K., Cooper, A., Hodgson, A.J., Garbi, R., (2018). Real time RNN based 3D ultrasound scan adequacy for developmental dysplasia of the hip. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*; Springer: Cham, Switzerland, 2018; pp. 365–373.
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Köpf, A., Yang, E., DeVito, Z., Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., Bai, J., & Chintala, S. (2019). PyTorch: An Imperative Style, High-Performance Deep Learning Library. *Neural Information Processing Systems*.
- Qian, N. (1999). On the momentum term in gradient descent learning algorithms. *Neural networks: the official journal of the International Neural Network Society*, 12 1, 145-151.
- Quader, N., Hodgson, A.J., Mulpuri, K., Savage, T., & Abugharbieh, R. (2015). Automatic assessment of developmental dysplasia of the hip. 2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI), 13-16.
- Quader, N., Hodgson, A. J., Mulpuri, K., Schaeffer, E., & Abugharbieh, R. (2017). Automatic Evaluation of Scan Adequacy and Dysplasia Metrics in 2-D Ultrasound Images of the Neonatal Hip. *Ultrasound in medicine & biology*, 43(6), 1252–1262.

- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 779-788).
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.
- Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015. Lecture Notes in Computer Science, vol 9351. Springer, Cham.
- Rosenblatt, F., (1957). The perceptron, a perceiving and recognizing automaton Project Para. Cornell Aeronautical Laboratory.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. ArXiv, abs/1609.04747.
- Sazlı, M. H. (2006). A brief review of feed-forward neural networks. *Communications Faculty of Sciences University of Ankara Series A2-A3 Physical Sciences and Engineering*, 50(01).
- Sezer, H. & Sezer, A. (2019). Automatic segmentation and classification of neonatal hips according to Graf's sonographic method: A computer-aided diagnosis system. *Applied Soft Computing*. 82. 105516.
- Şaşmaz, H. H., (2011). Gelişimsel kalça displazisi tanısında sonografik tarama tekniklerinin karşılaştırılması, Gaziantep Üniversitesi, Gaziantep, Türkiye, 113.
- Tosun, H. B., Bulut, M., Karakurt, L., Belhan, O., vd. (2010). Gelişimsel Kalça Displazisi Taraması İçin Yapılan Kalça Ultrasonografisi Sonuçlarının Değerlendirilmesi. *Fırat Tıp Dergisi*, 15(4), 178-183.
- 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.
- Turhan, M. M., & Talu, M. F. (2022). Adaptif Sigmoid, Lojistik Sigmoid ve Tanjant Hiperbolik Aktivasyon Fonksiyonların Tam Bağlı ve Konvolüsyonel Sinir Ağlarında Kıyaslanması. *Muş Alparslan Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 3(2), 89-101.
- Turing, A. M. (1950). *Computing Machinery and Intelligence*. 433–460.
- Wu, Y., Wu, Kirillov, A., Massa, F., Lo, W., Girshick. R., Lo W. Y., Girshick, R., (2019). Detectron2 [Computer software] <https://github.com/facebookresearch/detectron2> Erişim Tarihi: 01.09.2023
- Yan, Z., Yang, X., & Cheng, K. T. (2018). A Skeletal Similarity Metric for Quality Evaluation of Retinal Vessel Segmentation. *IEEE transactions on medical imaging*, 37(4), 1045–1057.