



T.C.  
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME İLE PROKSİMAL FEMUR KIRIKLARININ TESPİTİ VE  
SINIFLANDIRILMASI

Assma HIJAZI

DANIŞMAN

Doç. Dr. Derya YILTAŞ KAPLAN

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı

Ocak, 2024

## TEZ KABUL VE ONAYI

Assma HIJAZI tarafından, Doç. Dr. Derya YILTAŞ KAPLAN danışmanlığında hazırlanan "DERİN ÖĞRENME ile PROKSİMAL FEMUR KIRIKLARININ TESPİTİ ve SINIFLANDIRILMASI" başlıklı bu çalışma, jürimiz tarafından 15/01/2024 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

### Tez Jürisi

	İmza	Sonuç
DANIŞMAN	Doç. Dr. Derya YILTAŞ KAPLAN	<input checked="" type="checkbox"/>
	İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Mühendisliği Anabilim Dalı	<input type="checkbox"/> Kabul <input type="checkbox"/> Ret
ÜYE	Dr. Öğr. Üyesi G. Zeynep GÜRKAŞ AYDIN	<input checked="" type="checkbox"/>
	İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Mühendisliği Anabilim Dalı	<input type="checkbox"/> Kabul <input type="checkbox"/> Ret
ÜYE	Dr. Öğr. Üyesi Serpil ÜSTEBAY	<input checked="" type="checkbox"/>
	İstanbul Medeniyet Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı	<input type="checkbox"/> Kabul <input type="checkbox"/> Ret

## BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve bilimsel etik kuralları içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını ve her türlü hukuki sorumluluğu aldığımı kabul ederim.

Assma HIJAZI

*Mucizevi aileme, canım babam Abdülğani'ye, bir tanem annem Sümeyye'ye ve göz bebeğim  
Ömer'e, Sara'ya ve Osama'ya...*

## **BÜTÇE DESTEKLERİ**

### **DERİN ÖĞRENME ile PROKSİMAL FEMUR KIRIKLARININ TESPİTİ ve SINIFLANDIRILMASI**

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.



## TEŞEKKÜR

Öncelikle, şükürler olsun ki Yüce Allah'ın bana ihsan etmiş olduğu nimetler ile öğrenim hayatım boyunca ve bu tezin tamamlanmasında bana vermiş olduğu sonsuz lütufları için Hamd ediyorum.

Bu tezin tamamlanması tek başına mümkün olamazdı. Bir şekilde bana destek, rehberlik, yardım ve teşvik veren birçok kişiye minnettarım. Bu başarıyı mümkün kılan tüm kahramanlara teşekkür etmek benim için büyük bir mutluluk.

Her şeyden önce, araştırma süresince çabalarına olan inancı, cesaretlendirmesi, sonsuz desteği ve paha biçilmez rehberliği için hocam Doç. Dr. Derya YILTAŞ KAPLAN'a teşekkürlerimi sunarım. Araştırma yazma metodolojisini bana ders döneminde öğretti ve o dönemde eksikliklerim olsa da her zaman daha iyisini yapmam için beni teşvik etti ve bana inandı.

Hastalığı öneren, önemini açıklayan, kolay, basit ve anlaşılır bir şekilde sunduğu ve röntgen görüntülerinin sınıflandırılması ve yorumlanmasına nezaret eden sevgili babam ortopedi ve travmatoloji danışmanı Dr. Abdulgni Hijazi'ye özellikle teşekkür ederim. Onun çabaları ve denetimi olmasaydı bu tez ışık göremez ve başarıya ulaşamazdı.

Sevgili babam Abdulgni'den, annem Sümeyye'den, kardeşlerim Ömer ve Osama'ya ve kız kardeşim Sara'ya kadar tüm AİLEME sonsuz şükranlarımı sunarım. Onların sevgisi, duaları, inançları, cesaretlendirmeleri ve sürekli destekleri olmadan bu tez tamamlanamazdı.

Son olarak Hocamız Peygamber Efendimiz (s.a.v.)'in bize öğrettiği gibi, "İnsanlara teşekkür etmeyen, Allah'a da şükretmez", bu tezi tamamlanması için bana yardım eden, destek veren ve ufak da olsa bilgi veren, adını burada sayamadığım herkese teşekkürlerimi sunuyorum.

Ocak 2024

Assma HIJAZI

# İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI.....	ii
BEYAN .....	iii
BÜTÇE DESTEKLERİ .....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
ŞEKİL LİSTESİ .....	x
TABLO LİSTESİ.....	xii
KISALTMA LİSTESİ.....	xiii
ÖZET .....	xiv
ABSTRACT .....	xvi
<b>1. GİRİŞ.....</b>	<b>1</b>
1.1. SORUN BİLDİRİMİ .....	1
1.2. MOTİVASYON.....	2
1.3. TEZ ORGANİZASYONU .....	2
<b>2. KEMİKLER, PROKSİMAL FEMUR KIRIĞI VE KALÇA ÇIKIĞI.....</b>	<b>4</b>
2.1. KEMİKLER.....	4
2.1.1. Kemik İşlevi .....	4
2.1.2. Kemik Yapısı ve Anatomisi .....	5
2.1.3. Kemik Sınıflandırması .....	7
2.2. PROKSİMAL FEMUR KIRIĞI VE KALÇA ÇIKIĞI.....	10
2.2.1. Femur Başı Kırığı.....	12
2.2.2. Femur Boyun Kırığı .....	13
2.2.3. İntertrokanterik Kırık .....	15
2.2.4. AO/OTA Sınıflandırması .....	16
2.2.5. Kalça Çıkığı.....	17
2.3. TIBBİ GÖRÜNTÜLER İLE PROKSİMAL FEMUR KIRIKLARININ VE KALÇA ÇIKIKLARININ TESPİTİ .....	18
2.3.1. Röntgen (Radyografi).....	18

2.3.2. Bilgisayarlı Tomografi (CT) Taraması .....	19
2.3.3. Manyetik Rezonans Görüntüleme (MRI).....	20
2.4. TIP TARAFIYLA İLGİLİ ÖZET .....	20
<b>3. LİTERATÜR TARAMASI.....</b>	<b>22</b>
3.1. TIBBİ GÖRÜNTÜLERDE CV GÖREVLERİ .....	23
3.1.1. Tıbbi Görüntü Sınıflandırması .....	23
3.1.2. Tıbbi Görüntüde Nesne Algılama .....	23
3.1.3. Tıbbi Görüntü Segmentasyonu.....	24
3.2. ORTOPEDİ CV .....	24
3.2.1. Bilgisayar mı İnsan mı? Femur Boyun Kırıklarının Tespiti İçin Derin Öğrenme ile Algısal Eğitim Karşı Karşıya [64].....	27
3.2.2. Derin Bir Evrişimli Sinir Ağı Kullanarak İntertrokanterik Kalça Kırıklarını Ortopedist Düzeyinde Doğrulukla Tespit Etmek [65] .....	28
3.2.3. Düz Pelvik Radyografilerde Kalça Kırıklarının Tespiti ve Görselleştirilmesi için Derin Öğrenme Algoritmasının Uygulanması [66].....	28
3.2.4. Derin Öğrenme ve Genetik Algoritmalar Kullanılarak X-ışını Filmlerde Femur Boyun Kırığı Tespiti [67].....	29
3.2.5. Otomatik Femur Boyun Kırığı Tespiti ve Sınıflandırmasına Uygulanan İleri Derin Öğrenme Teknikleri [2].....	30
3.2.6. İnteraktif Eğitim ve Cerrahi Planlama için Hassas Proksimal Femur Kırığı Sınıflandırması [68].....	31
3.2.7. Pozisyon, Donanım Varlığı ve Kırık Tespiti için Pelvik Radyografilerin Derin Öğrenme Değerlendirmesi [69].....	32
3.2.8. Pelvik Röntgen Görüntülerinde Femur Kırık Tespiti İçin Meta-Öğrenimli Derin Sinir Ağları [70] .....	33
3.2.9. Proksimal Femur Röntgen Görüntülerinde Çok Aşamalı Derin Öğrenme ile Hiyerarşik Kırık Sınıflandırması [71] .....	34
3.2.10. Ölçeklenebilir Hekim Düzeyinde Derin Öğrenme Algoritması, Pelvik Radyografilerde Evrensel Travmayı Tespit Eder [72] .....	35
3.2.11. Proksimal Femur Kemiği Kırığının Mask R-CNN Kullanılarak Tespiti [73] .....	36
<b>4. MALZEME VE YÖNTEM .....</b>	<b>40</b>
4.1. MODELLER.....	40
4.1.1. YOLO Ailesi .....	40
4.1.2. Mask R-CNN [51].....	43
4.1.3. PointRend.....	44
4.2. PERFORMANS DEĞERLENDİRME METRİKLERİ.....	45
4.2.1. Hassasiyet (P).....	45

4.2.2. Geri Çağırma (R).....	45
4.2.3. Ortalama Hassasiyetin Ortalaması (mAP) .....	46
4.3. VERİ KÜMESİ/SETİ .....	46
4.3.1. Veri Seti Edinimi ve Açıklaması/Etiketlenmesi .....	46
4.4. VERİ BÜYÜTME .....	49
4.5. SİSTEM ORTAMI .....	50
4.6. İŞ AKIŞ SÜRECİ .....	50
<b>5. SONUÇLAR.....</b>	<b>52</b>
5.1. YOLO MODELLERİ .....	52
5.2. Mask R-CNN'nin Sonuçları .....	57
5.3. PointRend (İşaret Noktası).....	62
<b>6. TARTIŞMA.....</b>	<b>68</b>
<b>7. SONUÇ VE ÖNERİLER .....</b>	<b>70</b>
<b>8. KAYNAKÇA.....</b>	<b>71</b>
<b>İNTİHAL RAPORU İLK SAYFASI .....</b>	<b>80</b>
<b>ETİK KURUL İZİN YAZISI .....</b>	<b>81</b>
<b>KURUM İZİNİ YAZILARI.....</b>	<b>82</b>
<b>ÖZGEÇMİŞ .....</b>	<b>83</b>

## ŞEKİL LİSTESİ

	<b>Sayfa No</b>
Şekil 2.1 İskelet Sistemi Parçaları .....	4
Şekil 2.2 Kemik Anatomisi .....	7
Şekil 2.3 Konuma Göre Kemik Sınıflandırması.....	8
Şekil 2.4 Şekle Göre Kemik Sınıflandırması.....	9
Şekil 2.5 Uzun Kemik Ana Parçaları .....	10
Şekil 2.6 Femur Kemiği Ana Parçaları.....	11
Şekil 2.7 Proksimal Femur Kırığı ve Dislokasyon Röntgenleri .....	12
Şekil 2.8 Pipkin Sınıflandırması [23] .....	13
Şekil 2.9 Boyun Kırığı Röntgeni .....	13
Şekil 2.10 Pauwels Sınıflandırması [28] .....	14
Şekil 2.11 Garden Sınıflandırması [29].....	15
Şekil 2.12 İntertrokanterik Kırık Röntgeni.....	15
Şekil 2.13 Evans Sınıflandırması .....	16
Şekil 2.14 Çıkık X-ışınları.....	18
Şekil 2.15 Röntgen/X-ışını [37].....	19
Şekil 2.16 Bilgisayarlı Tomografi (CT) [41].....	19
Şekil 2.17 Manyetik Rezonans Görüntüleme (MRI) [47] .....	20
Şekil 4.1 YOLOv8 Modelin Mimarisi [84] .....	42
Şekil 4.2 Maske R-CNN Model Mimarisi .....	44
Şekil 4.3 PointRend Model Mimarisi [85] .....	45
Şekil 4.4 Polygon Aracı ile Açıklanmış/Etiketlenmiş Veriler.....	49
Şekil 4.5 Artırılmış Film Örneği .....	50

Şekil 4.6 İş Akış Süreci .....	51
Şekil 5.1 YOLOv5 Metrikleri Görselleştirme: Eğitim ve Doğrulama .....	54
Şekil 5.2 YOLOv7 Metrikleri Görselleştirme: Eğitim ve Doğrulama .....	54
Şekil 5.3 YOLOv8 Metrikleri Görselleştirme: Eğitim ve Doğrulama .....	55
Şekil 5.4 Test Verilerinde YOLOv5 Tahmini Sonuçlar .....	55
Şekil 5.5 Test Verilerinde YOLOv7 Tahmini Sonuçlar .....	56
Şekil 5.6 Test Verilerinde YOLOv8 Tahmini Sonuçlar .....	56
Şekil 5.7 Mask R-CNN ResNet50+FPN'ın ve Mask R-CNN ResNet101+FPN'ın Veri Büyütme Olmadan Doğruluk ve Kayıp Eğrileri.....	60
Şekil 5.8 Mask R-CNN ResNet50+FPN'ın ve Mask R-CNN ResNet101+FPN'ın Veri Büyütme ile Doğruluk ve Kayıp Eğrileri .....	60
Şekil 5.9 Mask R-CNN ResNet50+FPN'ın ve Mask R-CNN ResNet101+FPN'ın Veri Büyütme Olmadan ve İnce Ayarlar ile Doğruluk ve Kayıp Eğrileri.....	61
Şekil 5.10 Mask R-CNN ResNet50+FPN'ın ve Mask R-CNN ResNet101+FPN'ın Veri Büyütme ve İnce Ayarlar ile Doğruluk ve Kayıp Eğrileri.....	61
Şekil 5.11 Mask R-CNN Test Verileri Üzerinde Tahmini Sonuçları.....	62
Şekil 5.12 PointRend ResNet50+FPN'ın ve ResNet101+FPN'ın Büyütme Olmadan Doğruluk ve Kayıp Eğrileri .....	65
Şekil 5.13 PointRend ResNet50+FPN'ın ve ResNet101+FPN'ın Büyütme Olmadan Doğruluk ve Kayıp Eğrileri .....	65
Şekil 5.14 PointRend ResNet50+FPN'ın ve ResNet101+FPN'ın Büyütme Olmadan İnce Ayar ile Doğruluk ve Kayıp Eğrileri .....	66
Şekil 5.15 PointRend ResNet50+FPN'ın ve ResNet101+FPN'ın Büyütme ve İnce Ayar ile Doğruluk ve Kayıp Eğrileri .....	66
Şekil 5.16 PointRend Test Verileri Üzerinde Tahmini Sonuçları .....	67
Şekil 6.1 Sırasıyla YOLO, MASK R-CNN ve PointRend Çıkarım Karşılaştırması.....	69
Şekil 6.2 Mask R-CNN Sınıflarının Örtüşmesi.....	69

## TABLO LİSTESİ

	<b>Sayfa No</b>
Tablo 3.1 Farklı Kırık Tespiti ve Sınıflandırılması Konusunda Önceki Çalışmalar .....	25
Tablo 3.2 Proksimal Femur Kırığı ile İlgili Önceki Çalışmalar .....	36
Tablo 4.1 Veri Toplama.....	47
Tablo 4.2 Veri Kümesi Birleşimi .....	48
Tablo 5.1 YOLO Modelleri Eğitim Sonuçları.....	53
Tablo 5.2 YOLO Modellerinin Her Sınıf için Eğitim Metrik Sonuçları .....	53
Tablo 5.3 Mask R-CNN Modelleri Genel mAP Değerleri.....	58
Tablo 5.4 Mask R-CNN'nin Tüm Kategoriler Üzerindeki mAP Değerleri.....	59
Tablo 5.5 PointRend Eğitimi mAP Değerleri.....	63
Tablo 6.1 Model Karşılaştırmaları.....	68

## KISALTMA LİSTESİ

<b>Kısaltmalar</b>	<b>Açıklama</b>
<b>AUC</b>	: Eğri Altındaki Alan
<b>AUPRC</b>	: Hassas Geri Çağırma Eğrisinin Altındaki Alan
<b>AUROC</b>	: Alıcı Çalışma Karakteristik Eğrisi Altındaki Alan
<b>CNN</b>	: Evrişimli Sinir Ağı
<b>CT</b>	: Bilgisayarlı Tomografi
<b>CV</b>	: Bilgisayarlı Görü
<b>DICOM</b>	: Tıpta Dijital Görünteleme ve İşleme
<b>DCNN</b>	: Derin Evrişimli Sinir Ağı
<b>DL</b>	: Derin Öğrenme
<b>Fast R-CNN</b>	: Hızlı Bölge Evrişimli Sinir Ağı
<b>Faster R-CNN</b>	: Daha Hızlı Bölge Evrişimli Sinir Ağı
<b>FPN</b>	: Özellik Piramit Ağı
<b>GAN</b>	: Üretken Genişmeli Ağlar
<b>Grad-CAM</b>	: Gradyan Ağırlıklı Sınıf Aktivasyon Haritalandırması
<b>mAP</b>	: Mean Average Precision
<b>Mask R-CNN</b>	: Maske Bölge Evrişimli Sinir Ağı
<b>ML</b>	: Makine Öğrenmesi
<b>MRI</b>	: Manyetik Rezonans Görüntüleme
<b>NMS</b>	: Maksimum Olmayan Bastırma
<b>NoFF</b>	: Femur Boyun Kırıkları
<b>PXR</b>	: Pelvik X-ışını
<b>R-CNN</b>	: Bölge Evrişimli Sinir Ağı
<b>ROI</b>	: İlgi Bölgesi
<b>VGG</b>	: Görsel Geometri Grubu Algoritması
<b>YOLO</b>	: You Only Look Once

## ÖZET

### [YÜKSEK LİSANS TEZİ]

#### [DERİN ÖĞRENME ile PROKSİMAL FEMUR KIRIKLARININ TESPİTİ ve SINIFLANDIRILMASI]

[Assma HIJAZI]

**İstanbul Üniversitesi-Cerrahpaşa**

**Lisansüstü Eğitim Enstitüsü**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı**

**[Danışman: Doç. Dr. Derya YILTAŞ KAPLAN ]**

Proksimal femur kırıkları ve çıkıkları, doğru ve gerçek zamanlı tanı konulmadığı takdirde yaşlı hastalarda daha sık görülen mortaliteye, genç erişkin hastalarda ise topallamaya, çalışamamaya, spor yapamamaya yol açabildiği için en ciddi kırıklardan biridir. Yapay zekâ ve alt kategorileri olan makine öğrenmesi ve derin öğrenme, doktorların hastalıkları doğru ve zamanında teşhis etmelerini sağlamak amacıyla sağlık uygulamalarıyla birleştirildiğinde ortaya güzel sonuçlar çıkarmaktadır.

Bu tezin temel amacı, poligon açıklamasıyla örnek segmentasyon görevini kullanarak çeşitli proksimal femur kırık türlerini X-ışını/röntgen üzerinde tespit etmektir.

Bu tez çalışması için 756 adet X-ışını görüntüsünden oluşan bir veri seti kullanılmıştır. Bir danışman ve uzman ortopedi doktorunun gözetiminde örnek segmentasyon görevini gerçekleştirmek için görüntülere çokgen ek açıklaması kullanılarak manuel olarak açıklama eklendi. Veri setine açıklama eklemek için kullanılan etiketler kırık tipi (boyun, çıkık, büyük-trokanter, küçük-trokanter, intertrokanterik ve subtroknaterik) ve kırığı olmayanlar ile normaldi. Veri seti, eğitim için %70 ve doğrulama için %30'a bölündü. Modellerin performansını test etmek için modeller, X-ışını görüntülerinden önce görünmez olarak

verilmiştirlerdir. Örnek segmentasyon görevini gerçekleştirmek için kullanılan modeller YOLOv5, YOLOv7, YOLOv8, Mask R-CNN (Detectron2) ve PointRend'dir.

Sonuçlara göre, beş modelin tümü proksimal femur kırığının varlığını tespit edebildi ve sınıflandırabildi. Kutular için 0.5 (mAP50) olan Birleşim Üzerinden Kesişim (IoU) eşliğinin Ortalama Ortalama Tahmin (mAP) değerleri, sırasıyla YOLOv5, YOLOv7, YOLOv8, Mask R-CNN (Model3) ve PointRend (Model4) için %79.5, %79.2, %81.6, %73.82 ve %73.67 olarak bulunmuştur. Maskeler için 0.5 (mAP50) olan Birleşim Üzerinden Kesişim (IoU) Ortalama Tahmin değerleri sırasıyla YOLOv5, YOLOv7, YOLOv8, Mask R-CNN (Model3) ve PointRend (Model4) için %80, %78.8, %81.7, %74.05 ve %74.85 olarak bulunmuştur.

Ocak 2024, 100 sayfa.

**Anahtar kelimeler:** YOLO, Mask R-CNN, PointRend, Örnek Segmentasyonu, Poligon Açıklaması, Proksimal Femur Kırıkları, Evrişimli Sinir Ağları, Bilgisayarla Görme

## **ABSTRACT**

**[M.Sc. THESIS]**

**[PROXIMAL FEMORAL FRACTURES DETECTION and CLASSIFICATION USING  
DEEP LEARNING ]**

**[Assma HIJAZI]**

**İstanbul University-Cerrahpaşa**

**Institute of Graduate Studies**

**Department of Computer Engineering**

**Computer Engineering Master's Program with Thesis**

**[Supervisor: Assoc. Prof. Dr. Derya YILTAŞ KAPLAN ]**

Proximal femur fractures and dislocation are one of the most serious fractures as they can lead to mortality which are more common in elderly patients, and to limping, inability to work, to practice sport activity in young adults patients if not diagnosed accurately and in real time. Artificial intelligence and its sub-categories, machine learning and deep learning shows a great work when merged in healthcare applications in sustaining doctors to diagnose the diseases accurately and timely.

The main objective of this thesis is to detect the various proximal femur fractures types on x-rays using the instance segmentation task with the polygon annotation.

For this thesis, a dataset of 756 X-ray images was used. The images were manually annotated using polygon annotation in order to perform the instance segmentation task with the supervision of a consultant and specialist orthopedic doctor. The labels used to annotate the dataset were related to the fracture type (neck, dislocation, greater-trochanter, lesser trochanter, intertrochanteric and subtrochanteric) and normal the ones without any fracture. The dataset

was splitted into 70% for training and 30% for validation. In order to test the models performance, the models were given unseen before X-ray images. The models used in order to perform the instance segmentation task were YOLOv5, YOLOv7, YOLOv8, Mask R-CNN (Detectron2) and PointRend.

According the results, all five models were able to detect the presence of a proximal femur fracture and classify it. The Mean Average Prediction (mAP) values of Intersection over Union (IoU) threshold of 0.5 (mAP50) for boxes were 79.5%, 79.2%, 81.6%, 73.82% and 73.67% for YOLOv5, YOLOv7, YOLOv8, Mask R-CNN (Model3) and PointRend (Model4) respectively. While, the Mean Average Prediction values of Intersection over Union (IoU) threshold of 0.5 (mAP50) for masks were 80%, 78.8%, 81.7%, 74.05% and 74.85 for YOLOv5, YOLOv7, YOLOv8, Mask R-CNN (Model3) and PointRend (Model4) respectively.

January 2024, [100] pages.

**Keywords:** [YOLO, Mask R-CNN, PointRend, Instance Segmentation, Polygon Annotation, Proximal Femur Fractures, Convolutional Neural Networks, Computer Vision]

# 1. GİRİŞ

## 1.1. SORUN BİLDİRİMİ

Proksimal femur kırıkları, 65 yaş üstü nüfusta sık görülen ve yaşam kalitesini olumsuz şekilde etkileyen ciddi yaralanmalardır. Yüksek mortalite ve morbidite oranı (%30'a varan bir yıllık ölüm oranı), erken ve doğru teşhisin hayati önem taşıdığını göstermektedir. Bu kırıkların tanısı, karmaşık anatomileri ve ince farklılıklar nedeniyle deneyimli ortopedist ve radyologlar tarafından yapılması gereken zorlu bir süreçtir.

Proksimal femur kırıkları, genellikle femur boynu, başı ve trokanterler arası bölgede görülür. Tanı süreci, detaylı anamnez, fizik muayene ve röntgenin birlikte ele alınmasıyla gerçekleşir. Ancak, bazı durumlarda ince kırık hatları veya tam olmayan kırıklar röntgende net olarak görüntülenmeyebilir. Bu durum, deneyimli doktorların bile tanıyı gözden kaçırmaya yol açabilmektedir. İşte tam da bu noktada, bilgisayarlı tomografi (Computed Tomography, CT), manyetik rezonans görüntüleme (Magnetic Resonance Imaging, MRI) veya kemik taraması devreye girmektedir. Ancak, bu ileri tetkiklerin her hastanede mevcut olmaması ve maliyetlerinin yüksek olması, tanı sürecini geciktirebilir ve toplam tedavi masrafını artırabilir [1].

Proksimal femur kırıklarında yanlış tanı, tanıya veya tedaviye gecikme, sağlık açısından son derece ciddi sonuçlara yol açabilir. Bunlardan biri de avasküler nekroz, yani osteonekroz olarak bilinen, kemiğe kan akışının geçici veya kalıcı olarak kaybı durumudur. Avasküler nekroz, kemik dokusunun ölmesine ve erken osteoartrit kadar ilerleyen kemik çökmesine yol açar. Bu tür kırıklar her yaşta meydana gelebilse de yaşlılarda genç yetişkinlere kıyasla daha sık görülür. Yaşlılarda, kalça kemiğinin üst ucunda kırıklar genellikle düşük enerjili travmalar, yani basit düşmeler sonucu ortaya çıkar. Bunun nedeni, yaşla birlikte kemik yoğunluğunun azalması (osteoporoz), patolojik kırıklar (kemik kanseri) veya birden fazla sağlık sorununun varlığıdır. Genç yetişkinlerde ise yüksek enerjili travmalar, örneğin trafik kazaları, patlamalar veya yüksekten düşmeler sonucu proximal femur kırıkları meydana gelir [2-4]. Yaşlı hastalarda bu kırıkların ölümcül olabileceğini, genç veya yetişkin hastalarda ise

topallamaya, çalışma, spor yapma yetisini kaybetmeye ve dolayısıyla normal bir yaşam sürmeye engel olabileceğini unutmamak gerekir.

## 1.2. MOTİVASYON

Yapay zekânın alt alanları olan makine öğrenmesi (Machine Learning, ML) ve derin öğrenmenin (Deep Learning, DL) hızlı gelişimi, makinelerin insan performansına ulaşmada ne denli başarılı olabileceğini göstermiştir. Bilgisayarlı Görü (Computer Vision, CV) ve Konuşma Tanıma gibi uygulamalarda algı, makineler için hâlâ büyük bir meydan okuma olsa da bu teknolojiler sayısız alanı etkilemiş ve geliştirmiştir. Tıp, özellikle de tıbbi görüntüleme alanı ise bu teknolojilerden en çok etkilenenlerden biridir. CV tekniklerinin tıbbi görüntülemede kullanılması, tıbbi görüntüleri sınıflandırma, segmentasyon, anormal objeleri yerleştirme ve tespit etme konularında önemli bir rol oynamıştır. Acil servis ve ortopedi bölümlerinde, kırıkların varlığını tespit etmek amacıyla CV algoritmaları ve teknikleri kullanılmaya başlanmıştır. Proksimal femur kırığı ve çıkık ciddi bir sağlık sorunu olup ölümcül olabileceğinden ve bu konuda yapılan araştırmaların sayısı sınırlı olduğundan, bu tezde bu kırıkların ve çıkıkların tespiti için farklı CV teknikleri kullanılacaktır.

## 1.3. TEZ ORGANİZASYONU

Tezin diğer bölümleri aşağıdaki gibi düzenlenmiştir:

**Bölüm 2:** Bu bölümde kemiklerin anatomileri, işlevleri ve sınıflandırılması hakkında küçük bir genel bakış tartışılmaktadır. Daha sonra proksimal femur kırığı tipleri ve çıkığı tanımlanır. Son olarak, tıbbi görüntüleme türlerine genel bir bakış sunulmaktadır.

**Bölüm 3:** Bu bölümde, farklı kemik kırıklarının saptanması ve sınıflandırılması konusunu ele alan daha önceki araştırmalar tartışılmaktadır.

**Bölüm 4:** Bu bölümde, örnek segmentasyon görevlerini gerçekleştirmek için kullanılan Evrişimli Sinir Ağları (Convolutional Neural Networks, CNN) modelleri ve bunları değerlendirmek için kullanılan performans değerlendirme ölçümleri sunulmaktadır. Ayrıca, kullanılan veri seti, uygulanan ön işleme ve büyütme teknikleri hakkında bir açıklama sunulmaktadır.

**Bölüm 5:** Bu bölümde, kullanılan farklı modellerin deneysel sonuçları sunulmakta ve karşılaştırılmaktadır.

**Bölüm 6:** Bu bölümde elde edilen sonuçlar tartışılmaktadır.

**Bölüm 7:** Bu bölümde çalışmanın farklı tarafları açıklandıktan sonra gelecek çalışmalarla ilgili fikirler sunulmaktadır.



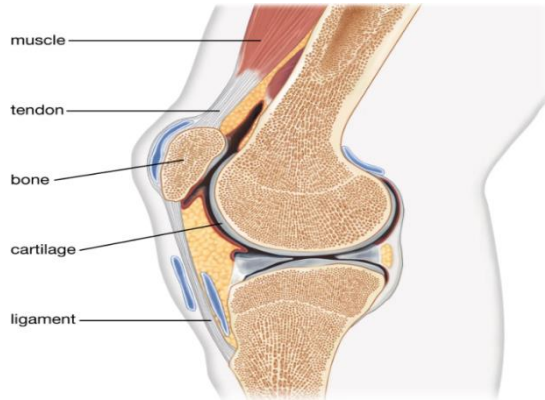
## 2. KEMİKLER, PROKSİMAL FEMUR KIRIĞI VE KALÇA ÇIKIĞI

Bu bölümde kemiklerin işlevleri, yapıları, anatomileri ve sınıflandırılması hakkında genel bir bakış sunulmaktadır. Daha sonra proksimal femur kırıkları ve kalça çıkığı tanımlanmaktadır. Son olarak, ortopedi tarafından bir kırığın mevcut olup olmadığını anlamak için kullanılan görüntü türleri hakkında kısa bir açıklama sunulmaktadır.

### 2.1. KEMİKLER

#### 2.1.1. Kemik İşlevi

İskelet sistemi, toplam vücut ağırlığının %15-20'sini oluşturduğu için vücuttaki muazzam organlardan/sistemlerden biridir [5]. İnsan vücuduna içsel bir çerçeve görevi görür. İskelet sistemi kemikler, eklemler<sup>1</sup>, kıkırdaklar<sup>2</sup>, bağlar<sup>3</sup> ve tendonlar<sup>4</sup> olmak üzere beş ana bölümden oluşur (Şekil 2.1).



**Şekil 2.1** İskelet Sistemi Parçaları

Bir iskelet sisteminin ana bölümünü temsil eden bir diyagram [6].

<sup>1</sup> İki veya daha fazla kemiğin birleştiği bölge.

<sup>2</sup> Eklemleri koruyan güçlü, yumuşak ve esnek bir doku.

<sup>3</sup> İki kemiği birbirine bağlayan elastik bir bant.

<sup>4</sup> Kasları kemiklere bağlayan bir doku bandı.

Kemikler iskelet sisteminin en temel yapısıdır, aslında bir insan iskeleti bebeklerde yaklaşık 270 kemikten oluşur ve gelişim sırasında kaynaşarak yetişkinlerde 206-213 kemiğe dönüşür. Kemikler sert, yoğun ve bağ dokularıdır. Uzun zamandır cansız statik bir yapı olarak kabul edildiler, fakat tam aksine, canlı dokularıdır [7]. Değerli işlevlerinden dolayı organ olarak kabul edilirler. Kemikler, insan vücudunu desteklemede ve şekil vermede, hareketleri kolaylaştırmada, iç hayati organları korumada, ilikte çeşitli hücrelerin (kırmızı kan hücreleri, beyaz kan hücreleri ve trombositler gibi) üretilmesinde çok önemli bir rol oynar ve kalsiyum ve fosfat gibi minerallerin depolanması için bir depo görevi görür [5,7].

### 2.1.2. Kemik Yapısı ve Anatomisi

Kemikler, %60 anorganik malzemeler, %30 organik malzemeler ve %10 su içermektedir. Kolajen, kemikte başlıca organik bileşendir ve mineraller (hidroksiapatit), başlıca anorganik bileşeni oluştururlar [8]. Organik bileşenler kemiklere esneklik kazandırırken, anorganik bileşenler kemiklere sertlik sağlar.

Kemikler üç tip hücreden oluşur: osteoblastlar, osteositler ve osteoklastlar [9,10].

- **Osteoblast** hücreleri, ilk kemik gelişimi sırasında ve daha sonraki kemik yeniden yapılandırma/şekillenme sürecinde kemik sentezi ve mineralizasyonunu yöneten büyük hücrelerdir. Bunlar, kemiklerin dış yüzeyini kaplayan periosteum ve iliğin boşluğundaki endosteum içindeki osteojenik hücrelerin farklılaşmasıyla oluşurlar.
- **Osteoklast** hücreleri, yaşlanmış kemikleri emme ve parçalama görevinden sorumlu olan hücrelerdir.
- **Osteositler**, kemikteki hücrelerin çoğunu oluşturan olgun kemik hücreleridir. Osteogenez sırasında osteoidi depolar ve mineralize olmuş kemik matrisine gömülerek osteositlere dönüşürler. Kemiklerin en yaygın hücresel bileşeni olmalarına rağmen, osteoblasttan osteosite geçiş süreci hakkında pek az bilgi bulunmaktadır.

Osteoblastlar ve osteoklastlar arasındaki denge kemik dokusunu destekler. Rezorpsiyon ve oluşum fizyolojik koşullarda stabildir, dengesizlik ise osteoporoz gibi hastalıklara neden olabilir [11].

Her kemik üç ana dokudan oluşur (Şekil 2.2). Periosteum, kemiğin dış tabakasıdır; bağ ve tendonların tutunduğu bölgeler ve kıkırdak ile kaplı bölge dışında kemiğin tüm yüzeyini kaplayan sert bir zardır [12].

Vücudumuzun iskelet sisteminin önemli yapı taşlarından olan kemikler, aslında iki farklı tarzda örgütlenen dokudan oluşur: kompakt ve süngerimsi kemik. Bu iki doku, aynı hayati görevi yerine getirirse de yapısal özellikleri bakımından birbirinden ayrılır.

### **1. Kompakt Kemik:**

**Kalın ve yoğun:** Adından da anlaşılacağı gibi, kompakt kemik sert ve dayanıklıdır. Bony matris adı verilen temel yapısı, hem organik hem de inorganik bileşenlerle sıkıca örülüdür. Bu sıkı örneğin içinde osteosit adı verilen kemik hücreleri için yalnızca küçük boşluklar bulunur.

**Dayanak noktası:** Kompakt kemik, uzun kemiklerin diyafiz dediğimiz ana shaftını oluşturarak iskelete sağlamlık ve rijitlik kazandırır. Kaslar da bu sert dokuya bağlanarak vücudumuzu hareket ettirir.

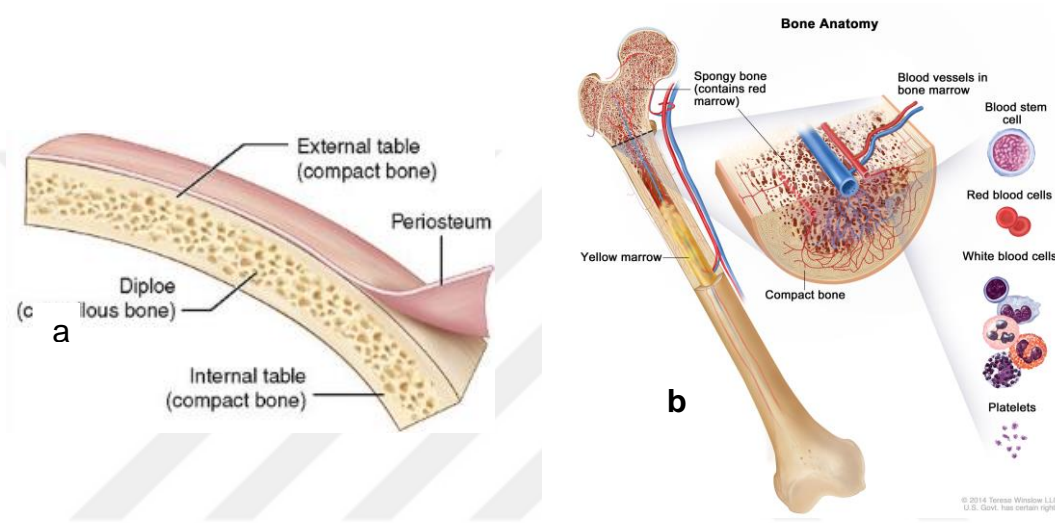
### **2. Süngerimsi Kemik:**

**Hafif ve gözenekli:** Spongy bone olarak da bilinen süngerimsi kemik, adından da anlaşılacağı üzere adeta bir bal peteği gibi görünür. Büyük ve birbirine bağlı boşluklar içeren yapısı, bu dokuya hafiflik ve esneklik verir. Boşluklarda genellikle kemik iliği ve kan damarları bulunur, bu nedenle süngerimsi kemik oldukça damarlıdır.

**Stratejik konumlanma:** Uzun kemiklerin uçlarında (epifiz) bulunan süngerimsi kemik, daha dışta yer alan kompakt kemik tarafından çevrelenir. Bu yerleşim, bir yandan dayanıklılık sağlar, bir yandan da kemiğin hafif kalmasına yardımcı olur.

Sonuç olarak, kompakt ve süngerimsi kemik, birbirini tamamlayan ikili bir güç oluşturarak vücudun ihtiyaçlarına uyum sağlar. Kompakt kemik, yapısıyla sağlamlık ve destek verirken, süngerimsi kemik hafifliği ve kan damarlarındaki zenginlik sayesinde kemiğin canlılığını ve yenilenmesini destekler. Bu muhteşem düzen, bizi ayakta tutan ve hareket ettiren iskelet sisteminin yapı taşlarını oluşturur [1].

Kemik iliği, çoğu kemiğin ortasında bulunan birçok kan damarına sahip yumuşak, süngerimsi bir madde olarak tanımlanabilir. Kemik iliği iki çeşittir: kırmızı ve sarı. Kırmızı kemik iliğindeki kan kök hücreleri, kırmızı kan hücrelerine, beyaz kan hücrelerine veya trombositlere dönüşebilir. Sarı kemik iliği esas olarak yağdır ve kıkırdak, yağ veya kemik hücrelerine farklılaşabilen kök hücreleri tutar [13].



**Şekil 2.2** Kemik Anatomisi


- a. Kemiği oluşturan farklı dokuları gösteren düz bir kemiğin bir bölümü: periost, süngerimsi kemik ve kompakt kemik [14].
- b. Bir kemiğin anatomisini gösteren uzun bir kemiğin temsili [13].

### 2.1.3. Kemik Sınıflandırması

Kemikler iskelet içindeki konumlarına göre veya şekillerine göre sınıflandırılabilir.

#### 2.1.3.1. Konuma Göre

İnsan iskeleti, aksiyal ve apendiküler iskelet olmak üzere iki ana bölüme ayrılır. Aksiyal iskelet, vücudun dikey, merkezi eksenini oluşturur. Kafatası, omurga ve göğüs kafesini içerir [15]. Apendiküler iskelet, merkezi eksene eklenmiş kemiklerden oluşur; üst ve alt ekstremiteler ile pelvik kuşağı içerir (Şekil 2.3).



**Şekil 2.3** Konuma Göre Kemik Sınıflandırması


Eksenel ve apendiküler iskeleti gösteren bir diyagram [16].

### 2.1.3.2. Şekle göre

Kemikler, kendi farklı işlevlerini yerine getirmek için şekilleri, boyutları ve güçleri bakımından farklılık gösterir. Kemikler şekillerine göre uzun, kısa, düz, düzensiz ve sesamoid olarak sınıflandırılır (Şekil 2.4).

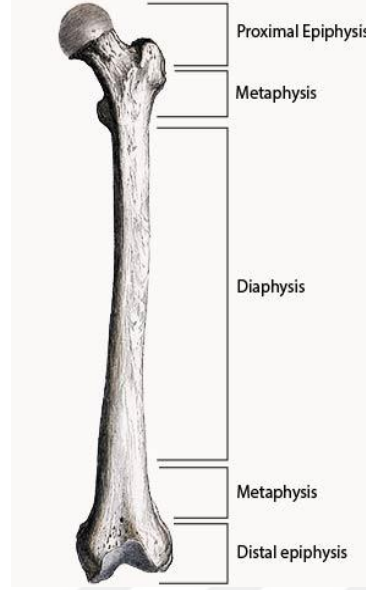
- **Uzun kemikler**, adından da anlaşılacağı gibi, genişliğinden daha uzundur. Üst (humerus, ulna, radius) ve alt ekstremitelerde (femur, tibia, fibula) bulunurlar [17]. Birden fazla benzersiz anatomik bölgeye sahiptirler. Diyafiz veya shaft, epifiz veya uçlar ve metafiz veya ikisi arasındaki alan, uzun bir kemiğin üç bölgesidir (Şekil 2.5). Diyafiz, kemik iliğini içeren kemik medullasını tutar. İlik, kırmızı hücreleri, beyaz hücreleri ve trombositleri üreten ana dokudur. Epifiz, genellikle artikülasyondan sorumlu olan uzun kemiğin terminal ucudur. Aynı zamanda uzun kemiklerde kırmızı kemik iliğinin ana kaynağı olarak hizmet eder ve kırmızı hücre üretimine izin verir. Birleşim noktasına yakın olan epifiz "Proksimal" olarak adlandırılırken, birleşim noktasından daha uzak veya uzakta olanı "Distal" olarak adlandırılır.
- **Kısa kemikler** küp şeklindedir ve neredeyse eşit boyuttadır. Bu tür kemikler ellerde ve ayaklarda bulunur. **Yassı kemikler**, adından da anlaşılacağı gibi, **Düz**, plaka benzeri şekilli, ince ve geniş kemiklerdir. Kafatası, kürek kemikleri, göğüs kemiği ve kaburga kemikleri bu kategoriye girer.

- **Düzensiz kemikler**, adından da anlaşılacağı gibi, net bir şekilde tanımlanmış bir forma sahip olmayan ve karmaşık bir yapıya sahip olan kemiklerdir. Düzensiz kemiklere örnek olarak omurlar, sakrum, kuyruk sokumu ve toplam yüz kemikleri verilebilir.
- **Sesamoid kemikler**, tendonlarda yerleştirilmiş küçük ve yuvarlak kemiklerdir. Patella, bu kategorinin bir örneğidir.



**Şekil 2.4** Şekle Göre Kemik Sınıflandırması

Farklı kemik türlerini gösteren bir diyagram: uzun, kısa, düz, düzensiz ve sesamoid [18].




**Şekil 2.5** Uzun Kemik Ana Parçaları

Üç ana bölümünü gösteren uzun bir kemiğin diyagramı: epifiz, metafiz ve diyafiz [19].

## 2.2. PROKSİMAL FEMUR KIRIĞI VE KALÇA ÇIKIĞI

Femur, insan vücudunun kalçadan dize kadar uzanan en uzun ve en güçlü kemiğidir. Uyluğun iskelet yapısını oluşturur. Kalça ve uyluk kaslarının geniş kısmı, bu eklemlerde hareket sağlamak için uyluk kemiğine bağlanır. Proksimal, şaft ve distal olmak üzere üç ana bölümden oluşur (Şekil 2.6).

- *Proksimal kısım* , kalça kemiği (asetabulum) ile eklemlenen, top ve soket eklemine (kalça eklemi) oluşturan uyluk kemiğinin üst kısmıdır. Baş, boyun, büyük trokanter, küçük trokanter ve intertrokanterik alandan oluşur.
- *Şaft kısmı* femurun uzun orta noktasıdır.
- *Distal kısım* , diz eklemlerini oluşturan tibia ve patella ile eklemlendiği femurun alt kısmıdır.



**Şekil 2.6** Femur kemiği Ana Parçaları

Femur kemiğinin çeşitli kısımlarını gösteren diyagramı [20].

Proksimal kırıklar, uyluk kemiğinin proksimal kısmında meydana gelen kırıklardır ve kalça bölgesinde meydana geldikleri için bir tür kalça kırığı olarak kabul edilirler. Her yaşta ortaya çıkabilirler, ancak yaşlılarda gençlere göre daha yaygındır ve çocuklarda nadirdir. Kadınlarda erkeklere göre daha yaygındır, kadınlarda %18 ve erkeklerde %6 [20]. Yaşlılarda proksimal femur kırıkları, yürürken basit bir düşme, zayıf kemik yoğunluğundan kaynaklanan kemik yaralanmaları (osteoporoz), patolojik kırıklar (kemik kanseri) veya tıbbi durumların bir kombinasyonu gibi düşük enerjili travmalardan kaynaklanır. Genç yetişkinlerde ise yüksek enerjili travmalar, örneğin trafik kazaları, patlamalar veya yüksekten düşmeler neden olur. Çalışmalar, bu kırıkların %90'ının yüksek enerjili travmanın sonucu olduğunu ve sadece %10'unun düşük enerjili travmaya bağlı olduğunu göstermektedir [21]. Bu kırıkların oluşumu yaşlı hastalarda morbidite ve mortalitenin önemli bir nedenidir ve 1 yıl içinde mortalite oranı %14-%36 arasındadır [22]. Ayrıca, bunlar bağımsızlık kaybının ve sakatlığın başlıca nedenlerinden biridir; sadece hastaların yüzde 50'si proksimal kırıklardan sonra bağımsız yaşayabilir.

Genellikle kalça kapsülü ile ilişkilerine göre intrakapsüler ve ekstrakapsüler kırıklar olarak sınıflandırılırlar. İntrakapsüler kırıklar femur başı ve femur boyun kırıklarını kapsar. Ekstrakapsüler kırıklar ise intertrokanterik ve subtrokanterik alan kırıklarını kapsar [23-24].

Femur boyun kırıkları ve intertrokanterik kırıklar proksimal femurda en sık görülen kırıklardır. Proksimal femur kırıklarının %90-95'ini oluştururlar [25]. Aksine, femur başındaki kırıklar nadirdir. Femur başı ile ilgili olan ve sıklıkla görülen yaygın bir yaralanma kalça çıkığıdır.

Proksimal kırıklar veya kalça çıkıkları, yakındaki kan damarlarında, sinirlerde, kaslarda, bağlarda ve diğer yumuşak dokularda yırtılmalara veya gerilmelere neden olabilir. Avasküler nekroz (kemik ölümü), kalça kırıklarının veya kalça çıkıklarının en yıkıcı sonucudur. Avasküler nekroz, kemik dokusu ölümüne ve tüm eklem çökmesine neden olur [26].



**Şekil 2.7** Proksimal Femur Kırığı ve Dislokasyon Röntgenleri

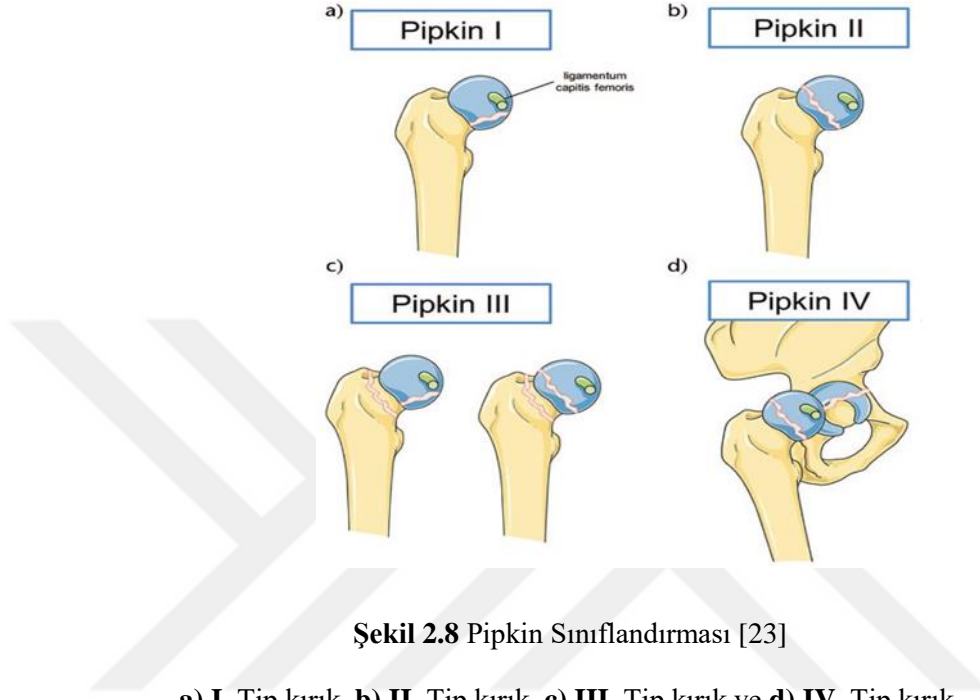
A. Sağ Femur Boyun Kırığı. B. Sağ İntertrokanterik Kırık. C. Sol kalça çıkığı.

### 2.2.1. Femur Başı Kırığı

Bu tür kırıklar nadir görülen kırıklardır ancak genellikle yüksek enerjili travmalara bağlı olarak çıkma sonucu ortaya çıkarlar; bu tür travmalar arasında motorlu araç çarpışmaları, yüksekten düşmeler, spor yaralanmaları, endüstriyel kazalar veya düşük enerjili düşmeler bulunmaktadır. Femur başı kırıklarını sınıflandırmak için kullanılan en önemli sınıflandırma Pipkin sınıflandırmasıdır. Pipkin sınıflandırması, kırığın konumuna ve ilişkili kırıkların olup olmadığına dayanmaktadır. Bu sınıflandırma, Femur başı kırıklarını dört tip olarak sınıflandırır: (Şekil 2.8):

- Tip I: Femur başı kırığı fovea kapititten daha düşüktür.


- Tip II: Femur başı kırığı fovea kapititten daha üst sıralarda yer alır.
- Tip III: Femur boyun kırığı ile ilişkili Tip I veya Tip II kırık.
- Tip IV: Asetabular kırık ile ilişkili Tip I veya Tip II kırık.



a) I. Tip kırık, b) II. Tip kırık, c) III. Tip kırık ve d) IV. Tip kırık.

### 2.2.2. Femur Boyun Kırığı

Bu tür kırıklar proksimal femurda en sık görülenlerdir, çünkü boyun femurun en zayıf kısmı olarak kabul edilir. Kemik yoğunluğu daha zayıf olan genç erişkinlere göre yaşlılarda görülürler.



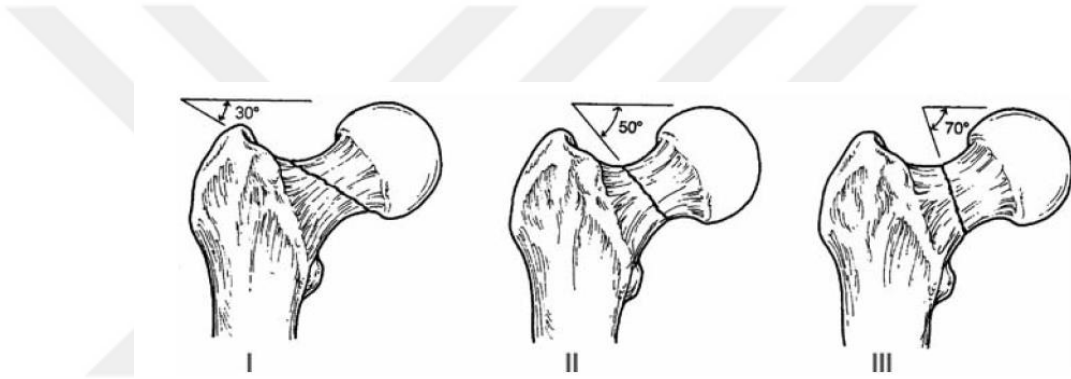
**Şekil 2.9** Boyun Kırığı Röntgeni

a. Sağ Femur Boyun Kırığı. b. Sol Femur Boyun Kırığı.

Femur boyun kırıklarını tanımlamak veya kategorize etmek için kullanılan birçok sınıflandırma vardır.

**Pauwels Sınıflandırması** (Şekil 2.10), fizyolojik olarak genç hastalarda yüksek enerjili femur boyun kırıkları için en yaygın kullanılan sınıflandırma [27]. Bu sınıflandırma, kırıkları yatay düzlemden kırılma açısına göre üç tipe sınıflandırır:

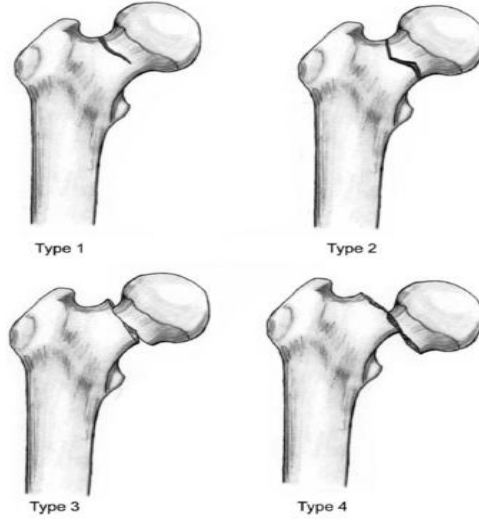
- Tip I:  $< 30^\circ$
- Tip II:  $30^\circ - 50^\circ$
- Tip III:  $> 50^\circ$



Şekil 2.10 Pauwels Sınıflandırması [28]

**Garden sınıflaması** (Şekil 2.11) yaşlı kalça kırıkları için en yaygın kullanılan sınıflandırma [27]. Bu sınıflandırma, kırığın tamlığına ve yer değiştirmesine bağlı olarak kırıkları dört tipe sınıflandırır.


- Tip I: eksik kırık ve yer değiştirme yok.
- Tip II: tam kırık ve yer değiştirme yok.
- Tip III: tam kırık ve kısmi yer değiştirme.
- Tip IV: tam kırık ve tam yer değiştirme.



Şekil 2.11 Garden Sınıflandırması [29]

### 2.2.3. İntertrokanterik Kırık

İntertrokanterik kırıklar, femur boynu ile küçük trokanter arasında meydana gelen kırıklardır [27]. Osteoporoz nedeniyle yaşlılarda ve 60 yaş üstü kadınlarda daha fazla görülür [22]. Diğer proksimal kırıklar gibi, İntertrokanterik kırıklar da bir düşmenin sonucudur.




Şekil 2.12 İntertrokanterik Kırık Röntgeni

a. Sol İntertrokanterik Kırık b. Sağ İntertrokanterik Kırık

İntertrokanterik kırıkları sınıflandırmak için Evans sınıflandırması kullanılır. Evans [30] sınıflandırması, İntertrokanterik femur kırıklarını üç ana gözleme göre sınıflandırır: yer değiştirme, parça sayısı ve yer değiştiren parça türü (Şekil 2.13).

1. Tip I: kırıklar iki kısımdır.
  - 1.1. A Grubu: Yer deęiřtirmemiş kırıklar
  - 1.2. B Grubu: Yer deęiřtirmiş kırıklar
2. Tip II: kırıklar üç bölümdür.
  - 2.1. A Grubu: belirgin bir BÜYÜK trokanter parçası ile
  - 2.2. B Grubu: KÜÇÜK trokanter parçası ile
3. Tip III: kırıklar dört bölümdür.



Şekil 2.13 Evans Sınıflandırması

#### 2.2.4. AO/OTA Sınıflandırması

AO/OTA sınıflandırma sistemi, kırıkları sınıflandırmak için yaygın olarak kullanılan bir sistemdir. Arbeitsgemeinschaft für Osteosynthesefragen (AO) tarafından geliştirilmiş ve daha sonra Ortopedik Travma Derneęi (OTA) tarafından revize edilmiştir.

Proksimal femur kırıkları AO/OTA sınıflandırma sistemine göre řu řekilde sınıflandırılır:

- Tip A: İntertrokanterik kırıklar.
- Tip B: Femur boyun kırıkları.
- Tip C: Femur başı kırıkları.

Bu tiplerin her biri, kırığın spesifik özelliklerine göre alt tiplere ayrılır.

### 2.2.5. Kalça Çıkığı

Kalça çıkığı, kalça eklemine topu yuvasından dışarı zorlandığında ortaya çıkar. Kalça eklemi stabilite ve geniş bir hareket aralığı sağlamak için tasarlanmıştır, ancak önemli bir kuvvet veya travma femur başını normal konumundan uzaklaştırabilir. Çıkık bir kalça, özellikle şiddetliyse, erken teşhis edilmezse ve meydana geldikten sonraki saatler içinde uygun şekilde tedavi edilmezse, ciddi uzun süreli sakatlık (düzgün yürüyememe veya hareket edememe) zorluklarına neden olabilir.

Çıkıklar, kırığın varlığına veya yokluğuna bağlı olarak basit veya karmaşık olarak kategorize edilir. Ayrıca, kalça çıkıkları femur başının pozisyonuna göre şu şekilde sınıflandırılabilir:

**Posterior çıkık** [13, 31-32], femur başının geriye doğru ve yuvadan dışarı itilmesidir, genellikle kalça bükülürken dizin ön tarafına kuvvetli bir darbe veya travma nedeniyle ve sıklıkla kırıklarla ilişkilidir. Bu, kalça çıkıklarının %90'ını oluşturan en yaygın çıkık modelidir. Motorlu taşıt kazaları ve yüksekten düşmeler yaygın nedenlerdir.

**Anterior çıkık** [13, 31-32], femur başının öne doğru ve yuvadan dışarı doğru hareket etmesidir. Daha az yaygındır ve genellikle kalça bükülürken güçlü bir darbe uyluğu geriye doğru ittiğinde olur. Posterior çıkıklardan farklı olarak, anterior çıkıklar çoğunlukla izole yaralanmalardır. Anterior çıkıklar inferior (obturator) çıkık ve superior (iliak veya pubik) çıkık olmak üzere iki tipe ayrılır.

Kalça çıkıkları, motorlu taşıt çarpışmaları, önemli bir yükseklikten düşme veya spor yaparken çarpışmalardan kaynaklanabilir [31].



**Şekil 2.14** Çıkık X-ışınları

**a.** Sağ taraf çıkığı **b.** ve **c.** Sol çıkık.

### 2.3. TIBBİ GÖRÜNTÜLER İLE PROKSİMAL FEMUR KIRIKLARININ VE KALÇA ÇIKIKLARININ TESPİTİ

Tıbbi görüntüleme, hemen görülemeyen hastalıkları ve anormallikleri tespit etmek için insan iç vücudunu görüntülemek için X-ışını/Röntgen, CT taraması ve MRI gibi teknolojilerin kullanılması işlemidir [33-34]. Klinisyenlere tıbbi durumların teşhisi, izlenmesi, tedavisi ve cerrahi planlamada yardımcı olmada çok önemli bir rol oynarlar. Proksimal kırıkları ve kalça çıkığını teşhis etmek için röntgen, CT taraması ve MRI kullanılır. Her mekanizmanın kısa bir açıklaması aşağıda sunulmuştur.


#### 2.3.1. Röntgen (Radyografi)

X-ışını, hızlı uygulanması ve geniş kullanılabilirliği nedeniyle kırıklar, tümörler ve enfeksiyonlar gibi çeşitli durumları teşhis etmek ve tedavi etmek için yaygın olarak kullanılan tıbbi görüntüleme biçimleridir. Hızlı, ağrısız ve invaziv olmayan bir yöntemdir.

X-ışınları Alman fizikçi Wilhelm Konrad Röntgen tarafından keşfedildi. Bunlar, 10-8 ile 10-12 metre arasında değişen son derece kısa dalga boyuna ve 106 ila 1020 Hertz arasında değişen karşılık gelen yüksek frekansa sahip bir elektromanyetik radyasyon biçimidir [35]. X-ışınları, vücuttan geçen ve vücudun iç yapılarının 2 boyutlu görüntülerini oluşturan az miktarda iyonlaştırıcı radyasyon kullanır.

X-ışınları vücuttaki farklı yapılar tarafından farklı şekilde emilir ve ortaya çıkan görüntü yapıları beyaz ve siyahın değişen tonları olarak gösterir. Kemikler ve akciğerler gibi yüksek yoğunluklu dokular, radyasyonu bloke ettikleri ve emdikleri için X-ışını görüntülerinde beyaz

renkte görünür. Öte yandan, kaslar, tendonlar, bağlar vb. gibi daha az yoğun dokular radyasyonu emmez, ancak gri tonlamalı renklerde görünmelerine izin verir [35-36].




Şekil 2.15 Röntgen/X-ışını [37]

### 2.3.2. Bilgisayarlı Tomografi (CT) Taraması

Bilgisayarlı Tomografi'nin kısaltması olan CT taraması, vücudun iç yapılarının 3D ayrıntılı bilgisayarlı 360 derecelik görüntülerini üretmek için X-ışınları ve bilgisayar teknolojisini kullanan tıbbi bir görüntüleme prosedürüdür [38-40].

CT taramaları özellikle beyin, göğüs, karın, pelvis ve iç organları görüntülemek için değerlidir ve tümörler, enfeksiyonlar ve kemik kırıkları dahil olmak üzere çok çeşitli durumların teşhisinde kullanılırlar [39].


X-ışınlarının aksine, CT taramaları daha pahalıdır ve kırsal veya küçük hastanelerde her zaman mevcut değildir.



Şekil 2.16 Bilgisayarlı Tomografi (CT) [41]

### 2.3.3. Manyetik Rezonans Görüntüleme (MRI)

Manyetik Rezonans Görüntüleme (MRI), vücudun iç yapılarının 3D ayrıntılı görüntülerini oluşturmak için güçlü bir manyetik alan, radyo dalgaları ve bilgisayar teknolojisi kullanan tıbbi bir görüntüleme tekniğidir [42-43]. X-ışınları ve CT taramalarının aksine, MRI iyonlaştırıcı radyasyon kullanmaz [44]. MRI özellikle beyin, omurilik ve kaslar gibi yumuşak dokuları görüntülemek için değerlidir ve kan damarları ve iç organlar hakkında ayrıntılı bilgi sağlar [45-46]. MRI genellikle güvenli kabul edilse de kalp pilleri, koklear implantlar veya metal implantlar gibi belirli tıbbi durumları olan kişiler için önerilmez [32].



Şekil 2.17 Manyetik Rezonans Görüntüleme (MRI) [47]

## 2.4. TIP TARAFIYLA İLGİLİ ÖZET

Sonuç olarak, kalça kırıkları ve çıkıkları şiddetli ağrı, hareket kaybı ve potansiyel uzun vadeli komplikasyonlara neden olabilen önemli yaralanmalardır. Kalça kırıkları, femur (uyluk kemiği) kalça ekleminin yakınında, genellikle düşme, osteoporoz veya travma nedeniyle kırıldığında meydana gelir. Öte yandan, kalça çıkığı, femurun top şeklindeki başının pelvisteki yuvasından çıkmasıyla meydana gelir ve bu da kuvvetli darbeler veya kazalardan kaynaklanabilir.

Hem kalça kırıkları hem de çıkıkları acil tıbbi müdahale gerektirir. Kalça kırıkları genellikle kırık kemiği yeniden hizalamak ve stabilize etmek için cerrahi müdahale gerektirir. Kalça çıkıkları, femur başını sokete manuel olarak geri yerleştirmek için bir küçültme prosedürüne ve ardından ilişkili yaralanmalar varsa destek, koltuk değneği veya ameliyat gibi destekleyici önlemlere ihtiyaç duyabilir.

Kalça kırıkları ve çıkıkları ile ilişkili komplikasyonlar arasında artrit, avasküler nekroz (kan akışının bozulması nedeniyle kemik dokusunun ölümü) ve derin ven trombozu (kan pıhtısı oluşumu) bulunur.

Kalça kırıkları ve çıkıkları için doğru teşhis, uygun tedavi ve kişiselleştirilmiş bakım planları için sağlık uzmanlarına danışmak önemlidir. Erken müdahale ve kapsamlı yönetim, sonuçları iyileştirebilir ve bireylerin hareketliliklerini ve yaşam kalitelerini yeniden kazanmalarına yardımcı olabilir.



### 3. LİTERATÜR TARAMASI

DL'nin hızlı ve sürekli ilerlemesi, CV, Doğal Dil İşleme (Natural Language Processing, NLP) ve Biyoinformatik gibi birçok alanda atılımlar yaptı [48]. CV, görüntülerle başa çıkmak için birçok DL algoritması kullanır, çünkü CV, bilgisayara görüntüler (2D veya 3D) ve videolar gibi farklı görsel içerikleri insanlar tarafından algılandığı gibi anlama, işleme ve analiz etme yeteneği kazandırmayı amaçlayan DL ve görüntü işlemenin kesişimi olarak tanımlanabilir. Birkaç dünyada, yapay zekâ bilgisayarların düşünmesine izin veriyorsa, CV görmelerine izin verir.

CV, görüntü sınıflandırma, nesne algılama, görüntü segmentasyonu, görüntü oluşturma ve diğerleri gibi belirli görevlerinden birini gerçekleştirmek için DL algoritmalarını ve özellikle CNN kullanarak görsel verilerden – görüntülerden ve videolardan – anlamlı veriler - özellikler - çıkarmaya odaklanır. Bu görevler aşağıdaki gibi tanımlanabilir:

- Görüntü sınıflandırma görevi, bir giriş görüntüsüne belirli bir etiket veya kategori atamak için kullanılır.
- Nesne algılama ve tanıma görevi, bir görüntüdeki belirli bir nesnenin konumunu yerleştirmekten ve ardından nesne kategorisini tanımaktan sorumlu olan görevdir.
- Görüntü bölütleme görevi, bir görüntüyü belirli bir kritere göre farklı bölgelere veya bölümlere ayırma işlemidir.
- Görüntü oluşturma görevi, yeni ve gerçekçi görüntü oluşturmaktan sorumlu olan görevidir.

CNN'lar, görüntülerle başa çıkma ve onlardan özellikler çıkarma yetenekleri nedeniyle CV görevlerinin temel yapı taşları ve kalbidir. CNN'lar evrişimli katman, havuzlama katmanı ve tamamen bağlı katmandan oluşur. Evrişimli katman, çekirdek olarak da bilinen belirli sayıda filtre uygulayarak giriş görüntüsünden kenarlar, dokular ve desenler gibi özelliklerin çıkarılmasından sorumludur. Bu katmanın çıktısı, evrişimli katmanda uygulanan filtrelerin sayısına bağlı olarak bir dizi özellik haritasıdır. Özellik haritaları, giriş görüntüsüne belirli bir

filtre uygulamanın etkisini vurgular. Ardından, özellik haritaları havuzlama katmanına aktarılır ve boyutları maksimum ve ortalama havuzlama gibi işlemler kullanılarak alt örneklenir. Son olarak, önceki katmanlar tarafından çıkarılan üst düzey özellikler, nihai tahminleri yapmak için tam bağlantılı katman tarafından yapılandırılır. CNN'ların mimarisi sürekli olarak gelişmektedir, bu da çeşitli CNN mimarilerinin belirli bir görevi yerine getirmesine yol açmaktadır.

### **3.1. TIBBİ GÖRÜNTÜLERDE CV GÖREVLERİ**

Sağlık sektörleri tarafından sağlanan tıbbi verilerin çoğu, onları sağlık uygulamalarında hayati bir bileşen haline getiren tıbbi görüntüleme verileridir. Tıbbi görüntüler, klinisyenler tarafından tıbbi durumları teşhis etmek, izlemek veya tedavi etmek için kullanılır [33-34].

Son yıllarda, CNN'nin tıbbi görüntüleme alanında kullanımı, tıbbi görüntü analizinde büyük bir ilerleme göstermiştir [49]. Bu tekniklerin uygulanması, doktorlara hastalığı sınıflandırma ve lokalize etmede yardımcı olmada hayati bir rol oynamıştır.

#### **3.1.1. Tıbbi Görüntü Sınıflandırması**

Tıbbi görüntüleme alanında, görüntü sınıflandırma görevi araştırmacılar tarafından yaygın olarak kullanılmaktadır. Tıbbi görüntüleme görüntü sınıflamasının temel amacı, bir hastalığın varlığını veya yokluğunu belirlemek ve sınıflandırmaktır. Tıp alanında görüntü sınıflandırma tekniklerinden yararlanan uygulamalar, cilt kanseri, akciğer kanseri, meme kanseri, diyabetik retinopati, COVID varlığı ve diğerleri gibi çoktur.

En bilinen ve kullanılan görüntü sınıflandırma CNN mimarileri AlexNet, Görsel Geometri Grubu (Visual Geometry Group, VGG), EfficientNet, GoogLeNet, ResNet ve DenseNet'tir.

#### **3.1.2. Tıbbi Görüntüde Nesne Algılama**

Tıbbi görüntüde nesne algılamanın ana rolü, etrafında bir sınırlayıcı kutu tasarlayarak hastalığın tıbbi görüntüdeki varlığını lokalize etmek ve daha sonra onu kendi özel sınıfına/kategorisine göre ayırmaktır. Tıbbi nesne algılama teknikleri, klinisyenlerin hastalığın yerini en kısa sürede belirlemelerine yardımcı olmada önemli bir rol oynamıştır. Bu teknik, akciğer nodüllerinin saptanması, meme kanseri, COVID-19 ve diğerleri gibi birçok tıbbi alanda uygulanmıştır.

Nesne algılama görevini gerçekleştiren en bilinen algoritmalar Bölge Evrişimli Sinir Ağı (Region-Convolutional Neural Network, R-CNN), Hızlı R-CNN (Fast R-CNN), Daha Hızlı R-CNN (Faster R-CNN), YOLO (You Only Look Once) [50] ve Tek-Atış Dedektörü (Single-Shot Detector, SSD)'dür.

### 3.1.3. Tıbbi Görüntü Segmentasyonu

Nesne algılama, ilgilenilen nokta etrafında bir sınırlayıcı kutu tasarlarlarken, görüntü segmentasyon görevi ilgili bölge için bir piksel maskesi üretir. Bu teknik, prostat kanseri, beyin tümörleri, meme kanseri ve diğer birçok segmentte kullanılmıştır.

Görüntü bölütleme görevini yerine getirmede en çok kullanılan algoritmalar U-şekilli Ağ (U-shaped Network, U-Net), Maske Bölgesi Tabanlı Evrişimli Sinir Ağı (Mask Region-based Convolutional Neural Network, Mask R-CNN) [51], DeepLab'dır.

## 3.2. ORTOPEDİ CV

Ortopedi bölümü, kemiklerin insan vücudunda önemli bir rol oynaması nedeniyle araştırmacıların dikkatini çeken bir bölümdür. Kemikler vücudun hareket etmesini sağlar, vücut yapısını destekler ve hayati organları korur.

Bu alanda yapılan çalışmalar, kemik kırıklarını saptamak, sınıflandırmak ve lokalize etmek için ML/DL ve CV algoritmalarının geliştirilmesi ve incelenmesi konusu etrafında dönmektedir. Bu çalışmalardan bazıları genel olarak yapılmıştır; örneğin, çeşitli kemik kırıklarını tespit etmek gibi [52-55]. Diğer çalışmalar ise bilek kırıkları [56-58], kol kırıkları [59-60] ve ayak bileği kırıkları [61-63] gibi belirli bir kemik tipine odaklanmaktadır. Her çalışmanın bir özeti Tablo 3.1'de sunulmaktadır.

**Tablo 3.1** Farklı Kırık Tespiti ve Sınıflandırılması Konusunda Önceki Çalışmalar

Yazar	Yıl	İskelet Eklemleri	Veri Kümesi Boyutu	Açıklama	Model	Performans				
						Doğruluk	Hassasiyet / Geri Çağırma	Özgünlük	Kesinlik	AUC
[57]	2017	Bilek	1389	Çalışmanın amacı, CNN'lerden transfer öğrenmenin X-ışını görüntülerindeki kırıkları tespit edebileceğini göstermektedir.	InceptionV3	-	90%	88%	-	95.4%
[56]	2018	Bilek	135,845	Çalışmanın amacı, DL uygulanmasıyla doktorun bileğin kırık olup olmadığını ayırt etmesine yardımcı olmaktır.	U-Net	-	93.3%	94.5%	-	97.5%
[58]	2019	Bilek (Distal Radius)	1010	Çalışmanın amacı, Distal Radius-bilek kırıklarını Posterior/Anterior (PA) ve Lateral (LAT) radyografilerde tespit etmektir.	CNN	-	-	-	-	96%
[60]	2019	Kol (Dirsek, Önkol, Humerus)	MURA 40,895	Çalışma, farklı kol kırıklarının tespiti için bir yöntem önermektedir.	ResNet	-	-	-	62.04%	-
[59]	2020	Kol (Humerus)	115	Çalışma, proksimal humerus kırıklarını sınıflandırmak için X-ışını görüntülerinden özellikler çıkarmak için HOG, LPB ve RFNCA görüntü tanımlayıcılarını kullanır.	<ul style="list-style-type: none"> <li>SVM</li> <li>LD</li> <li>kNN</li> <li>BT</li> </ul>	99.12%	99.12%	94.78%	85.21%	-
[61]	2019	Ayak bileği	596	Çalışmanın amacı, küçük veri setlerinde ayak bileği kırıklarını tespit etmede CNN modellerinin etkinliğini belirlemektir.	<ul style="list-style-type: none"> <li>InceptionV3</li> <li>ResNet 101</li> <li>Drop/aux ile ResNet</li> <li>Xception</li> <li>Drop/aux ile Xception</li> <li>Ensemble A (Inception V3, ResNet, drop/aux ile ResNet, Xception, drop/aux ile Xception)</li> <li>Ensemble B (Inception V3, ResNet, drop/aux ile Xception)</li> </ul>	Bir/Üç Görünüm 0.70/0.74 0.73/0.75 0.72/0.73 0.75/0.78 0.75/0.78 0.76/0.81 0.75/0.81	Bir/Üç Görünüm 0.68/0.73 0.68/0.70 0.74/0.73 0.73/0.75 0.71/0.73 0.77/0.80 0.68/0.73	Bir/Üç Görünüm 0.73/0.75 0.77/0.80 0.70/0.73 0.76/0.80 0.80/0.73 0.76/0.82 0.79/0.85	-	-

[62]	2021	Ayak bileği	1226	Çalışmanın amacı, Anter posterior (AP) ve lateral (LAT) ayak bileği X-ışınlarında kırık olup olmadığını tespit etmektir.	InceptionV3	AP: %83 LAT: 0.91	-	-	-	AP: %90 LAT:0.95
[63]	2021	Ayak bileği	5495	Çalışmada AO Vakfı/Ortopedik Travma Derneği (AO/OTA) sınıflamasına göre ayak bileği kırıklarının tespitinde CNN modelinin uygulanması sunulmuştur.	ResNet	-	-	-	-	0.90
[53]	2017	Genel	-	Çalışma, kırıkların konumlarını ve şekillerini tespit etmek için görüntü işleme tekniklerine dayanan bir model sunmakta, aynı zamanda görüntüleri kırık ve kırık olmayan olarak sınıflandırmak için BPNN modelini kullanmaktadır.	3 katmanlı Geri Yayılım Sinir Ağı (BPNN)	94.3%	-	-	-	-
[54]	2017	Genel	MURA 40,895	Çalışmanın amacı, MURA veri kümesini tanıtmak ve bir kemik kırık olup olmadığını tespit etmek için bir CNN modelinin performansını radyolog performansıyla karşılaştırarak değerlendirmektir.	DenseNet 169	-	0.815	0.887	-	-
[55]	2020	Genel	715,343	Bu çalışmanın amacı, kas-iskelet sistemi kırıklarını tespit etmektir.	Dilated Residual Network (DRN)	-	95.2%	81.3%	-	97.4%
[52]	2022	Genel	-	Bu çalışmada kullanılan model, gri tonlu görüntülerden Canny kenarlarını çıkarmak için geliştirilmiş bir Canny kenar algoritmasına dayanmaktadır. Daha sonra, gri ve Canny kenar görüntüleri sınıflandırma için SFNet'e beslenir.	Hybrid SFNet	99.12%	100%	-	99%	-

Proksimal femur kırıkları, kalça/pelvik bölgede meydana gelen kırıkları ifade eder. Proksimal femur kırıklarının saptanması/sınıflandırılması konusunu tartışan çalışmaların çoğu, başlığında kalça/pelvik kırıkları veya kırığın adını (baş, boyun, intertrokanterik kırık) tutmaktadır. Aşağıda 2018-2023 yılları arasında ilgili alanda yapılan çalışmalar özetlenmektedir.

### 3.2.1. Bilgisayar mı İnsan mı? Femur Boyun Kırıklarının Tespiti İçin Derin Öğrenme ile Algısal Eğitim Karşı Karşıya [64]

**Amaç:** Bu çalışmanın amacı, iki Derin Evrişimli Sinir Ağı (Deep Convolutional Neural Network, DCNN) olan AlexNet ve GoogleNet'in doğruluğunu, uzmanlaşmış radyologlar ve radyoloji uzmanlık öğrencilerinin başarılarıyla karşılaştırmaktır. Aynı zamanda, önceki bir çalışmanın sonuçlarıyla da karşılaştırma yapılmaktadır. Bu önceki çalışmada, tıp veya radyoloji eğitimi almamış 142 öğrenciye bir saatten az bir sürede Femur Boyun Kırıklarını (Neck of Femur Fracture, NoFF) algılamaları için algısal eğitim verilmiştir. Öğrencilere, sağ kalça röntgen görüntülerinde kırık olup olmadığını belirtmeleri istenmiştir. Verilen cevaplar doğru veya yanlış olarak değerlendirilmiş ve varsa kırığın yeri belirlenmiştir.

**Veri seti:** Kullanılan veri seti 805 film içerir, çekilen 403 film NoFF gösterir ve 402 normaldir.

**Ön İşleme:** Her şeyden önce, tüm görüntüler aynı boyut ve oranlara sahip olacak şekilde düzenlenmiştir. Bundan sonra, sol taraflı kalça filmleri sağ taraflı kalça filmlerine dönüştürülmüştür ve son olarak, femur başının yerini belirtmek için manuel olarak kırılmıştır.

**Yöntem:** Çalışma, her aşamanın sırasıyla 200, 320 ve 640 olmak üzere farklı bir örneklem boyutuna sahip olduğu üç aşamada yapılmıştır. Üç aşamada, filmler eğitim için %80'e ve doğrulama için %20'ye bölünmüştür. Test için 160 film den oluşan ayrı bir örnek alınmıştır.

Sınıflandırma için, ImageNet tarafından önceden eğitilmiş AlexNet ve GoogleNet çerçeveleri kullanılmıştır. Yazarlar, iki çerçevedeki son üç katmanı değiştirmişlerdir. Böylece NoFF'yi tespit etmek için uygulanabilmişlerdir. Bununla birlikte, bir büyütme algoritması kullanılmış ve ölçülmüştür.

**Sonuçlar:** Çalışma, eğitim veri setinin örneklem büyüklüğüne göre GoogleNet ve AlexNet doğruluk değerinin arttığını göstermektedir. Örneklem boyutu ne kadar büyükse, doğruluk da o kadar büyük olur. AlexNet'te doğruluk %81,9'dan %89,4'e, GoogleNet'te ise %88,1'den %94,4'e yükselmiştir. Uygulanan büyütme önemli bir fark oluşturmamıştır.

Çalışma, GoogleNet'in kalça kemiği boyun kırığı tespitinde AlexNet'in (89,4%) doğruluğunu, [62]'de tıbbi bilgisi olmayan bireylere uygulanan algısal eğitimin (90,5%)

doğruluğunu, radyoloji uzmanlarının (93,5%) ve asistanlarının (92,9%) doğruluğunu aşarak %94,4 başarı oranıyla lider konuma yerleştiğini göstermektedir.

### 3.2.2. Derin Bir Evrişimli Sinir Ağı Kullanarak İntertrokanterik Kalça Kırıklarının Ortopedist Düzeyinde Doğrulukla Tespit Etmek [65]

**Amaç:** Bu çalışmanın amacı, CNN'nin proksimal femur kırıklarının röntgenlerinden ve ortopedik röntgenlerden intertrokanterik kalça kırıklarını saptama yeteneğini karşılaştırmaktır.

**Veri seti:** 2678 filmde oluşan bir eğitim seti (1408 kırıklı ve 1270 kırık olmayan film), 334 filmde oluşan bir doğrulama seti (185 kırık ve 149 kırık olmayan film) ve 334 filmde oluşan bir test seti, başlangıçta rastgele karıştırıldıktan sonra 3346 kalça filminin tümünden oluşturulmuştur (180 kırık ve 154 kırık olmayan film). Bu filmler 1773 hastadan çekilip toplanmıştır.

**Ön İşleme:** Filmler, femur başı ile büyük ve küçük trokanterler görünebilecek şekilde 300\*300 piksel bir matrisle kırılmıştır. Femur boyun kırığı sonrasında sahte eklem görülen ve donanım uygulaması gösteren filmler hariç tutulmuştur.

**Yöntem:** Bu çalışmada, önceden eğitilmiş VGG\_16 modeli kullanılmıştır. Aşırı öğrenmeyi önlemek için, ImageDataGenerator kullanılarak veri büyütme, En Küçük Kareler Hataları (Least Square Errors, L2) düzenleme ve erken durdurma teknikleri uygulanmıştır.

**Sonuçlar:** CNN ve ortopedik cerrahların doğruluk oranları sırasıyla %95,5 ve %92,2; hassasiyet ve özgüllük oranları ise sırasıyla %93,9 ve %88,3 ile %97,4 ve %96,8 olmuştur.

### 3.2.3. Düz Pelvik Radyografilerde Kalça Kırıklarının Tespiti ve Görselleştirilmesi için Derin Öğrenme Algoritmasının Uygulanması [66]

**Amaç:** Bu çalışmanın amacı, DCNN'nin düz ön pelvik radyograflar üzerinde kalça kırıklarını tanımlama ve lokalize etme kabiliyetinin olduğunu kanıtlamaktır.

**Veri Kümesi:** Üç farklı veri kümesi kullanılmıştır. Farklı Limb röntgenlerinin 25.505 filmi tutan Limb radyografisi veri seti, 6019'u ayak bilekleri için, 3832'si dirsekler için, 4134'ü ayaklar için ve 3378'i bilekler içindir. Bu veri seti, transfer öğrenimi için bir ön eğitim materyali olarak kullanılmıştır. 1975'i kalça kırığı olan (931 NoFF ve 1044 Trokanterik Kırık) ve 1630'u olmayan 3605 film içeren Pelvik X-ışını (Pelvic X-ray, PXR) veri setidir. Test için 100 PXR filminden oluşan ayrı bir veri kümesi kullanılmıştır.

**Ön İşleme:** PXR veri setindeki her filme bir seri numarası verilmiş ve değerlendirilmiştir. Limb veri setindeki filmler, karşılık gelen vücut kısmı ile yeniden etiketlenmiştir. İki veri kümesinin görüntüleri, 8 bit gri tonlamalı renkle 512\*512 olarak yeniden boyutlandırılmıştır.

**Yöntem:** Bu çalışma, sinir ağı yapısı olarak DenseNet-121'i ve aktarım öğrenimi için bir ön eğitim materyali olarak Limb veri setini kullanmaktadır. X-ışınlarından vücut bölümünü tanımlama eğitimi için Limb veri seti, kalça kırıklarını tespit etmek için PXR veri seti kullanılmıştır. Limb veri seti eğitim için %90 ve doğrulama için %10 olarak bölünürken, PXR veri seti eğitim için %80 ve doğrulama için %20 olarak bölünmüştür. Modelin geçerliliğini göstermek adına, Gradyan-Ağırlıklı Sınıf Aktivasyon Haritalandırması (Gradient-weighted Class Activation Mapping, Grad-CAM) olarak bilinen bir görselleştirme algoritması uygulanmıştır.

**Sonuçlar:** Limb veri setine eğitimi sırasında uygulanan ağırlıklar %99,5 başarı elde etmiş olup, benzer ağırlıklar PXR veri setine de uygulanmıştır. PXR veri setinde elde edilen başarı sırasıyla %91, %98 ve %84 olarak hassasiyet, özgüllük ve duyarlılık şeklindedir. Kalça kırıklarını teşhis etme yeteneklerini değerlendirmek için 21 uzmana bir anket hazırlanmıştır. Bu uzmanlardan 16'sı radyolog ve cerrah dışında kalan birincil hekimler, 6 uzman ise iki radyolog ve dört ortopedi uzmanıdır. Birincil hekimlerin hassasiyet ve özgüllük ortalamaları sırasıyla %95,6 ve %82,2 olarak gerçekleşmiştir. Uzmanlarda ise bu oranlar sırasıyla %99,3 ve %87,7'ye ulaşmıştır. Grad-CAM uygulamasıyla birlikte elde edilen başarı ise %95,9'dur.

Önerilen model, 21 uzmanınkine benzer bir performans göstermiştir. Bu da DCNN algoritmalarının kalça kırıklarını tespit etmek için kullanılabileceği ve doktorların sonuçları önlemek için bunları gerçek zamanlı olarak tespit etmelerine yardımcı olabileceği anlamına gelmektedir.

### 3.2.4. Derin Öğrenme ve Genetik Algoritmalar Kullanılarak X-ışını Filmlerde Femur Boyun Kırığı Tespiti [67]

**Amaç:** Bu çalışmanın amacı, DL teknikleri ve Genetik Algoritmalar (Genetic Algorithms, GA) kullanılarak frontal PXR'den NoFF'yi tespit etmektir.

**Veri seti:** Veri seti, 149'u NoFF ve 85'i kırık olmayan 234 frontal PXR görüntüsünden oluşmaktadır. Kabul edilebilir bir veri kümesine sahip olmak için, büyütme yöntemleri kullanılarak veri setinin boyutu 2106 filme, 1341'i NoFF'ye ve 765'i kırılmamış filme

çıkarılmıştır. Büyütme işlemi, orijinal filmin saat yönünde ve saat yönünün tersine 10, 20 ve 30 derece döndürülmesiyle elde edilmiştir. Gaussian gürültü uygulamanın dışında aynı zamanda orijinal filmin yansıması elde edilmeye çalışılmıştır. Böylece orijinal filmde 8 yeni film elde edilmiştir.

**Ön İşleme:** Tüm X-ışını görüntüleri, femur boyun kısmını gösterecek şekilde manuel olarak kırılmış ve 50\*50, 100\*100, 200\*200 ve 400\*400 olarak yeniden boyutlandırılmıştır. Test için kullanılan görüntüler kırıklı ve kırıksız olarak sınıflandırılmıştır.

**Yöntem:** Kullanılan model 5 bloktan oluşmaktadır. Her blok, evrişimli katman, toplu normalleştirme, Doğrultulmuş Doğrusal Birim (Rectified Linear Unit, ReLU) ve maksimum havuzlama katmanı içermektedir. 5 bloğun ardından, 0.5 değerinde bir bırakma katmanı gerçekleştirilmiştir. Bunları takiben, softmax katmanı ve sınıflandırma katmanı olmak üzere iki sınıfın tam bağlantılı üç katmanı mevcuttur. CNN hiper parametrelerinin optimizasyonu ve modelin testinden sonra ortaya çıkan hatanın en aza indirilmesi için GA uygulanmıştır.

**Sonuçlar:** Doğruluk, Kappa, F1 skoru, Duyarlılık ve Özgüllük beş aşamalı çapraz geçerlik testi kullanılarak ölçülmüştür. 50\*50 olarak yeniden ölçeklendirilen filmler, GA'nın uygulandığı veya uygulanmadığı en iyi performansı kaydetmiştir. GA olmadan Doğruluk, Kappa, F1 skoru, Duyarlılık ve Özgüllük değerleri sırasıyla %77, %52, %83, %83 ve %67 olmuştur. GA metriklerinin uygulanmasıyla değerler Doğruluk %79, Kappa %55, F1 puanı %84, Hassasiyet %83 ve Spesifiklik %73 olacak şekilde elde edilmiştir.

### 3.2.5. Otomatik Femur Boyun Kırığı Tespiti ve Sınıflandırmasına Uygulanan İleri Derin Öğrenme Teknikleri [2]

**Amaç:** Bu çalışmanın amacı, 2D Sinir Ağı'nı incelemek ve Üretken Çekişmeli Ağlar (Generative Adversarial Network, GAN) ile Dijital Olarak Yeniden Oluşturulmuş Radyograflar (Digitally Reconstructed Radiographs, DRR) artırma yöntemlerini NoFF tabanlı Garden sınıflandırmasını tespit etmede uygulamaktır.

**Veri seti:** Tıpta Dijital Görüntüleme ve İletişim (Digital Imaging and Communications in Medicine, DICOM) dosyaları olarak çıkarılan toplam 1444 Ön-Arka (anteroposterior, AP) kalça radyografisi filminden oluşmaktadır. Donanım (implements) içeren veya NoFF olmayan görüntüler hariç tutulmuş ve bu da 1036 X-ışınlarından oluşan bir veri kümesiyle sonuçlanmıştır. Bu 1036 görüntü 127 film ile Garden I/II kırığı, 610 film ile Garden III/IV

kırığı ve 326 film ile normal olmak üzere 3 gruba ayrılmıştır. Test işleminde her grup için 35 film olarak kategorize edilmiş 105 filmde oluşan ayrı bir grup çekilmiştir.

**Ön İşleme:** GAN ve DRR büyütme yöntemleri uygulanarak 9063 film elde edilmiştir. Filmler 256\*256 piksel olarak ayarlanmıştır.

**Yöntem:** Model, 2B sinir ağı tabanlı bir ResNet mimarisidir. Birinci aşda femur boyun kısmı ilgilenilen bölge dairesel kullanılarak lokalize edilmektedir. Bundan sonra ikinci aşda femur boyun Garden I/II, Garden III/IV ve normal olarak sınıflandırılmıştır.

**Sonuçlar:** Değerlendirilen metrik değerler, Eğri Altındaki Alan (Area Under the Curve, AUC), Doğruluk, Duyarlılık, Özgüllük, Pozitif Tahmin Değeri (Positive Predictive Value, PPD) ve Negatif Tahmin Değeri (Negative Predictive Value, NPV)'dir.

GAN ve DRR büyütme ile kırıklı veya kırık olmayan iki sınıfın tahmini için değerler şunlardır: AUC: 0.92, Doğruluk: %92.3, Duyarlılık: 0.91, Özgüllük: 0.93, PPV: 0.96 ve NPV: 0.86

Herhangi bir büyütme olmadan iki sınıfın (kırıklı veya kırıksız) tahmini için AUC 0.80'e, sadece DRR büyütme AUC 0.91'e ve sadece GAN büyütme AUC 0.87'ye ulaşmıştır.

GAN ve DRR büyütme ile üç sınıfın (Garden I/II, Garden III/IV ve normal) tahmini için değerler şunlardır: AUC: 0.96, Doğruluk: %86, Duyarlılık: 0.79, Özgüllük: 0.90, PPV: 0.80 ve NPV: 0.90.

### 3.2.6. İnteraktif Eğitim ve Cerrahi Planlama için Hassas Proksimal Femur Kırığı Sınıflandırması [68]

**Amaç:** Bu çalışmanın amacı, proksimal femur kırıklarını otomatik olarak saptayan Bilgisayar Destekli Teşhislerin (Computer-Aided Diagnoses, CAD) geliştirilmesi ve DL kullanılarak AO'ya göre sınıflandırılmasıdır.

**Veri seti:** Veri seti 1347 X-ışını görüntüsünü içermektedir. 567 film kırıksız, 780 film kırıklıdır (anormal). Kırık filmler, AO sınıflandırmasına göre Tip-A ve Tip-B olarak kategorize edilmiştir; Tip C, veri setindeki düşük varlığı nedeniyle dışarıda bırakılmıştır. Kırık filmlerin 327'si Tip-A, 453'ü Tip-B'ye aittir. Veri seti eğitim için %70, doğrulama için %10 ve test için %20 olarak bölünmüştür.

**Ön İşleme:** Görüntüler, sınıflandırma işlemi için ResNet50 tarafından kullanılmak üzere 2500\*2048'den 224\*224 piksele yeniden boyutlandırılmıştır. Ardından AlexNet kullanılarak yapılan yerleştirme işlemi için 227\*227 piksele yeniden boyutlandırılmıştır. Veriler, öteleme, ölçekleme ve döndürme gibi büyütme yöntemleri kullanılarak artırılmıştır.

**Yöntem:** Sınıflandırma işlemi için ResNet50 ve proksimal femur bölgesinin lokalizasyonu için farklı İlgi Bölgesi (Region of Interest, ROI) yolları ile AlexNet kullanılmıştır.

**Sonuçlar:** Kırıklı ve kırıksız olarak yapılan sınıflamada F1 skoru %94 ve AUC skoru 0.98 olarak saptanmıştır. Tip-A, Tip-B ve kırıksız olarak sınıflandırılırken, F1-skoru %87 ve AUC 0.95 olarak bulunmuştur.

### 3.2.7. Pozisyon, Donanım Varlığı ve Kırık Tespiti için Pelvik Radyograflerin Derin Öğrenme Değerlendirmesi [69]

**Amaç:** Bu çalışmanın amacı, oluşturulan bir DL modelinin pelvik pozisyonu otomatik olarak tanımlayabilme yeteneğini incelemek, implante edilmiş donanımın varlığını tespit etmek, pelvik, asetabüler ve kalça kırıklarını algılayabilmektir.

**Veri kümesi:** Kullanılan veri kümesi 14.374 film içerir. Çalışma farklı görevlere odaklandığı için veri kümesi görevlere göre bölünmüş ve değerlendirilmiştir.

Pelvis ve kalça pozisyonlarını ve olası donanım varlığını tanımlamak için oluşturulan veri seti, çeşitli görüntü açıları ve kategorileri içeren toplam 3025 filminden oluşmaktadır. Veri seti aşağıdaki şekilde ayrılmıştır:

- 2006 Pelvis: Frontal (ön), Oblik (eğik), Inlet (giriş), Outlet (çıkış)
- 801 Kalça: Frontal (ön), Frog-leg lateral (kurbağa bacak yan), Cross-table lateral (masada yan)
- 18 Hatalı: Pelvis veya kalça yeterince net olmadığı için değerlendirmeye alınmayan filmler (donanım varlığına göre etiketlenmiştir)
- 200 Göğüs: Veri setine dahil edilen ancak analiz kapsamı dışında kalan filmler.
- Donanım varlığına göre dağılım ise: 2507 Donanımsız ve 318 Donanımlı

Veri seti, daha sonra analiz için %70 eğitim ve %30 test olmak üzere ayrılmıştır.

Kırık tespiti için kalan 11522 film 7337'ye indirilmiş ve normal (3428 film), anterior pelvis (713 film), posterior pelvis (13 film), proksimal femur (1902 film), asetabular (410 film) ve kompleks (761 film) olarak etiketlenmiştir. Her kırık vakasının %70'i eğitime, %30'u teste ayrılmıştır.

**Ön İşleme:** Filmler başlangıçta 238\*238 piksel olarak yeniden boyutlandırılmış, ardından nihai boyut olarak 224\*224 piksel boyutuna ulaşmıştır. Rastgele parlaklık, rastgele kontrast, rastgele yatay çevirme ve rastgele kırpma büyütme yöntemleri kullanılmıştır.

**Yöntem:** Oluşturulan DL modeli DenseNet-121 mimarisine dayandırılmıştır.

**Sonuçlar:** Pozisyon ve donanım varlığı görevi için AUC 0.99-1.00 aralığındadır. Sınıflandırma görevi için ise proksimal femur kırığının tespiti için AUC 0.95, pelvik ve asetabular kırık AUC değeri ise 0.70 ile düşük (posterior pelvis kategorisi) ve 0.85 ile yüksek (asetabular kategori) olarak belirlenmiştir.

### 3.2.8. Pelvik Röntgen Görüntülerinde Femur Kırık Tespiti İçin Meta-Öğrenimli Derin Sinir Ağları [70]

**Amaç:** Çalışmanın amacı, X-ışını görüntüleri ve raporlar aracılığıyla femur kırıklarını sınıflandırmayı öğrenen bir model tabanlı meta-öğrenme sunmaktır.

**Veri Seti:** Kullanılan veri seti 786 anterior-posterior pelvik röntgen filmi ve 459 rapordan oluşturulmuştur. 410 film kırık, 376 kırık değildir. Raporlarıyla eşleştirilen 459 film, 239'u kırık ve 220'si kırıksız olmak üzere eğitim filmi olarak alınmıştır. Raporlarla eşleşmeyen diğer 327 film, doğrulama ve test arasında rastgele bölünmüştür. Doğrulamada 59 kırık filmi ve 41 kırık olmayan film yer almıştır. Test, 112 kırık filmi ve 115 kırık olmayan film içermektedir.

**Ön İşleme:** Veri seti dengesiz olduğundan dolayı, eğitim veri setinde döndürme, çevirme ve ölçeklendirme gibi veri artırma yöntemleri uygulanmıştır.

Rapordaki sözcüğü vektör olarak göstermek için Global Vectors for World Representation (GloVe) kullanılmıştır.

**Yöntemler:** Her biri bir kodlayıcı-dekodöz ve bir sınıflandırma ağı içeren iki DL mimarisi sunulmaktadır. Kodlayıcı yapısı, GoogLeNet-Inception3'e dayanmaktadır. Kodlayıcı, giriş filmi alır ve sıkıştırır, ardından onu restorasyon için sıkıştırılmış bir vektör olarak kullanır. Kod çözücü yapısı, Çift Yönlü Uzun Kısa Süreli Belleğe (Bidirectional long short-term memory, Bi-LSTM) dayanmaktadır. Metin, hem film hem de metin içeren bir latent temsil üretmek için bir kod çözücü kullanır. Filmler, 512\*512 piksele yeniden boyutlandırılmıştır. Metinler, kelimelerle ayrıştırılmış, one-hot kodlu, 128 boyutuna dönüştürülmüş ve ardından Bi-LSTM'ye aktarılmıştır. İki mimari arasındaki fark, ilkinde kodlayıcı, kod çözücü ve sınıflandırıcının ayrı ayrı eğitilmiş olmasıdır. İkinci mimaride ise kodlayıcı, kod çözücü ve sınıflandırıcının birlikte eğitilmiş olmasıdır.

**Sonuçlar:** Çalışma AO/OTA sınıflandırmasına dayandırılmıştır. Bu sınıflandırma kırığın pozisyonuna bağlıdır. Trokanterikteki kırıklar Tip-A olarak adlandırılır. Boyunda bulunanlar Tip-B olarak adlandırılır. Tip-C, son derece nadir görülen kafada görülür. Kırığın şekline göre her tipin A1, A2, A3, B1, B2, B3, C1 ve C2 olarak listelenen bir alt kategorisi vardır. Tip-C kırıkları nadir olduğu için devre dışı bırakılmıştır.

Değerlendirme üç seviyeye göre yapılmıştır: 2-sınıf: Kırılan veya kırılmayan, 3-sınıf: üç grup (A,B,C) arasındaki sınıflandırma, 7-sınıf: yedi grup arasındaki sınıflandırma (kırksız, A1, A2, A3, B1, B2, B3).

İlk mimari, 2 sınıflı, 3 sınıflı ve 7 sınıflı karşılaştırmalar için %85.02, %79.74, %69.60 genel doğruluğa ve 0.54, 0.79, 0.49 F1 puanına ulaşmıştır.

İkinci mimari, 2 sınıflı, 3 sınıflı ve 7 sınıflı karşılaştırmalı olarak %86.78, %82.38, %74.89 genel doğruluğa ve 0.87, 0.82, 0.50 F1 puanına ulaşmıştır.

### 3.2.9. Proksimal Femur Röntgen Görüntülerinde Çok Aşamalı Derin Öğrenme ile Hiyerarşik Kırık Sınıflandırması [71]

**Amaç:** Bu çalışmanın amacı, AO/OTA sınıflandırmasını takip eden DL tabanlı bir araç tasarlamaktır.

**Veri seti:** 1133 Kırık femur, 570 Tip-A, 750 Tip-B, 4 Tip-C olarak sınıflandırılan toplam 2453 anteroposterior film kullanılmıştır. Tip-C, film sayısının az olması nedeniyle hariç tutulmuştur. Tip A kırıkları 280 film ile A1, 183 film ile A2 ve 107 film ile A3 olarak sınıflandırılmıştır.

**Ön İşleme:** Her şeyden önce, sağ ve sol uyluk kemiği alanının net bir şekilde görülebilmesi için filmler kırılmış, ardından 299\*299 piksel olarak yeniden boyutlandırılmıştır. Daha sonra bunlar incelenmiş ve toplam 183 film protez cihaz içermesi (n=15), çözünürlüğünün yetersiz olması (n=47), uyluk kemiğini çevreleyen bölgeyi kısmen kapatması (n=23) veya yanal perspektif göstermesi (n=98) nedeniyle devre dışı bırakılmıştır. Son adımda, veri kümesinin doğrulanmasını onaylamak için radyolog tarafından gözden geçirilmiştir.

**Yöntem:** DL tabanlı araçların uygulanması için iki strateji kullanılmıştır. İlk strateji, DL tabanlı aracın temeli olarak hizmet veren değiştirilmiş bir InceptionV3 CNN'dir. İkincisi, AO/OTA sınıflandırma sisteminin hiyerarşik yapısına uyacak şekilde oluşturulmuş, kademeli olarak ardışık CNN'lerden oluşan çok aşamalı bir mimaridir. Sınıflandırma için resimlerin en önemli bölgeleri, Grad-CAM kullanılarak gösterilmiştir.

**Sonuçlar:** Üç sınıf için sınıflandırma sonuçları 0.86, beş sınıf için 0.81 olarak hesaplanmıştır.

### 3.2.10. Ölçeklenebilir Hekim Düzeyinde Derin Öğrenme Algoritması, Pelvik Radyografilerde Evrensel Travmayı Tespit Eder [72]

**Amaç:** Bu çalışmada, nokta tabanlı açıklama kullanılarak eğitilmiş bir DL algılama algoritması olan PelviXNet sunulmaktadır.

**Veri Seti:** Eğitim setinde 3110 adedi akut travma, 2094 adedi travmasız olmak üzere toplam 5204 adet PXR film bulunmaktadır. Akut travmada kalça kırığı 2036 X-ışını film ile yer almaktadır. Geri kalan 919 filmler ile pelvik bölge kırıkları ve 232 filmler ile diğer anormallikler yer almaktadır. Test seti 1888 hastanın PXR'sini içermektedir.

**Ön İşleme:** Filmler 1024\*1024 piksel olarak yeniden boyutlandırılmış ve rastgele yatay ve dikey çeviriler, rastgele ölçekleme, rastgele yatay çevirme, rastgele döndürme ve parlaklık ve kontrast titremesi ile artırılmıştır.

**Yöntem:** PelviXNet'in geliştirilmesi, DenseNet, nokta denetimi ve özellik piramidi ağı (FPN) kombinasyonuna dayanmaktadır.

**Sonuçlar:** PelviXNet, Alıcı Çalışma Karakteristik Eğrisi Altındaki Alan (Area Under the Receiver Operating Characteristic Curve, AUROC) 0.973, Hassas Geri Çağırma Eğrisinin

Altındaki Alan (Area Under the Precision-Recall Curve, AUPRC) 0.963, doğruluk 0.924, duyarlılık 0.908 ve özgüllük 0.932 olarak elde edilmiştir.

### 3.2.11. Proksimal Femur Kemiği Kırığının Mask R-CNN Kullanılarak Tespiti [73]

**Amaç:** Bu çalışmada proksimal femur kemiğinde kırık varlığını saptamak için CNN'ler ve Mask R-CNN kullanılmaktadır.

**Veri seti:** Veri seti, proksimal femur kırıklarının röntgen filmlerini içerir. Filmlerin ortalama çözünürlüğü 2345\*2310 pikseldir.

**Ön İşleme:** Filmler JPEG'e dönüştürülmüş, açıklama eklenmiş, ardından eğitim için %75'e ve test için %25'e bölünmüştür.

**Yöntem:** ResNet101'i temel alan omurgaya sahip, önceden eğitilmiş bir Mask R-CNN modeli kullanılmıştır.

**Sonuçlar:** Çalışmaya göre, model sadece 18 dönemde ve her dönem için 35 döngüde %85,4'lük bir doğruluğa yol açmaktadır.

**Tablo 3.2** Proksimal Femur Kırığı ile İlgili Önceki Çalışmalar

Yazar	Yıl	Veri Kümesi Boyutu	Model	Performans				Sınıflandırma türü	Veri Ön İşleme ve Büyütme
				Doğruluk	Hassasiyet / Geri Çağırma	Özgüllük	AUC		
[64]	2018	Üç Set: 200 320 640	AlexNet GoogleNet	89.4% 94.4%	- -	- -	- -	Kırık / Kırık olmayan	<p><b>Ön İşlem:</b></p> <ul style="list-style-type: none"> <li>Filmler, eşdeğer boyut ve oranlarda olacak şekilde yeniden boyutlandırıldı.</li> <li>Sol taraflı kalça filmleri sağ taraflı olacak şekilde yansıtıldı.</li> <li>Kırığın yerini göstermek için filmler manuel olarak kırıldı.</li> </ul> <p><b>Büyütme:</b></p> <ul style="list-style-type: none"> <li>Filmler rastgele yansıtıldı.</li> <li>Filmler rastgele çift yönlü olarak 15 dereceye kadar döndürüldü.</li> </ul>

[65]	2018	3346	VGG_16	95.5%	93.9%	97.4%	-	Kırık / Kırık olmayan	<p><b>Ön İşlem:</b> Filmler proksimal femoral kısmı dahil etmek için 300*300 piksellik bir matris ile kırıldı.</p> <p><b>Büyütme:</b></p> <ul style="list-style-type: none"> <li>• ImageDataGenerator []: <ul style="list-style-type: none"> <li>o 5.0° dönüş</li> <li>o Genişlik ve Yükseklik kaydırma aralığı 0.2</li> <li>o 0.1'lik kesme</li> <li>o 0,2 yakınlaştırma</li> <li>o %50 yatay çevirme</li> </ul> </li> </ul>
[66]	2019	Limb: 25505 PXR: 3605 100	DenseNet-121 Grad-CAM	91% 95.9%	98% -	84 -	0.98 -		<p><b>Ön İşlem:</b></p> <ul style="list-style-type: none"> <li>• PXR veri setindeki filmlere seri numarası verilmiş ve değerlendirilmiştir.</li> <li>• Limb veri kümesindeki filmler, karşılık gelen vücut bölümüyle yeniden etiketlendi.</li> <li>• İki veri kümesinin filmleri, 8 bit gri tonlamalı renkle 512*512 olarak yeniden boyutlandırıldı.</li> </ul> <p><b>Büyütme:</b></p> <ul style="list-style-type: none"> <li>• %10 yakınlaştırma</li> <li>• Yatay ve Dikey çevirme</li> <li>• 10° dönüş</li> </ul>
[67]	2020	234	CNN GA ile CNN	0.78 0.79	0.83 0.83	0.70 0.73	-	Kırık / Kırık olmayan	<p><b>Ön İşlem:</b> Tüm röntgen filmleri femur boyun kısmını gösterecek şekilde manuel olarak kırıldı ve 50*50, 100*100, 200*200 ve 400*400 olarak yeniden boyutlandırıldı.</p> <p><b>Büyütme:</b></p> <ul style="list-style-type: none"> <li>• Saat yönünde ve saat yönünün tersine 10°, 20° ve 30° dönüş.</li> <li>• Gauss gürültüsü uygulama</li> <li>• Yansıtılmış film</li> </ul>
[2]	2020	1063	ResNet	İki sınıf: 92.3% Üç sınıf: 86.0%	İki sınıf: 0.91 Üç sınıf: 0.79	İki sınıf: 0.93 Üç sınıf: 0.90	İki sınıf: 0.92 Üç sınıf: 0.96	Garden Sınıflandırması	<p><b>Ön İşlem:</b> Filmler 256*256 piksel olarak ayarlandı.</p> <p><b>Büyütme:</b></p> <ul style="list-style-type: none"> <li>• Rastgele Yatay/Dikey çevrildi.</li> <li>• -30° ve 30° Rastgele Dönüştürüldü</li> <li>• Rastgele Gauss Gürültüsü uygulandı</li> <li>• Rastgele kontrast titremesi</li> <li>• GAN</li> </ul>

									• DRR
[68]	2020	1347	ResNet-50 + AlexNet	-	-	-	İki sınıf: 0.98  Üç sınıf: 0.95	AO Sınıflandırma	<b>Ön İşlem:</b> <ul style="list-style-type: none"> <li>ResNet-50 için filmler 224*224 olarak yeniden boyutlandırıldı</li> <li>Filmler AlexNet için 227*227 olarak yeniden boyutlandırıldı.</li> </ul> <b>Büyütme:</b> <ul style="list-style-type: none"> <li>Çeviri</li> <li>Ölçekleme</li> <li>Rotasyon</li> </ul>
[69]	2020	14,374	Yoğun Net-121				<ul style="list-style-type: none"> <li>Konum ve donanım varlığı: 0.99-1.00.</li> <li>Sınıflandırma görevi ve proksimal femur kırığının tespiti: 0.95</li> </ul>		<b>Ön İşlem:</b> <ul style="list-style-type: none"> <li>Filmler 238*238 olarak yeniden boyutlandırıldı ve ardından son boyut olarak 224*224 boyutuna ulaştı.</li> </ul> <b>Büyütme:</b> <ul style="list-style-type: none"> <li>Rastgele parlaklık</li> <li>Rastgele kontrast</li> <li>Rastgele yatay çevirme</li> <li>Rastgele kırpma</li> </ul>
[70]	2020	786 röntgen filmi ve 459 rapor.	Kodlayıcı: GoogLeNet-Inception3  Kod çözücü: Bi-LSTM	Birinci mimari: 2 sınıf: %85,02  3 sınıf: %79,74  7 sınıf: %69,60  İkinci mimari: 2 sınıf: %86,78  3 sınıf: %82,38  7 sınıfı: %74,89	-	-	-	AO/OTA Sınıflandırma	<b>Ön İşlem:</b> <ul style="list-style-type: none"> <li>Filmler 512*512 piksel olarak yeniden boyutlandırıldı.</li> <li>Metinler kelimelerle ayrıştırıldı, tek sıcak kodlandı, 128-D'ye dönüştürüldü, ardından Bi-LSTM'ye aktarıldı.</li> </ul> <b>Büyütme:</b> <ul style="list-style-type: none"> <li>Rotasyon</li> <li>Çevirme</li> <li>Ölçekleme</li> <li>Dünya Temsili için Küresel Vektörler (GloVe) rapordaki sözcüğü vektör olarak temsil eder</li> </ul>
[71]	2020	2453	Inception V3	3 sınıf: 0.86  5 sınıf: 0.81	-	-	-	AO/OTA Sınıflandırması	<b>Ön İşlem:</b> <ul style="list-style-type: none"> <li>Filmler, sağ ve sol uyluk kemiği alanının net bir şekilde görülebilmesi için kırıldı.</li> <li>Filmler 299*299 piksel olarak yeniden boyutlandırıldı.</li> </ul>

[72]	2021	5204	PelvixNet	0.924	0.908	0.932	-	-	<b>Ön İşlem:</b> <ul style="list-style-type: none"> <li>Filmler 1024*1024 olarak yeniden boyutlandırıldı.</li> </ul> <b>Büyütme:</b> <ul style="list-style-type: none"> <li>Rastgele yatay ve dikey çeviriler</li> <li>Rastgele ölçeklendirme</li> <li>Rastgele yatay çevirme</li> <li>Rastgele döndürme</li> <li>Parlaklık</li> <li>Kontrast titremesi.</li> </ul>
[73]	2021	-	Mask R-CNN	85.4%	-	-	-	Kırık / Kırık olmayan	<ul style="list-style-type: none"> <li>Filmler JPEG'e dönüştürüldü</li> </ul>



## 4. MALZEME VE YÖNTEM

Son yıllarda, bilgisayarlı görünün görevlerinden biri olan film bölümlendirme, film analizi ve bununla bağlantılı birçok alanda kullanılmaktadır. Film bölümlendirme teknikleri tıbbi filmlerde ortaya çıktığından beri, tıbbi bakımın sürdürülebilirliğinde büyük bir ilerleme kaydedilmiştir. Tıbbi filmlerde, film bölümlendirmenin amacı, söz konusu ilgi noktasının, yani organların, hastalıkların veya anormalliklerin bölgesini bulmaktır.

Film bölütleme görevinin semantik bölütleme, örnek bölütleme ve panoptik bölütleme olmak üzere üç türü vardır [74]. Anlamsal, ya da semantik, segmentasyon, nesne örneklerini ayırt etmeden her pikseli ait olduğu kategoriye etiketlerken, örnek segmentasyonu, filmdeki her farklı nesne örneği için benzersiz bir etiket sağlar. Başka bir deyişle, örnek segmentasyonu, nesne algılama, nesne sınıflandırması ve nesne yerelleştirmesinin birleşimidir. Panoptik segmentasyon, semantik ve örnek segmentasyonu arasında birleşir.

### 4.1. MODELLER

#### 4.1.1. YOLO Ailesi

YOLO ailesi, gerçek zamanlı nesne algılama ve sınıflandırma için tasarlanmıştır. YOLO'nun ilk versiyonu ilk olarak Joseph Redmon ve diğ. tarafından 2016'da yayınlanmıştır [75]. You Only Look Once (Sadece Bir Kez Bak) anlamına gelen YOLO ismi, bu ailenin tespit ve sınıflandırma görevini tek bir CNN geçişinde gerçekleştirme yeteneğine sahip olduğu gerçeğini ifade etmektedir [76].

YOLO ağı, bir filmi hürelere böler ve her hücre için sınıf olasılığını ve sınırlayıcı kutuları tahmin eder. Bir ögenin hücre içindeki konumunu ve boyutunu hesaplar ve sınıf olasılığı, bir nesnenin belirli bir sınıfa ait olma olasılığını yansıtır. Nesne tespiti bulgularında örtüşen sınırlayıcı kutuları ortadan kaldırmak için "maksimum olmayan baskılama" tekniği kullanılır. YOLO'nun hızı ve hassasiyeti, onu otonom sürüş, robotik ve gözetim dahil olmak üzere çeşitli endüstrilerde değerli kılmaktadır.

YOLO algoritmalarının ana mimarisi üç ana ağıdan oluşmaktadır [76]:

- Omurga: Omurganın ana mimarisi CNN'den yapılmıştır. Burada, CNN, onlardan özellikler çıkarmak için giriş filmlerine uygulanır.
- Boyun: Bu ağda, çıkarılan özellikler işlenir ve daha sonra bir sonraki katmana aktarılmak üzere birleştirilir.
- Kafa: Bu ağ, gerçekleştirilmesi gereken görevle ilgili ağlardan oluşur. Omurgadan çıkarılan ve işlenen ve daha sonra boyundan toplanan özelliklere dayalı tahminlerde bulunmayı başarır.

#### 4.1.1.1. YOLOv5

YOLOv5 [77], Ultralytics tarafından 2020'de piyasaya sürülen YOLO ailesinin popüler bir versiyonudur. YOLOv5, YOLO ailesinin bulut sunucusu segmentasyon görevini destekleyen ilk sürümüydü. Basitliği, hızı ve doğruluğu nedeniyle bilgisayarlı görüş uygulamalarında yaygın olarak kullanılmaktadır. Minimum hesaplama kaynağıyla eğitmek kolaydır. YOLOv5 ağ mimarisi dört ana bileşenden oluşur: giriş fazı, omurga ağı, boyun ağı ve kafa çıkış fazı. Giriş aşaması,  $416 \times 416$  ağ giriş boyutunu karşılamak için film ön işleme, büyütme ve ölçeklendirmeyi içerir [78]. Focus, Conv, C3 ve Uzamsal Piramit Havuzu (Spatial Pyramid Pooling, SPP) modüllerinden oluşan omurga ağı, çeşitli boyutlarda film unsurları toplar ve üretir. C3 modülünü basamaklandırmak için darboğazlar ve üç evrişim katmanı kullanılır. Yukarı örnekleme yaklaşımı, komşu düğümdeki önceki katman füzyonunun çözünürlüğünü artırır. Boyun ağı, film özelliklerini bütünleştirir ve birleştirir, bu da özellik aralığını genişletir [78]. Kafa çıkış terminali, film özelliklerinden öge sınırlama kutuları oluşturur, nesne sınıflarını sınıflandırır ve sonuçları tahmin eder. Model, doğruluk ve çıkarım süresine dayalı seçim ile nanodan ekstra büyüğe kadar değişen beş varyanta sahiptir.

#### 4.1.1.2. YOLOv7

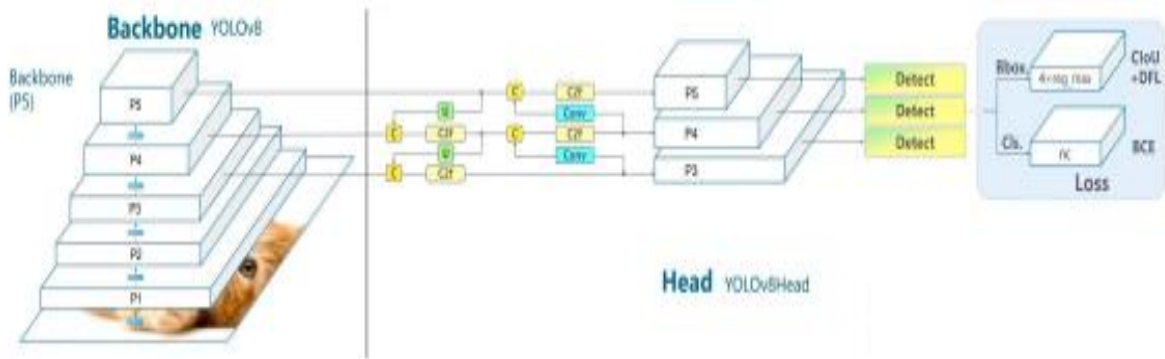
YOLOv7 [79], tarafından yayımlanan YOLO ailesinin bir uzantısıdır. WongKinYiu ve Alexey Bochkovskiy tarafından 2022'de piyasaya sürülmüştür. YOLOv7 ağı dört bölüme ayrılmıştır: giriş, omurga, kafa ve tahmin. Giriş modülü, giriş filmlerini hedef algılama boyutu kriterlerine uyacak şekilde ayarlar. BConv evrişimli katmanlar, Genişletilmiş Verimli Katman Toplama Ağı (Extended Efficient Layer Aggregation Network, E-ELAN) evrişimli katmanlar ve (MPCConv) evrişimli katmanlar omurgayı oluşturur. E-ELAN evrişimli katman, yeni özellikleri öğrenirken orijinal ELAN tasarım mimarisini korur. MPCConv evrişimli katman, BConv katmanını bir Max havuz katmanı ile genişleterek iki dala sonuçlanır. Üst dal, film yönünü ikiye bölmek için Maxpool'u kullanırken, alt dal, film kanallarını ikiye bölmek için ilk BConv katmanını kullanır. Cat işlemi, unsur ayıklama yeteneklerini geliştirmek için üst ve

alt dallardaki unsurları birleştirmek için kullanılır. Çeşitli düzeylerde etkili özellik füzyonu için, Head/Kafa modülü bir Yol Toplama Özelliği Piramit Ağı (Path Aggregation Feature Pyramid Network, PAFPN) yapısı kullanır. Tahmin modülü, Yeniden Parametrelendirilmiş Evrişimli Blok (Reparameterized Convolutional Block, REP) yapısını ve güvenilirlik, kategori ve bağlantı çerçevesi tahmini için 1x1 evrişimi kullanarak P3, P4 ve P5 özelliklerinin farklı ölçekleri için film kanallarını ayarlar.

#### 4.1.1.3. YOLOv8

YOLOv8 [80], YOLO ailesinin en son sürümüdür ve 2023 yılında Ultralytics tarafından piyasaya sürülmüştür. YOLOv5 gibi YOLOv8 için de henüz bir makale yayınlanmamıştır; modelle ilgili tüm bilgiler Ultralytics'in GitHub sayfasında bulunmaktadır.

YOLOv8, hesaplamayı hızlandırmak için iki evrişimli katmana ve bir Uzamsal Piramit Havuzlama Hızlı (SPPF) modülüne sahip değiştirilmiş (Çapraz Aşama Kısmi Ağ) CSPDarknet53 [81] omurgasını kullanan bir DL modelidir. Sınıflandırma ve nesne algılama için ayrılmış bir kafa, nesne algılama için bir sigmoid aktivasyon işlevi ve sınıflandırma olasılığı için bir softmax işlevi kullanır. Model bağlayıcısızdır ve farklı veri kümeleri üzerinde eğitim almayı kolaylaştırır. YOLOv8, Maksimum-Olmayan Bastırma (Non-Maximum Suppression, NMS) [81] yerine Yumuşak Maksimum Olmayan Bastırmayı (softNMS) tanıtan, hedef bilgileri koruyan ve Yanlış Pozitif ve Yanlış Negatif [82] gibi durumları azaltan ilk sürümdür. Modelin, doğruluk ve çıkarım süresine dayalı seçim ile nanodan ekstra büyüğe kadar değişen beş çeşidi vardır [83]. Ayrıca örnek segmentasyonu, nesne algılama ve izleme ve poz tahmini gibi diğer görevleri de sağlar.



Şekil 4.1 YOLOv8 Modelin Mimarisi [84]


#### 4.1.2. Mask R-CNN [51]

Mask R-CNN, son teknoloji ürünü örnek segmentasyon görevidir. Mask R-CNN, nesne algılama algoritmaları olan R-CNN'nin (Bölge Tabanlı CNN) bir uzantısı olan Fast R-CNN'nin geliştirilmiş bir versiyonu olan Faster R-CNN üzerine inşa edilmiştir. Mask R-CNN ile üzerine inşa edildiği algoritmalar arasındaki temel fark, Mask R-CNN'nin yalnızca sınırlayıcı kutular oluşturmaması, aynı zamanda nesne algılama görevi için maskeler oluşturmasıdır. YOLO ailesinden farklı olarak, Mask R-CNN iki aşamalı bir algoritmadır, bölge önerilerini çıkarmak için bir adım, sınırlayıcı kutularla maskeleri sınıflandırmak ve oluşturmak için başka bir adımdır.

Mask R-CNN, Faster R-CNN'nin üzerine inşa edildiğinden, Mask R-CNN'nin mimarisi, maske segmentasyonlarını önceden belirlemek için ek bir ağ ile Faster R-CNN'ye neredeyse benzerdir. Mask R-CNN mimarisi şunlardan oluşur:

- Omurga Ağı: Bu ağda, özellikler giriş filmlerinden çıkarılır ve bunun için özellik haritalarını oluşturan ResNet ağı kullanılır.
- Öneri Bölgesi Ağı (Region Proposal Network, RPN): Omurga ağından elde edilen özellik haritaları, bazı nesnelere içeren bölge önerileri oluşturmak için bu ağda kullanılır.
- İlgi Bölgesi Hizalaması (ROI Hizalaması): Faster R-CNN arasındaki farklardan biri de ROI'nin türüdür. Daha Hızlı R-CNN ROI havuzunu kullanırken, Mask R-CNN ROI hizalamasını kullanır. Bu değişiklik, veri kaybından ve ROI havuzunun neden olduğu yanlış hizalama sorunundan kaynaklanmaktadır. İki ROI türünün amacı, önceki ağdan çıkarılan bölgeleri sabit bir boyuta yeniden boyutlandırmaktır. Yeniden boyutlandırılan bölgeler daha sonra Sınırlayıcı Kutu Başlığına ve Maske Başlığına paralel olarak geçirilir.
- Sınırlayıcı Kutu Başlığı: Bu dal, belirli bir bölgenin sınırlayıcı kutularını ve sınıf etiketlerini tahmin etmek için yeniden boyutlandırılan bölgeleri alan tam bağlantılı katmandan oluşur.

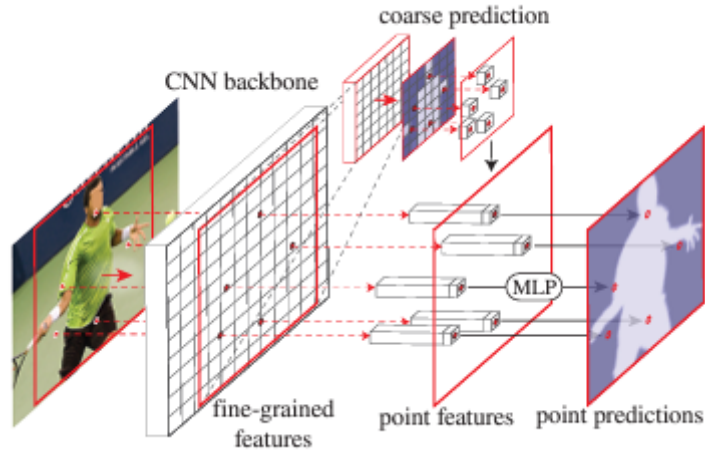
- Maske Başlığı: Bu dal, tahmin edilen sınırlayıcı kutuda tahmin edilen nesnenin maskesini çıkarmak için yeniden boyutlandırılan bölgeleri alan tamamen evrişimli ağdan oluşur.



Şekil 4.2 Maske R-CNN Model Mimarisi

#### 4.1.3. PointRend

PointRend [85] modeli 2020 yılında yayınlanmıştır. PointRend, bilgisayar grafiklerindeki işleme (rendering) kavramından gelmiştir. Model, her piksele tek bir etiket vermek yerine, filmin nesnelere özelliklerine ve kenarlıklarına ince ayar yapmaya odaklanır. Yaklaşım, segmentasyon maskelerini resmin tamamı yerine yerel nokta bazında tahmin eder. Bu, modelin küçük özellikleri yakalamasını ve karmaşık nesne sınırlarını daha başarılı bir şekilde yönetmesini sağlar. PointRend, anında her piksel için alıcı alanı değiştiren uyarlanabilir bir evrişimli operatör kullanır. Bu esneklik, modelin resmin çeşitli alanları için ilgili bağlama odaklanmasına yardımcı olur. Model, tahminlerini tekrar tekrar iyileştirir ve sonunda segmentasyon maskelerinin kalitesini artırır. Bu sürekli artırma prosedürü, hassas özelliklerin yakalanmasına ve daha pürüzsüz kenarlıkların üretilmesine yardımcı olur. Şekil 4.3, PointRend'in mekanizmasını göstermektedir.



Şekil 4.3 PointRend Model Mimarisi [85]

## 4.2. PERFORMANS DEĞERLENDİRME METRİKLERİ

Değerlendirme metrikleri, ML ve DL'de bir modeli değerlendirmede çok önemlidir. Bir modelin kalitesini ölçmek ve bu modelin ne kadar iyi performans sunduğunu göstermek için kullanılırlar. Ayrıca farklı modellerin karşılaştırılmasına da yardımcı olurlar. Örnek segmentasyon algoritmalarının performansını değerlendirmek için Precision (Hassasiyet), Recall (Geri Çağırma) ve mAP (Ortalama Hassasiyetin Ortalaması) gibi çeşitli değerlendirme metrikleri kullanılır.

### 4.2.1. Hassasiyet (P)

Hassasiyet, modelin pozitif tahminleri ne kadar doğru bir şekilde tahmin edebildiğini ölçer. Hassasiyet, doğru tahmin edilen örnekleri tüm pozitif tahminlerin toplamına bölerek hesaplanır (Denklem 1).

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \quad (1)$$

### 4.2.2. Geri Çağırma (R)

Geri çağırma, duyarlılık ve gerçek pozitif oran (TPR) olarak da bilinir. Modelin tüm pozitif vakaları ne kadar iyi tespit edebildiğini ölçer. Doğru tahmin edilen örneklerin toplam gerçek pozitif örnek sayısına oranıdır (Denklem 2).

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (2)$$

#### 4.2.3. Ortalama Hassasiyetin Ortalaması (mAP)

Ortalama Hassasiyetin Ortalaması, her sınıf için farklı İkişyon üzerine Birlik (IoU) eşiklerinde hesaplanan Ortalama Hassasiyet (AP) değerlerinin ortalamasıdır (Denklem 3).

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (3)$$

### 4.3. VERİ KÜMESİ/SETİ

#### 4.3.1. Veri Seti Edinimi ve Açıklaması/Etiketlenmesi

Bu tezde kullanılan kalça X-ışını görüntülerinin veri seti oluşturulma aşamalarından birkaç aşamadan geçmiştir.

- **Veri Toplama:** Kalça/pelvik/proksimal kırıkları kapsayan veri kümelerinin çok az olduğu düşünülmektedir. Bu nedenle veriler farklı kaynaklardan toplanmıştır. Çeşitli kaynaklar Tablo 4.1'de listelenmiştir.
- **Veri Sınıflandırması:** Veri setinde 321 röntgen normal, kırıksız ve 435 röntgen kırıklı olmak üzere toplam 756 kalça radyografisi bulunmaktadır. Kırık filmler çıkık, boyun kırığı, intertrokanterik kırık, rende trokanter kırığı, küçük trokanter kırığı ve subtrokanterik kırık olarak sınıflandırılmıştır. Sınıflandırma bir ortopedi doktoru tarafından yapılmıştır. Veri tabanı kombinasyonu Tablo 4.2'de sunulmuştur.
- **Veri Açıklaması/Etiketlenmesi:** Kırığın kesin şekillerini, boşluklarını ve yerlerini yakalamak için, Roboflow platformunda çokgen segmentler kullanılarak filmlere manuel olarak açıklama eklenmiştir [86]. Verinin örnekleme işlemi, örneğin segmentasyon teknikleri için Roboflow kullanılarak yapılan bir örnekleme, Şekil 4.4'te gösterilebilir. Etiketleme işlemi bir ortopedi doktorunun denetimi altında gerçekleştirilmiştir.
- **Veri Ön İşleme:** Roboflow üzerinde gerçekleştirilen veri açıklama işleminden sonra ekstra ön işleme işlemine ihtiyaç duyulmuştur. Veri ön işleme teknikleri Roboflow kullanılarak uygulanmıştır. Kullanılan ön işleme teknikleri şunlardır:

- Otomatik Yönlendirme
- 640x640 olarak yeniden boyutlandırma: Filmler farklı kaynaklardan toplandığı için çeşitli boyutlardadır. Veri setinin durumunu gösteren Roboflow panosuna göre medyan film oranı 2144×2021 idi. Bu nedenle, tüm filmler aynı 640×640 boyutuna getirilmiştir.
- Histogram Eşitleme kullanılarak ayarlanan kontrast: Ana hattın görünür olabilmesi için bazı filmlerin kontrast açısından iyileştirilmesi gerekmiştir.
- Gri tonlama
- **Veri Dışa Aktarma:** Açıklamalı veriler, COCO [87] formatı ve YOLO formatı olmak üzere iki formatta dışa aktarılmıştır. COCO formatı, tüm filmlerin ek açıklamalarını her veri kümesi (eğitim, doğrulama, test) için tek bir json dosyasına kaydeder. Aksine, YOLO formatı her filmin açıklamasını bir .txt dosyasına kaydeder.

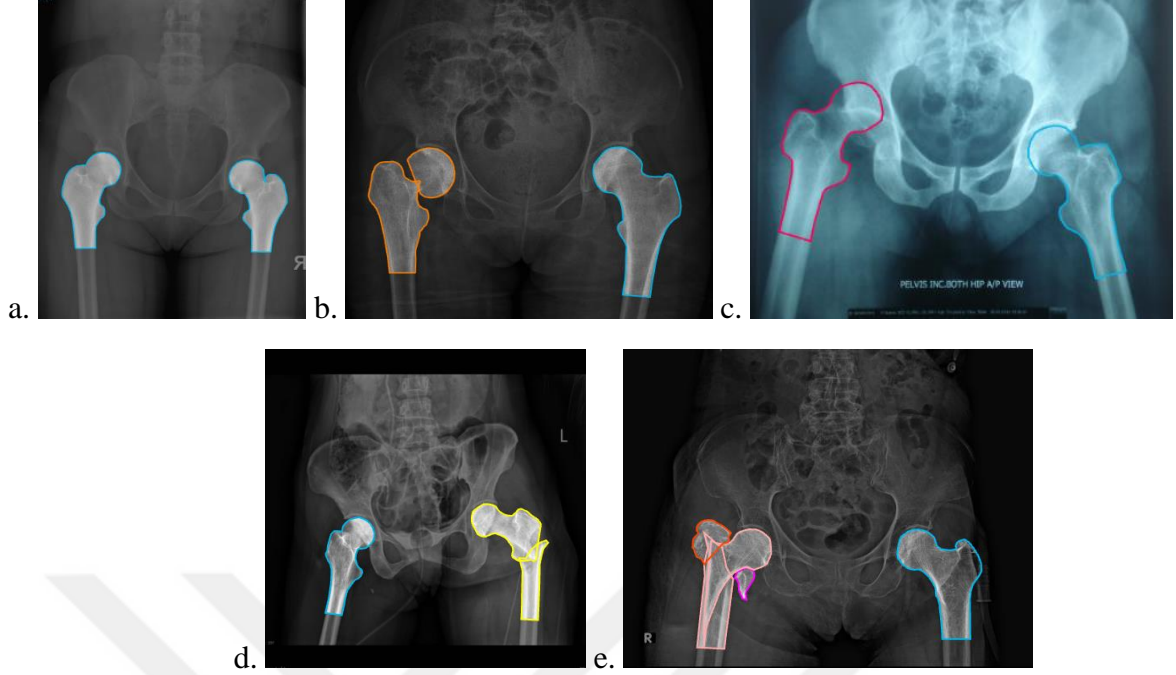
**Tablo 4.1** Veri Toplama

Veri Kümesi/Seti Adı	Kullanılan Filmlerin Sayısı
<b>Hip-fx [88]</b>	102
<b>PelvixNet [72]</b>	97
<b>ChestPelvisCSpineScans [89]</b>	192
<b>Radiopaedia.org [90]</b>	21
<b>Pelvis AP X-ray [91]</b>	43
<b>Hip Fracture Detection [92]</b>	60
<b>Fracture Detection [93]</b>	78
<b>Testset [94]</b>	45
<b>Validate Set Hip Bone Dataset [95]</b>	59
<b>Global Internet Search</b>	103
<b>Roboflow tarafından tekrarlanan filmleri kaldırmadan önce</b>	800
<b>Roboflow tarafından tekrarlanan filmleri kaldırdıktan sonra</b>	756
<b>Test Veri Seti: h5ybüne Dataset [96]</b>	30

**Tablo 4.2** Veri Kümesi Birleşimi

<b>Tür</b>		<b>Filmlerin Sayısı</b>
<b>Normal</b>		321
<b>Çıkık</b>		64
<b>Kırık</b>	Boyun	138
	Büyük Trokanter	24
	İntertrokanterik	50
	Küçük Trokanter	Karışık kırık filmlerinde daha küçük trokanter görülür.
	Subtrokanterik	46
<b>Karışık Kırık Filmleri (Kırıktan daha fazlasını içeren filmler)</b>		115
<b>Toplam</b>		756

Roboflow, oluşturma aşamasından dağıtıma kadar CV ve ML projeleri üzerinde çalışma sürecini basitleştiren bir dizi araç sunan bir platformdur. Veri ön işleme, veri etiketleme/açıklama ve veri artırma için araçlar sunar. Ayrıca, YOLO, SSD, VGG gibi bir dizi CV modeli sağlayarak hazırlanan verileri eğitmeye olanak tanır. Son olarak, Roboflow projeleri uygulamalar, web siteleri veya diğer hizmetler olarak dağıtmaya olanak sağlar. Böylece büyük açık kaynaklı CV veri setlerini sunan bir ortam sunar [97].



**Şekil 4.4** Polygon Aracı ile Açıklanmış/Etiketlenmiş Veriler

Roboflow'da segmentasyon gibi çokgen açıklama kullanılarak filmlere nasıl açıklama/etiketleme eklendiğini gösteren filmler. **a)** Normal. **b)** Sağ tarafta boyun kırığı ve sol tarafta normal. **c)** Sağ tarafta çıkık ve sol tarafta normal. **d)** Sol tarafta subtrokankerik ve sağ tarafta normal. **e)** Sağ tarafta intertrokanterik, büyük ve küçük trokanter kırığı ve sol tarafta normal.


#### 4.4. VERİ BÜYÜTME

Modeller, eğitim setine veri büyütme teknikleri uygulanmış/uygulanmamış olmak üzere iki biçimde eğitilmiş ve değerlendirilmiştir. Veri büyütme aşamasında, eğitim setine uygulanan teknikler şunlardır:

- Yansıma: Yatay, Dikey
- 90° Döndürme: Saat Yönünde, Saat Yönünün Tersine, Ters Çevirme
- Döndürme: -30° ile +30° arasında
- Eğme:  $\pm 15^\circ$  Yatay,  $\pm 15^\circ$  Dikey
- Parlaklık: -10% ile +10% arasında
- Işık: -25% ile +25% arasında

- Gürültü: Piksellerin %3'üne kadar

Artırılmış filmlerin bir örneği Şekil 4.5'te gösterilmektedir.



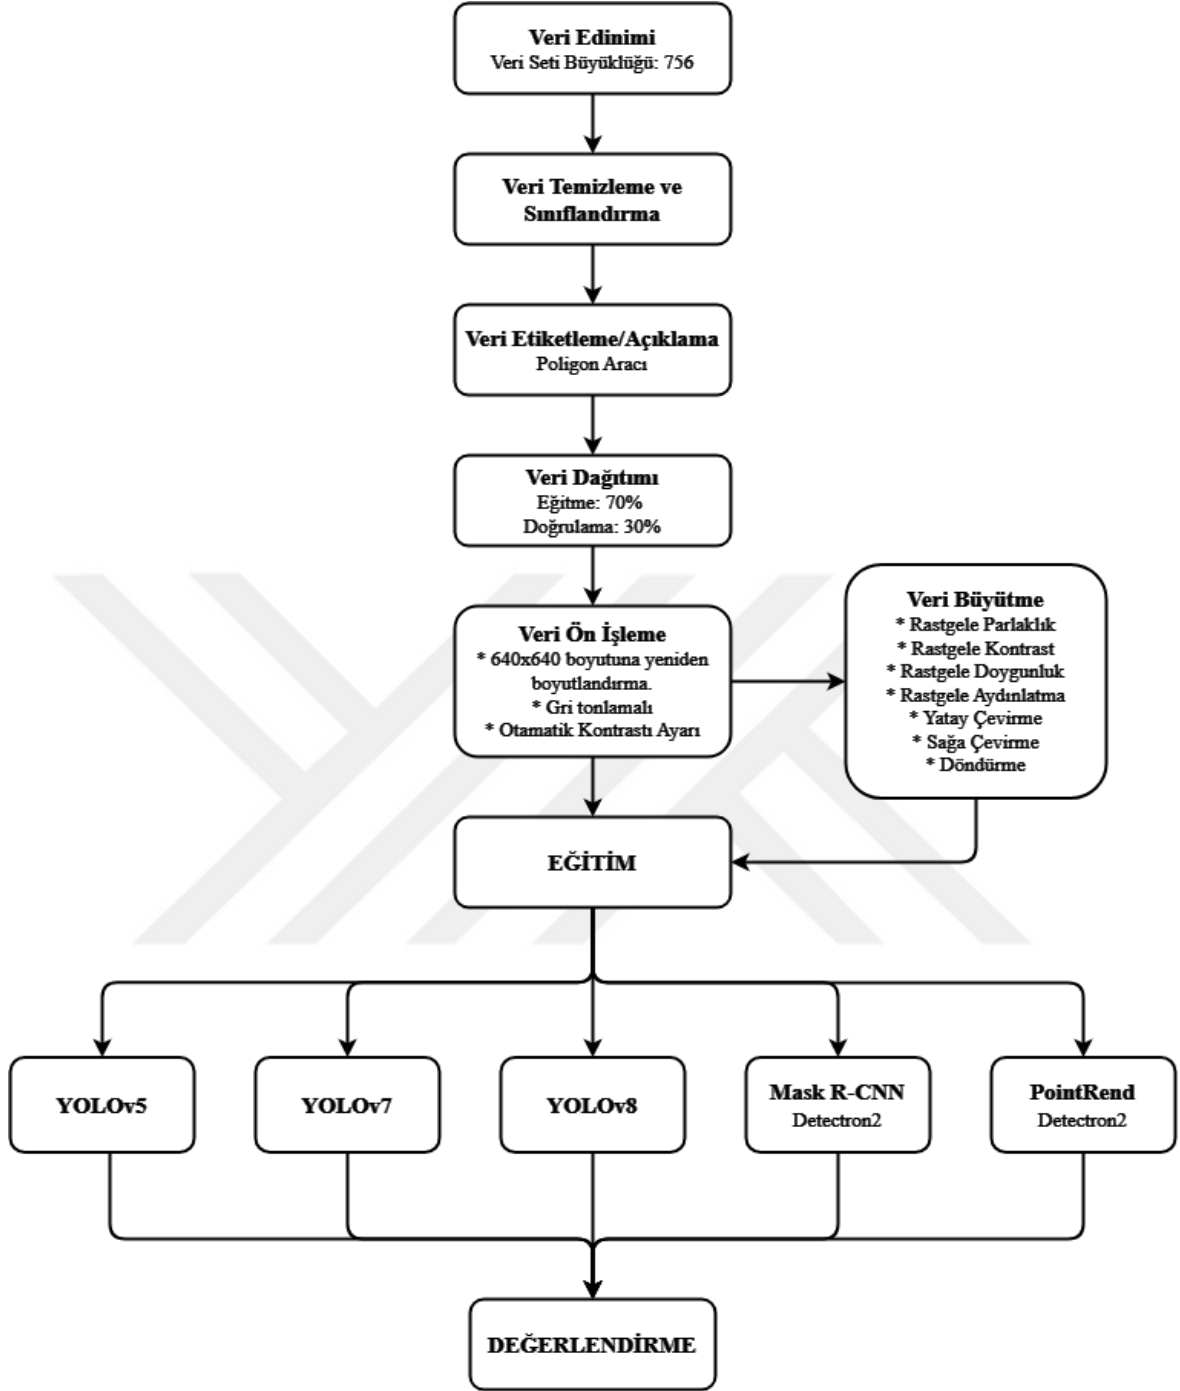
Şekil 4.5 Artırılmış Film Örneği

#### 4.5. SİSTEM ORTAMI

Kullanılan dizüstü bilgisayarda Intel(R) Core(TM) i7-3610QM CPU @2.30GHz 2.30GHz işlemci, 6,00 GB RAM, 64 bit işletim sistemi ve x64 tabanlı işlemci bulunmaktadır. Modellerin cihaz üzerinde eğitilmesi çok zaman almıştır. GPU olmamasından dolayı GPU'ya ücretsiz erişim sağlayan Google Colab gibi bulut tabanlı bir platforma geçme kararı alınmıştır.

#### 4.6. İŞ AKIŞ SÜRECİ

Bu tezin iş akış süreci aşağıda gösterilmektedir.



Şekil 4.6 İş Akış Süreci

## 5. SONUÇLAR

### 5.1. YOLO MODELLERİ

Tüm YOLO modelleri, önceden eğitilmiş modeller kullanılarak segmentasyon görevi için eğitilmiştir. Önceden eğitilmiş modeller, Github depolarına göre COCO veri kümesi [87] üzerinde eğitilmiştir. YOLOv5 ve YOLOv8 için "x" boyutu (yolov5x-seg.pt ve yolov8x-seg.pt), YOLOv7 için (yolov7) kullanılmıştır. Çünkü "x" boyutu yüksek GPU ve RAM belleğine ihtiyaç duymaktadır (ilk dönemden itibaren Google Colab craches'te çalışırken).

Her üç model de 200 dönem için, parti büyüklüğü 16 ve öğrenme oranı 0.001 olarak eğitilmiştir. Genel kategoriler üzerindeki nihai değerlendirme metriklerinin değerleri Tablo 5.1'de gösterilmektedir. Bu değerlere göre, YOLOv8, 50 IoU eşliğinde segmentasyon için Ortalama Hassasiyetin Ortalaması açısından YOLOv5 ve YOLOv7'yi ve 0,85 değeriyle hem sınırlayıcı kutu (Bounding Box) hem de maskeler için Hassasiyet açısından geçmiştir. YOLOv5, hem sınırlayıcı kutular hem de maskeler için 0,79 değeriyle geri çağırma açısından YOLOv7 ve YOLOv8'i geride bırakmıştır.

Tablo 5.2, her kategori için üç modelin eğitim metrikleri sonuçlarını sunmaktadır. Tablo 5.2'ye göre YOLOv8, geri çağırma açısından subtrokanterik, büyük trokanter, boyun ve intertrokanterik, mAP50 ve mAP50-95 olmak üzere dört kategoride YOLOv5 ve YOLOv7'yi hem sınırlayıcı kutular hem de maskeler için ve çıkık, küçük trokanter, büyük trokanter ve intertrokanterik olmak üzere dört kategoride Hassasiyet açısından geride bırakmıştır. YOLOv5, tüm metriklerde normal kategoride YOLOv7 ve YOLOv8'i geçmiştir.

Eğitim ve doğrulama sürecinde farklı kayıpların ve değerlendirme metrik değerlerinin üzerindeki değişim, YOLOv5 için Şekil 5.1'de, YOLOv7 için Şekil 5.2'de ve YOLOv8 için Şekil 5.3'te verilmektedir. Rakamlar, farklı kayıpların 0 değerlerinin altına düştüğünü göstermektedir.

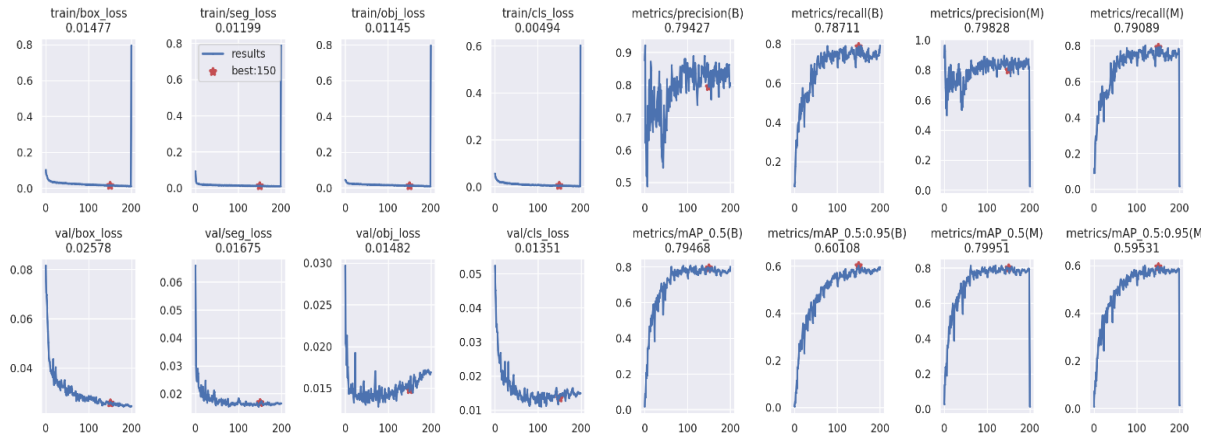
**Tablo 5.1** YOLO Modelleri Eğitim Sonuçları

Model	Sınırlayıcı Kutular Metrikleri Performansı				Maske Metrikleri Performansı			
	P	R	mAP 50	mAP 50-95	P	R	mAP 50	mAP 50-95
YOLOv5	0.794	0.787	0.795	0.602	0.798	0.791	0.8	0.595
YOLOv7	0.846	0.764	0.792	0.593	0.848	0.766	0.788	0.578
YOLOv8	0.82	0.797	0.816	0.613	0.819	0.805	0.817	0.611

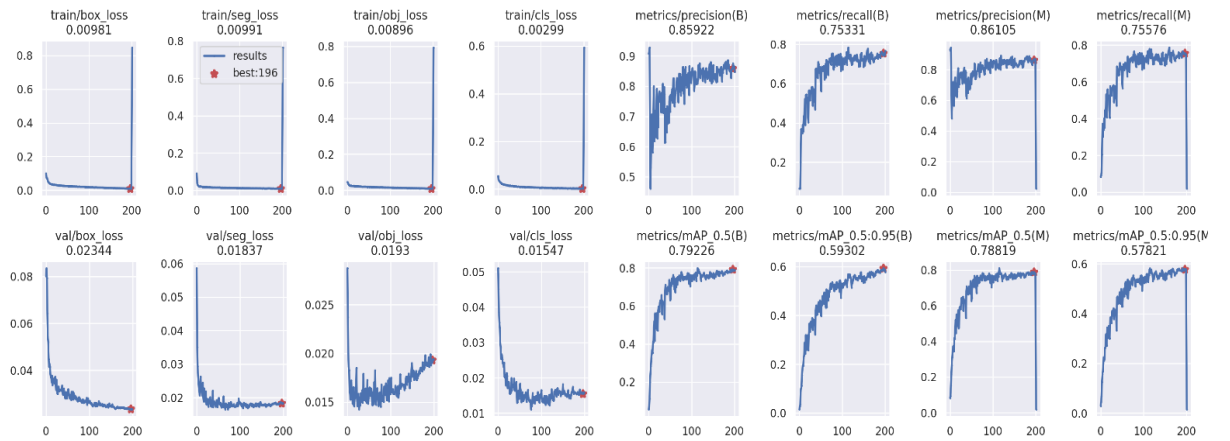
**Tablo 5.2** YOLO Modellerinin Her Sınıf için Eğitim Metrik Sonuçları

Model	Kategori	Sınırlayıcı Kutular Metrikleri Performansı				Maske Metrikleri Performansı			
		P	R	mAP 50	mAP 50-95	P	R	mAP 50	mAP 50-95
YOLOv5	Çıkığı	0.92	0.95	0.94	0.68	0.94	0.97	0.97	0.75
	Küçük Trokanter	0.72	0.84	0.85	0.64	0.72	0.84	0.85	0.59
	Subtrokanterik	0.69	0.80	0.69	0.49	0.68	0.78	0.69	0.46
	Büyük Trokanter	0.65	0.35	0.45	0.35	0.65	0.35	0.45	0.31
	Boyun	0.90	0.71	0.84	0.65	0.90	0.71	0.85	0.65
	İntertrokanterik	0.75	0.85	0.81	0.59	0.77	0.88	0.83	0.55
	Normal	0.93	1	0.97	0.91	0.93	1	0.97	0.86
YOLOv7	Çıkığı	0.95	0.95	0.98	0.70	0.95	0.95	0.98	0.76
	Küçük Trokanter	0.80	0.81	0.85	0.60	0.80	0.81	0.85	0.56
	Subtrokanterik	0.74	0.71	0.70	0.50	0.74	0.71	0.70	0.47
	Büyük Trokanter	0.81	0.33	0.40	0.30	0.80	0.33	0.37	0.22
	Boyun	0.92	0.74	0.83	0.65	0.92	0.74	0.83	0.64
	İntertrokanterik	0.79	0.81	0.83	0.60	0.80	0.83	0.84	0.55
	Normal	0.91	1	0.95	0.81	0.92	1	0.95	0.85
YOLOv8	Çıkığı	0.97	0.74	0.86	0.66	1	0.77	0.92	0.71

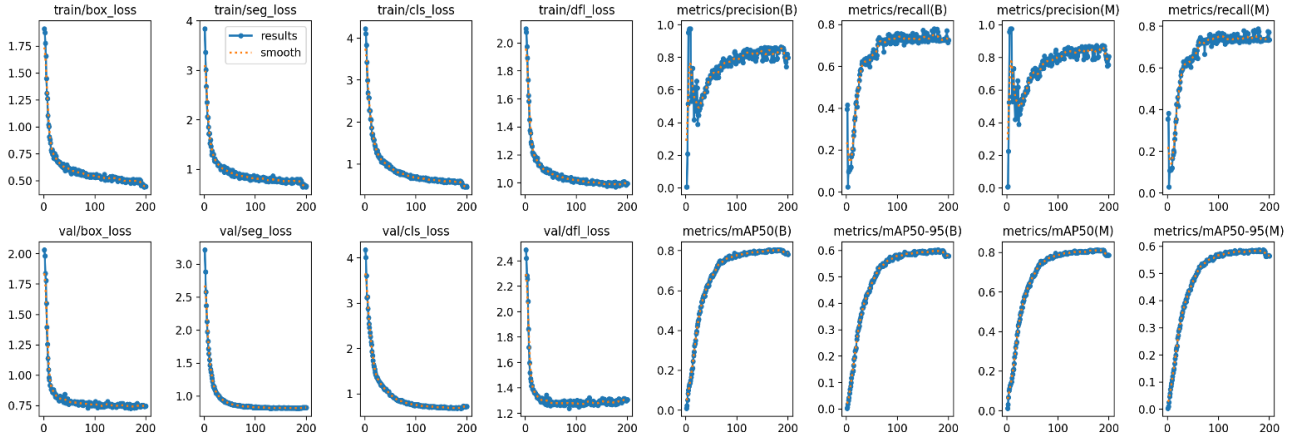
Küçük Trokanter	0.91	0.23	0.43	0.31	0.91	0.23	0.43	0.29
Subtrokanterik	0.71	0.87	0.83	0.58	0.71	0.87	0.82	0.53
Büyük Trokanter	0.82	0.78	0.84	0.64	0.82	0.78	0.83	0.56
Boyun	0.92	0.79	0.91	0.73	0.92	0.79	0.91	0.69
İntertrokanterik	0.89	1	0.97	0.82	0.89	1	0.97	0.86
Normal	0.75	0.79	0.75	0.50	0.73	0.77	0.74	0.45



Şekil 5.1 YOLOv5 Metrikleri Görselleştirme: Eğitim ve Doğrulama




Şekil 5.2 YOLOv7 Metrikleri Görselleştirme: Eğitim ve Doğrulama




Şekil 5.3 YOLOv8 Metrikleri Görselleştirme: Eğitim ve Doğrulama

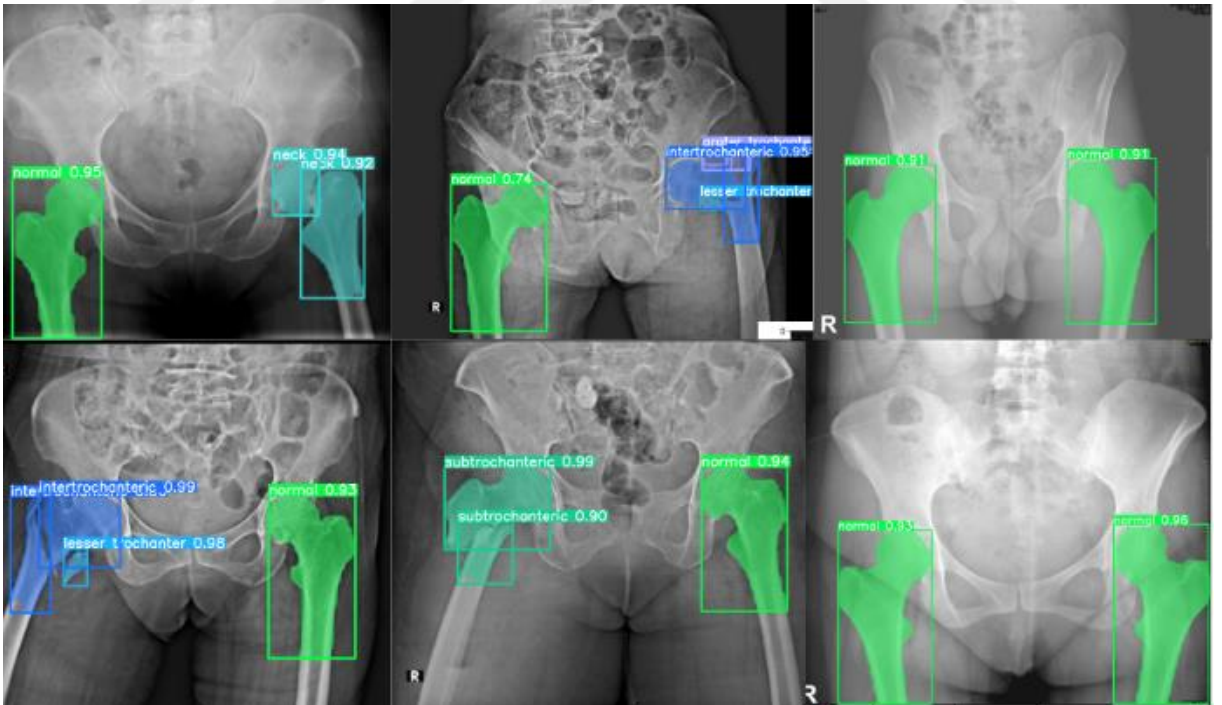
Üç model de daha önce görülmemiş bir film kümesinde[96] test edilmiştir. Tahminin sonuçları YOLOv5 için Şekil 5.4'te, YOLOv7 için Şekil 5.5'te ve YOLOv8 için Şekil 5.6'da gösterilmektedir.



Şekil 5.4 Test Verilerinde YOLOv5 Tahmini Sonuçlar



Şekil 5.5 Test Verilerinde YOLOv7 Tahmini Sonuçlar



Şekil 5.6 Test Verilerinde YOLOv8 Tahmini Sonuçlar

## 5.2. Mask R-CNN'nin Sonuçları

Mask R-CNN, Detectron2 [98] tarafından sunulan iki farklı önceden eğitilmiş model kullanılarak çeşitli proksimal femur kırıklarını tespit etmek için eğitilmiştir. Önceden eğitilmiş modelin omurgası, FPN ile ResNet50 ve ResNet101 üzerine inşa edilmiş ve COCO veri kümesi üzerinde eğitilmiştir.

İlk adım olarak Mask R-CNN modelleri, en iyisinin seçilebilmesi için farklı öğrenme oranlarıyla eğitilmiştir. İki model, 0,0001, 0,001 ve 0,01 olmak üzere farklı öğrenme oranlarıyla eğitilmiştir. Öğrenme oranı değeri 0,01 olduğunda model değerlendirme metrikleri yüksek olduğu için öğrenme oranı değeri 0,01 olarak sabitlenmiştir. Daha sonra modeller 2500 iterasyon için eğitilmiştir. Modellerin iyi öğrenmesi için 2500 iterasyon yeterli olmadığından iterasyon sayısı 10000'e çıkarılmıştır. Yığın (Batch) büyüklüğü 8 olarak alınmıştır.

Mask R-CNN modelleri büyütme teknikleri uygulanarak ve uygulanmadan eğitilmiştir. Ayrıca, bunlar, varsayılan hiper parametreler değerleriyle veya bazı hiper parametreler değerlerini değiştirerek eğitilmiştir.

İnce ayar sürecinde değişen hiper parametreler değerleri, 0.9'dan 0.95'e kadar olan momentum ve 0.0001'den 0.001'e ağırlık azalması olmuştur. Modellerin küçük nesnelere algılama yeteneğini artırmak için çapa boyutu (16, 32, 64, 128, 256, 512, 640) ve çapa oranları (0.3, 0.5, 1.0, 2.0, 3.0) olarak ayarlanmıştır.

Tablo 5.3, her iki model için gerçekleştirilen denemelerin metrik değerlerini göstermektedir ve bunlar aşağıdaki gibidir:

- Model1: ResNet50+FPN Büyütme olmadan ve varsayılan değerlerle.
- Model2: ResNet101+FPN Büyütme olmadan ve varsayılan değerlerle.
- Model3: ResNet50+FPN Büyütme ve varsayılan değerlerle.
- Model4: ResNet101+FPN Büyütme ve varsayılan değerlerle.
- Model5: ResNet50+FPN Büyütme olmadan ve ince ayar.
- Model6: ResNet101+FPN Büyütme olmadan ve ince ayar.

- Model7: ResNet50+FPN Büyütme ve ince ayar.
- Model8: ResNet101+FPN Büyütme ve ince ayar.

**Tablo 5.3** Mask R-CNN Modelleri Genel mAP Değerleri

	Modeller							
	Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
<b>SINIRLAYICI KUTULAR</b>								
<b>AP</b>	47.84	48.58	47.65	48.95	48.40	48.07	48.99	45.55
<b>mAP50</b>	70.06	70.07	73.82	71.88	70.76	69.81	73.03	70.36
<b>mAP75</b>	54.02	54.17	51.45	50.92	52.62	52.18	55.09	47.63
<b>mAPs</b>	0	0	8.42	10.10	14.31	4.49	0	11.78
<b>mAPm</b>	45.67	43.62	42.92	42.49	44.40	44.78	38.08	41.25
<b>mAPI</b>	51.83	52.85	50.53	53.60	51.14	51.60	53.19	49.95
<b>MASKE</b>								
<b>AP</b>	48.50	48.96	48.93	49.93	48.75	49.27	50.09	46.04
<b>mAP50</b>	71.29	72.27	74.05	72.05	72.35	71.15	73.70	70
<b>mAP75</b>	53.25	51.73	52.34	54.61	53.76	55.47	56.11	49.68
<b>mAPs</b>	0	0	3.37	1.12	2.67	1.92	0	4.77
<b>mAPm</b>	43.45	38.85	38.62	39.89	40.17	40.92	36.17	37.81
<b>mAPI</b>	55.58	55	53.90	55.72	53.78	55.10	55.41	51.81

Tablo 5.3 ve Tablo 5.4'teki sonuçlardan hem büyütme tekniklerinin uygulanmasının hem de hiper parametre değerlerindeki değişikliğin önemli bir etki oluşturmadığı görülmektedir. Sınırlayıcı kutuların mAP50'si 69,81 ile 73,82 arasında, maskelerin mAP'si ise 71,15 ile 74,05 arasında değişmektedir.

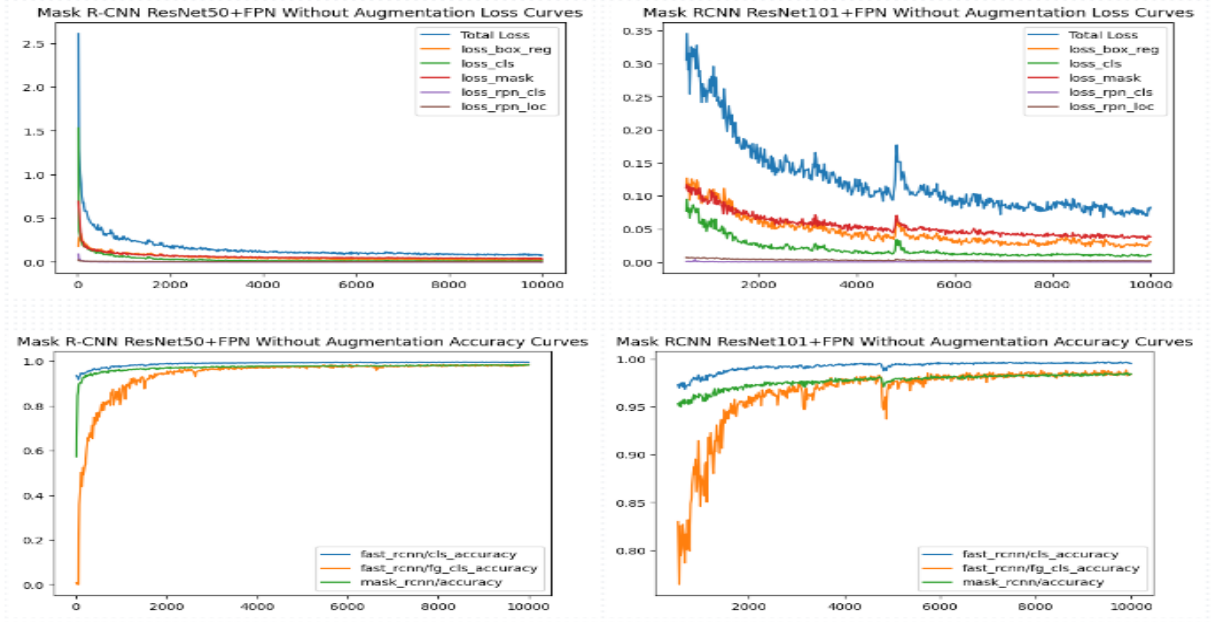
Tablo 5.3'te sunulan sonuçlara göre Model3, sınırlayıcı kutular ve maskeler için en iyi mAP50 değerine sahiptir. Model3, sınırlayıcı kutular için 73,82 ve maskeler için 74,05 değerine ulaşmıştır.

mAP açısından Model4, sınırlayıcı kutular için 14,31 değeriyle en iyi değere sahipken Model7, maskeler için 4,77 değeriyle en iyi değere sahiptir.

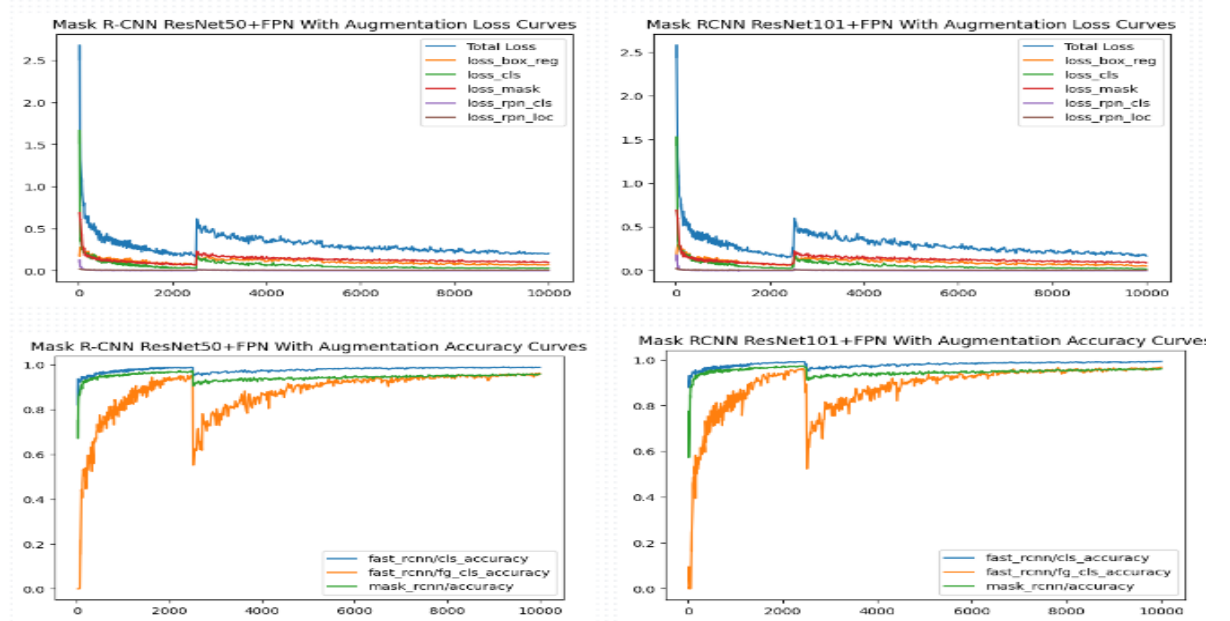
**Tablo 5.4** Mask R-CNN'nin Tüm Kategoriler Üzerindeki mAP Değerleri

Kategori	Modeller							
	Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
<b>SINIRLAYICI KUTULAR</b>								
Çıkığı	45.90	52.79	57.91	55.62	44.25	42.23	66.43	50.38
Küçük Trokanter	51.95	52.75	73.82	54.08	54.48	55.11	48.37	52.63
Subtrokanterik	40.51	35.87	35.92	35.08	39.97	35.88	32.18	31.77
Büyük Trokanter	16.80	20.88	16.68	20.55	22.67	16	19.07	15.75
Boyun	54.94	51.88	57.95	54.10	54.97	58.12	53.68	50.17
İntertrokanterik	49.47	49.23	43.01	45.77	46.52	51.37	45.25	42
Normal	75.33	76.23	69.90	77.45	75.97	77.81	77.98	76.11
<b>MASKE</b>								
Çıkığı	50.15	56.29	64.09	62.81	50.05	48.27	71.22	53.75
Küçük Trokanter	50.37	49.48	48.49	53.88	51.59	52.36	50.80	48.99
Subtrokanterik	39.52	37.80	36.44	36.47	38.22	38.41	31.90	32.43
Büyük Trokanter	15.93	17.69	13.43	17.09	19.34	14.85	15.88	16.79
Boyun	55.42	53.41	59.20	54.57	54.96	58.16	54.24	49.90
İntertrokanterik	47.21	47.42	42.81	42.84	45.93	50.59	43.95	39.16
Normal	80.92	80.61	78.02	81.89	81.25	82.22	82.62	81.28

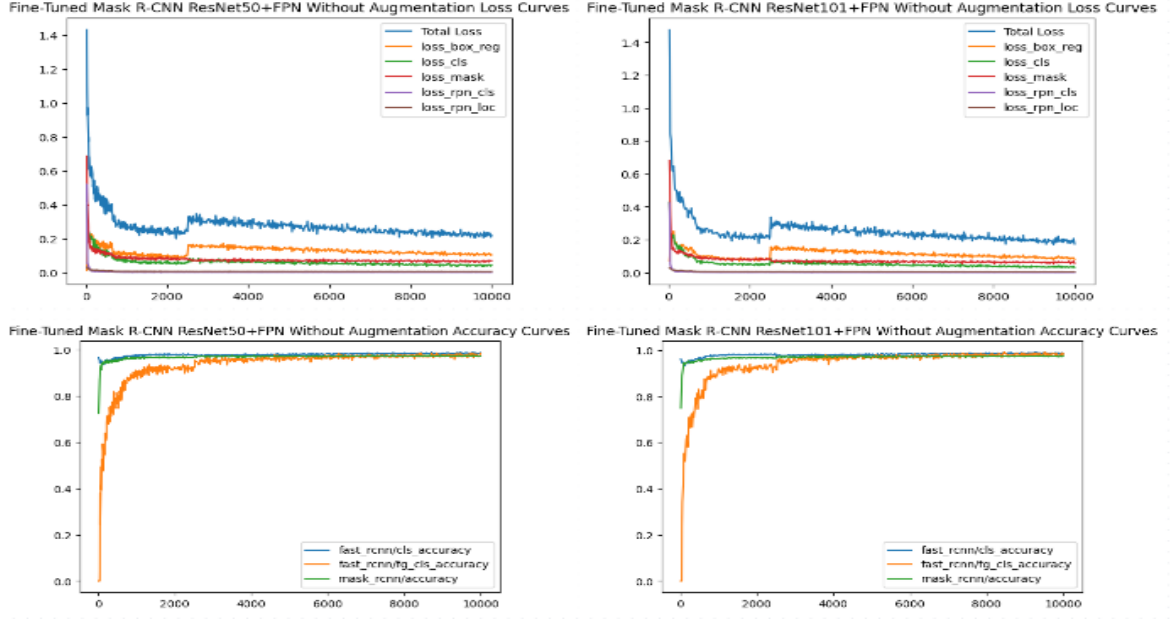
Modelleri daha fazla değerlendirmek için Doğruluk eğrileri ve Kayıplar çizilmiştir. Bu da Şekil 5.7'den Şekil 5.14'e kadar gösterilmektedir. Şekillere göre tüm deneylerde doğruluk değerlerinin 1'e, kayıp değerlerinin ise 0'a yaklaştığı görülmektedir.



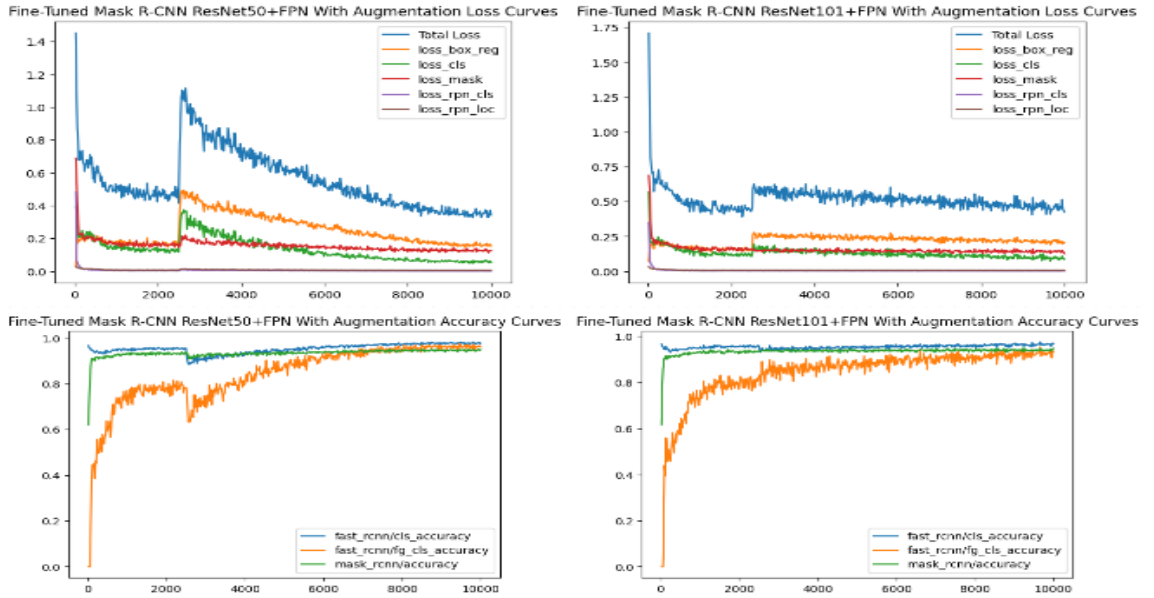
Şekil 5.7 Mask R-CNN ResNet50+FPN'in ve Mask R-CNN ResNet101+FPN'in Veri Büyütme Olmadan Doğruluk ve Kayıp Eğrileri



Şekil 5.8 Mask R-CNN ResNet50+FPN'in ve Mask R-CNN ResNet101+FPN'in Veri Büyütme ile Doğruluk ve Kayıp Eğrileri

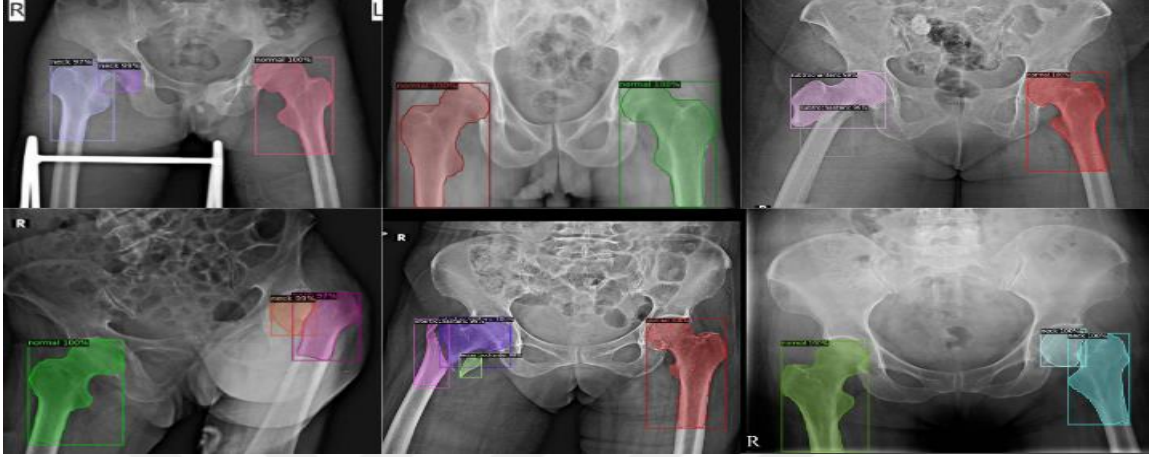


Şekil 5.9 Mask R-CNN ResNet50+FPN'in ve Mask R-CNN ResNet101+FPN'in Veri Büyütme Olmadan ve İnce Ayarlar ile Doğruluk ve Kayıp Eğrileri



Şekil 5.10 Mask R-CNN ResNet50+FPN'in ve Mask R-CNN ResNet101+FPN'in Veri Büyütme ve İnce Ayarlar ile Doğruluk ve Kayıp Eğrileri

YOLO modelleri olarak, Mask R-CNN modelleri daha önce görülmemiş bir veri seti [96] üzerinde test edilmiştir. Tahmin edilen kırıkların bir örneği Şekil 5.15'te gösterilmektedir.



Şekil 5.11 Mask R-CNN Test Verileri Üzerinde Tahmini Sonuçları

### 5.3. PointRend (İşaret Noktası)

Mask R-CNN olarak PointRend, büyütme uygulanarak ve uygulanmadan, ince ayar yapılarak ve yapılmadan, ResNet50+FPN ve ResNet101+FPN omurgalı önceden eğitilmiş modeller kullanılarak detectron2 aracılığıyla eğitilmiştir. 2500 iterasyonun karşılaştırma için yeterli görülmemesi nedeniyle tüm modeller 10000 iterasyon için eğitilmiştir. Batch 8, öğrenme oranı 0,01 alınmıştır. Farklı modeller aşağıdaki gibidir:

- Model1: ResNet50+FPN Büyütme olmadan ve varsayılan değerlerle.
- Model2: ResNet101+FPN Büyütme olmadan ve varsayılan değerlerle.
- Model3: ResNet50+FPN Büyütme ve varsayılan değerlerle.
- Model4: ResNet101+FPN Büyütme ve varsayılan değerlerle.
- Model5: ResNet50+FPN Büyütme olmadan ve ince ayar.
- Model6: ResNet101+FPN Büyütme olmadan ve ince ayar.

- Model7: ResNet50+FPN Büyütme ve ince ayar.
- Model8: ResNet101+FPN Büyütme ve ince ayar.

Mask R-CNN'de olduğu gibi, artırma tekniklerinin uygulanması ve ince ayar, temametrik değerlerde değerli bir değişiklik göstermez. Bu, mAP50 değerinin sınırlayıcı kutular için 69,05 ile 73,67 arasında ve maskeler için 69,89 ile 74,85 arasında olduğu Tablo 5.5'te görülebilmektedir.

Model4, hem sınırlayıcı kutular hem de maskeler için sırasıyla 73,67 ve 74,85 değeriyle en iyi mAP50 değerine sahiptir.

Model8, küçük nesnelerin tespitinde hem sınırlayıcı kutular hem de maskeler için en iyi değerlere sahiptir; burada mAP değerleri sınırlayıcı kutular için 24,88 ve maskeler için 8,42 bulunmuştur.

Her iki modelin doğruluk ve kayıp eğrileri Şekil 5.12 ve Şekil 5.15'te gösterilmektedir, bu da doğruluk eğrilerinin yaklaşık 1'e yaklaştığını ve kayıp eğrilerinin 0'a yaklaştığını gösterir.

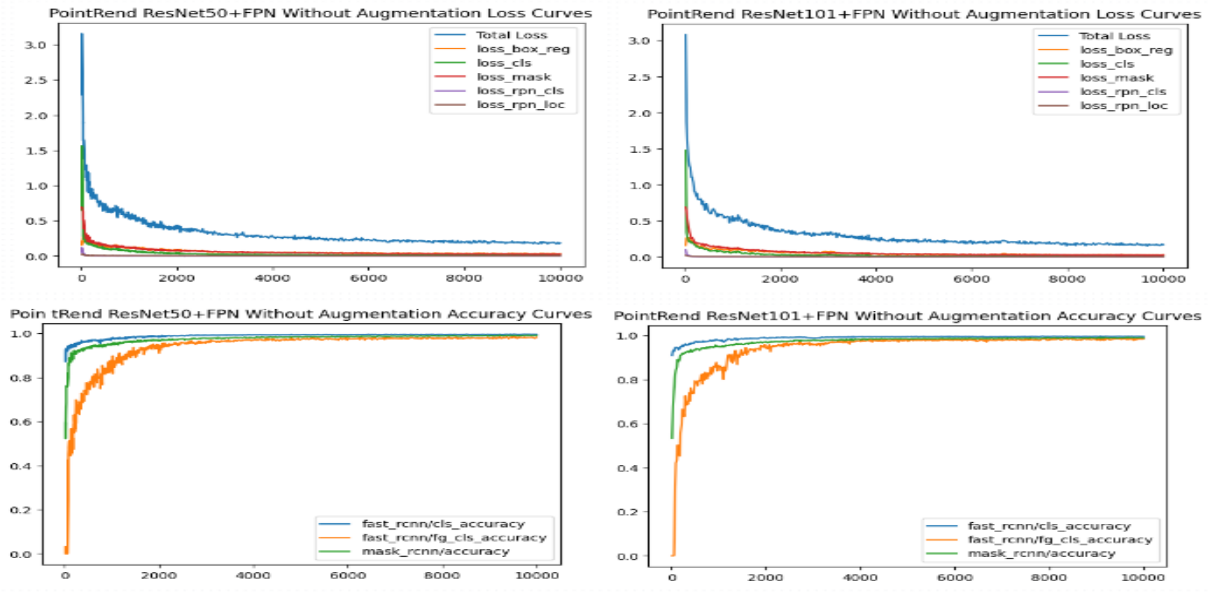
**Tablo 5.5** PointRend Eğitimi mAP Değerleri

	Modeller							
	Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
<b>SINIRLAYICI KUTULAR</b>								
<b>AP</b>	48.66	48.62	47.01	49.98	46.48	47.41	45.46	44.76
<b>mAP50</b>	70.05	70.26	71.43	73.67	69.16	69.05	70.52	69.17
<b>mAP75</b>	55	53.89	51.10	52.19	49.75	52.09	47.77	47.81
<b>mAPs</b>	5.05	2.69	0	15.15	1.68	5.89	10.10	24.88
<b>mAPm</b>	48.50	42.36	38.70	41.01	46.12	45.76	41.07	42.83
<b>mAPl</b>	51.58	52.70	51.45	54.50	50.64	51.79	50.29	48.08
<b>MASKE</b>								
<b>AP</b>	50.08	50.04	49.16	51.59	48.35	49.17	46.51	46.32

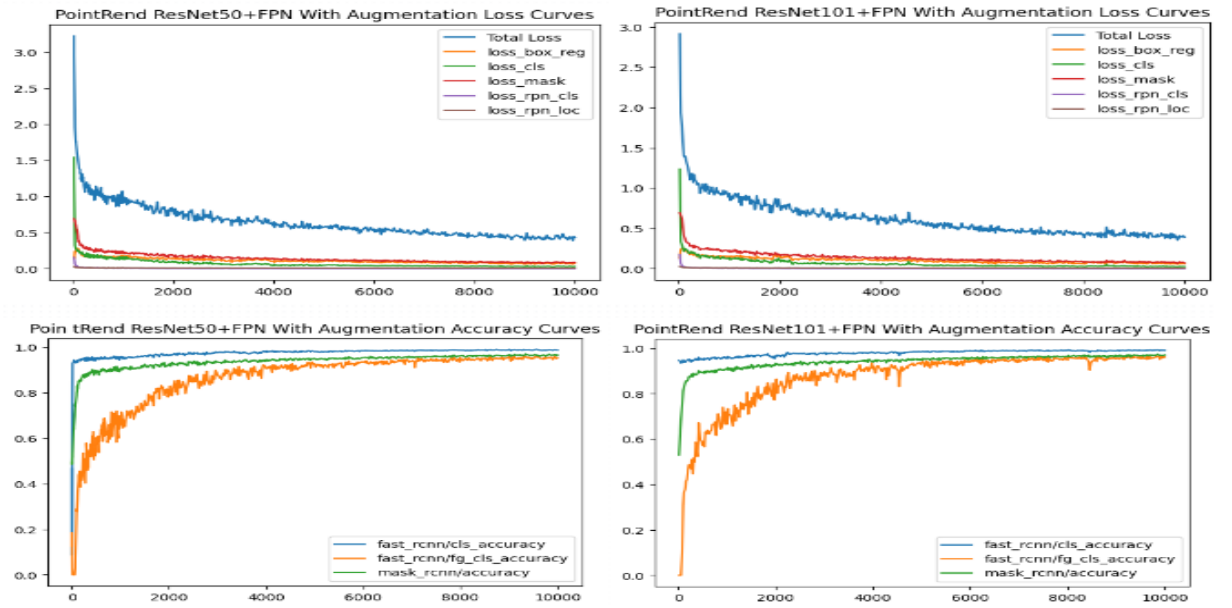
mAP50	71.44	71.61	72.30	74.85	69.89	70.19	70.14	69.47
mAP75	53.13	53.49	53.71	56.83	52.79	54.15	50.35	51.46
mAPs	3.65	1.17	0	7.78	1.29	1.63	4.09	8.42
mAPm	44.94	39.35	39.16	37.50	44.76	43.38	40.05	35.19
mAPI	55.47	56.89	54.78	57.28	53.93	55.24	51.98	52.24

**Tablo 5.6** Tüm Sınıflar için PointRend mAP Değerleri

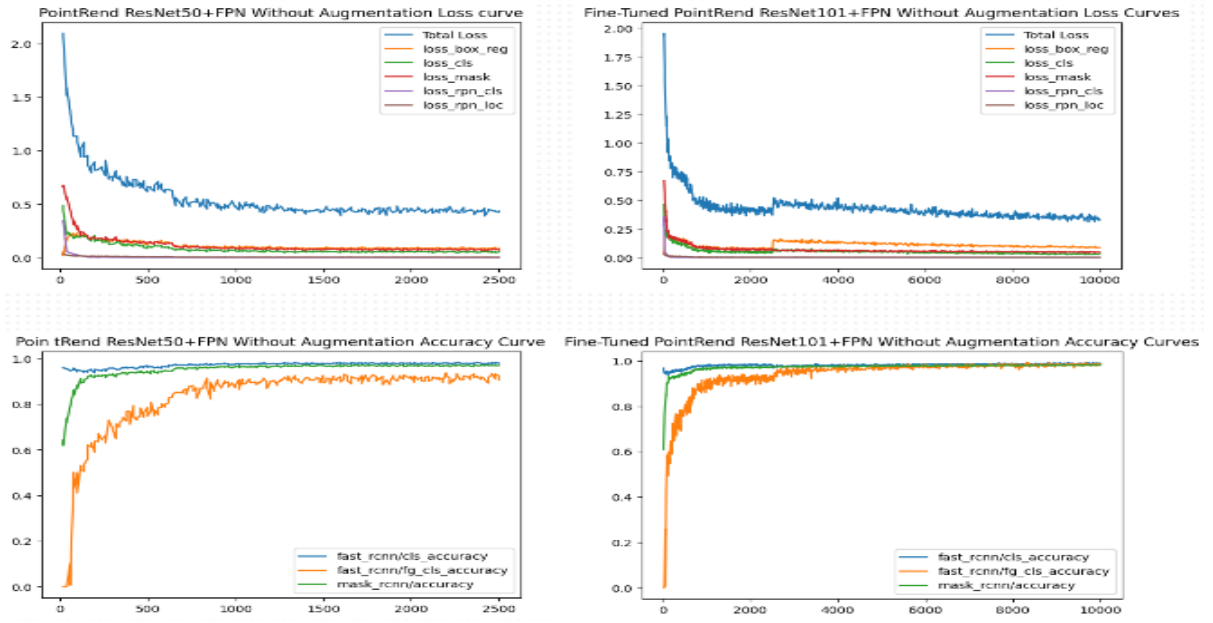
Kategori	Modeller							
	Model1	Model2	Model3	Model4	Model5	Model6	Model7	Model8
<b>SINIRLAYICI KUTULAR</b>								
<b>Çıkığı</b>	49.09	47.52	58.33	64.13	30.67	37.11	44.82	47.81
<b>Küçük Trokanter</b>	56.63	54.51	51.24	50.95	53.30	50.59	51.21	53.68
<b>Subtrokanterik</b>	36.42	40.87	36.62	37.42	36.62	40.06	34.06	30.09
<b>Büyük Trokanter</b>	20.18	20.86	15.01	18.84	22.41	23.85	16.61	10.30
<b>Boyun</b>	54.04	51.23	50.91	54.76	55.19	55.84	52.10	53.74
<b>İntertrokanterik</b>	49.24	48.75	42.84	47.76	50.75	49.39	42.96	42.75
<b>Normal</b>	75	76.59	74.16	75.99	76.46	75.04	76.44	74.97
<b>MASKE</b>								
<b>Çıkığı</b>	57.11	53.76	63.42	70.77	38.93	43.36	48.72	52.25
<b>Küçük Trokanter</b>	51.78	52.05	50.23	50.63	52.90	50.34	47.60	50.78
<b>Subtrokanterik</b>	37.85	43.18	36.25	37.71	37.25	40.94	33.87	31.34
<b>Büyük Trokanter</b>	16.33	16.90	15.05	16.05	19.45	23.09	18.47	10.59
<b>Boyun</b>	56.55	53.90	52.68	57.03	57.56	57.14	52.78	55.93
<b>İntertrokanterik</b>	48.36	46.55	42.75	45.60	49.17	46.47	40.28	41
<b>Normal</b>	82.59	83.95	83.76	83.32	83.10	82.85	83.83	82.35



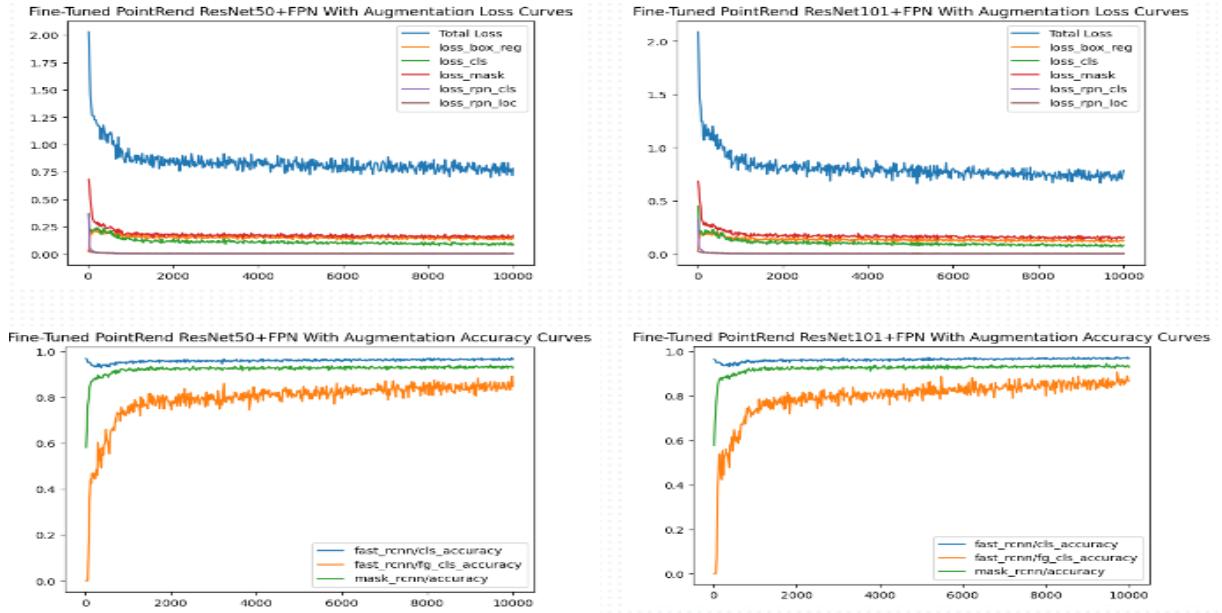
Şekil 5.12 PointRend ResNet50+FPN'ın ve ResNet101+FPN'in Büyütme Olmadan Doğruluk ve Kayıp Eğrileri



Şekil 5.13 PointRend ResNet50+FPN'ın ve ResNet101+FPN'in Büyütme Olmadan Doğruluk ve Kayıp Eğrileri

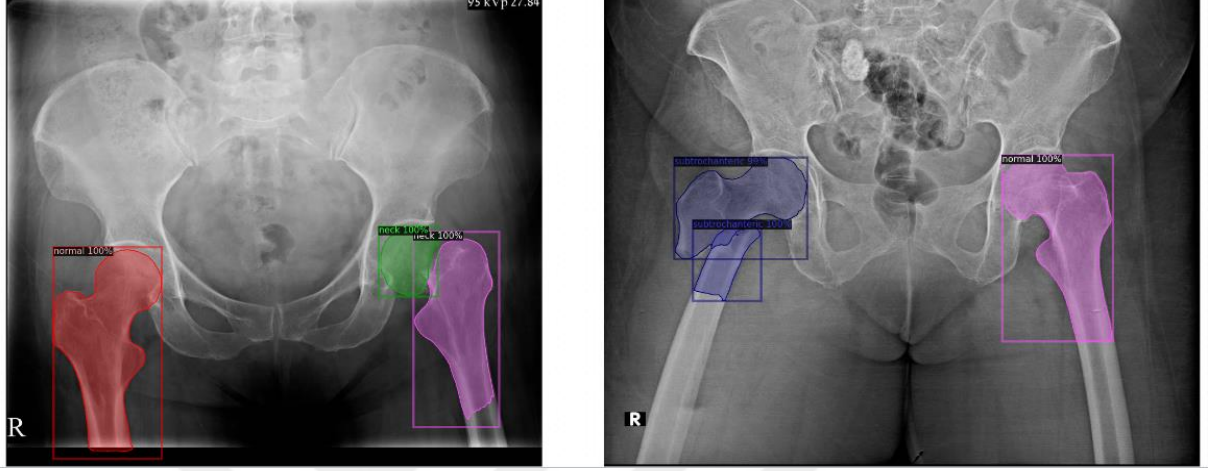


Şekil 5.14 PointRend ResNet50+FPN'ın ve ResNet101+FPN'in Büyütme Olmadan İnce Ayar ile Doğruluk ve Kayıp Eğrileri



Şekil 5.15 PointRend ResNet50+FPN'ın ve ResNet101+FPN'in Büyütme ve İnce Ayar ile Doğruluk ve Kayıp Eğrileri

YOLO modelleri ve Mask R-CNN gibi PointRend de daha önce görülmemiş bir veri kümesi [96] üzerinde test edilmiştir. Şekil 5.16 çıkarımın bir örneğini göstermektedir.



Şekil 5.16 PointRend Test Verileri Üzerinde Tahmini Sonuçları

## 6. TARTIŞMA

Bu tezde, çeşitli proksimal femur kırıkları ve çıkıklarının varlığını tespit etmek amacıyla X-ışını görüntüleri üzerinde eğitilen ve değerlendirilen toplam beş derin sinir ağı modeli bulunmaktadır. CV alanıyla ilgili bu modeller, YOLOv5, YOLOv7, YOLOv8, Mask R-CNN ve PointRend olarak adlandırılmaktadır.

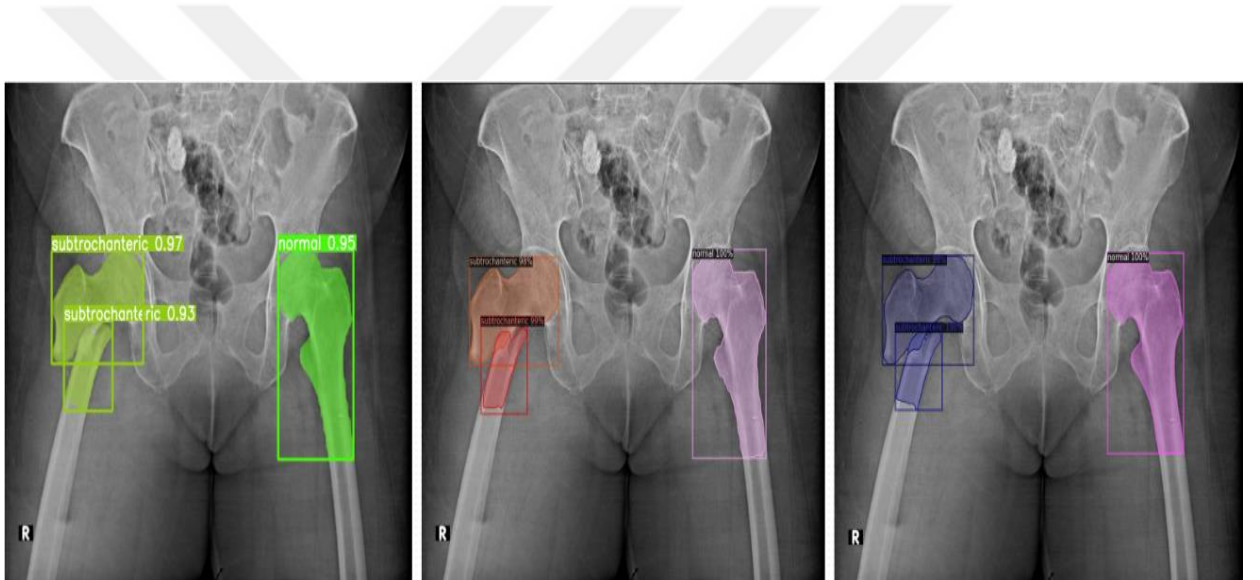
Farklı modeller, proksimal femur kırığı tespiti konusunda daha iyi bir performans için objektif bir şekilde incelenmiş ve karşılaştırılmıştır. YOLO ailesi modelleri 200 epoch boyunca eğitilmiş, Mask R-CNN ve PointRend modelleri ise farklı omurgalarıyla, yani ResNet50+FPN ve ResNet101+FPN ile birlikte 10000 iterasyon boyunca eğitilmiştir. mAP'ye göre farklı modeller arasındaki karşılaştırma Tablo 6.1'de gösterilmiştir. Deneysel çalışma ayrıca, tüm modellerin hastalıkları tanımak ve kategorize etmek için uygun olduğunu ortaya koymuştur. Tablo 6.1'e göre çoğu bozukluk için YOLOv8, farklı sürümleriyle IoU 0.50'de 81.6% mAP değeriyle diğer modelleri geride bırakmaktadır.

**Tablo 6.1** Model Karşılaştırmaları


Modeller		AP (B)	mAP50 (B)	AP (M)	mAP50 (M)
YOLOv5		60.2	79.5	59.5	80
YOLOv7		59.3	79.2	57.8	78.8
YOLOv8		61.3	81.6	61.1	81.7
Mask R-CNN	Model1	47.84	70.06	48.50	71.29
	Model2	48.58	70.07	48.96	72.27
	Model3	47.65	73.82	48.93	74.05
	Model4	48.95	71.88	49.93	72.05
	Model5	48.40	70.76	48.75	72.35
	Model6	48.07	69.81	49.27	71.15
	Model7	48.09	73.03	50.09	73.70
	Model8	45.55	70.36	46.04	70
PointRend	Model1	48.66	70.05	50.08	71.4
	Model2	48.62	70.26	50.04	71.61
	Model3	47.01	71.43	49.16	72.30
	Model4	49.98	73.67	51.59	74.85
	Model5	46.48	69.16	48.35	69.89
	Model6	47.41	69.05	49.17	70.19
	Model7	45.46	70.52	46.51	70.14
	Model8	44.76	69.76	46.32	69.47

Çeşitli modelleri test veri kümesindeki çıkarımlara göre karşılaştırırken aşağıdakiler gözlemlenmiştir:

- PointRend, render problemine dayalı mimarisi nedeniyle, maskelerin ana hatlarını tasarlamada Mask R-CNN ve YOLO ailesinden daha iyi performans göstermiştir. Bu durum, Şekil 6.1'de görülebilmektedir.
- YOLO ailesi, Maksimum Olmayan Baskılama (MOB) uygulayan mimarisi sayesinde, Mask R-CNN'de desteklenmeyen iki sınıfın çakışmasını engeller. Bu durum, Şekil 6.2'de görülebilmektedir.



Şekil 6.1 Sırasıyla YOLO, MASK R-CNN ve PointRend Çıkarım Karşılaştırması



Şekil 6.2 Mask R-CNN Sınıflarının Örtüşmesi

## 7. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, YOLOv5, YOLOv7, YOLOv8, Mask R-CNN, PointRend olmak üzere beş farklı CNN modelinin proksimal femur kırığı varlığını tespit etme ve X-ışınları ile sınıflandırma performansı incelenmiştir.

Bir örnek segmentasyon görevi için sınırlayıcı kutular yerine Polygon etiketleme aracı kullanılmıştır. Bilgimiz dahilinde, önceki hiçbir çalışma, proksimal femur kırıklarını tespit etmek ve sınıflandırmak için örnek segmentasyon görevine Polygon etiketleme aracı kullanılarak gerçekleştirilmemiştir. Bu tür bir teknik, meme kanseri lezyonu gibi birçok tıbbi alanda kullanılmıştır, ancak daha önce bir kırığın varlığını tespit etme ve doğru sınıflandırma alanında işlenmemiştir. Kırıkları tespit etmek için önceki araştırmalarda, sınırlayıcı kutuları kullanmaya ve bunlara maske uygulamaya odaklanılmıştır.

Örnek segmentasyon görevlerini gerçekleştirebilen YOLOv5, YOLOv7, YOLOv8, Mask R-CNN ve PointRend gibi önceden eğitilmiş modellerle Polygon etiketleme aracı kullanmanın sonuçları, bu modellerin potansiyel etkinliği hakkında değerli bilgiler sağlar. Sonuçlara göre, beş modelin tümü proksimal femur kırığının varlığını tespit edebilmiş ve sınıflandırabilmiştir. mAP açısından YOLOv8, kutular ve maskeler için 81,6 ve 81,7 değerleriyle diğer modelleri geride bırakmıştır.

Sonuçların başarılı olmasına karşın çalışmada bazı sınırlamalar da mevcuttur. Proksimal femur kırıklarının farklı tiplerini gösteren tıbbi verilerin eksikliği daha iyi sonuçlar alınmasını engellemektedir. Odaklanması gereken başka bir sınırlama, tıbbi verilerin Polygon etiketleme aracı kullanılarak etiketlenmesidir; bu yöntem zaman alıcı olabilir, ancak iyi sonuçlar vermektedir.

Gelecekte yapılabilecek muhtemel çalışmalar, modelin proksimal femurun çeşitli parçalarını (baş, boyun, intertrokanterik, büyük trokanter, küçük trokanter, subtrokanterik ve çıkık) algılamayı öğrenmesi, bu parçaları normal veya kırık formda göstermesi olarak özetlenebilmektedir. Bunların dışında, hedef hastalığa ilişkin yeterli ölçüde tıbbi veri bulunmadığından dolayı üretken Adversial Networks aracının kullanılması, eğitim verilerini iyileştirmek amacıyla yeni görüntüler oluşturmada önemli olabilecektir.

## 8. KAYNAKÇA

- [1] 7.1 Divisions of the Skeletal System – Anatomy & Physiology. (n.d.). Retrieved from <https://open.oregonstate.edu/aandp/chapter/7-1-divisions-of-the-skeletal-system/>, [Ziyaret Tarihi: 2 Şubat 2023]
- [2] Mutasa, Simukayi; Varada, Sowmya; Goel, Akshay; Wong, Tony T.; Rasiej, Michael J. (2020). Advanced Deep Learning Techniques Applied to Automated Femoral Neck Fracture Detection and Classification. Journal of Digital Imaging, (), –. <https://doi.org/10.1007/s10278-020-00364-8>
- [3] Koray Açııcı; Emre Sümer; Salih Beyaz; (2021). Comparison of different machine learning approaches to detect femoral neck fractures in x-ray images. Health and Technology, (), –. <https://doi.org/10.1007/s12553-021-00543-9>
- [4] Chan, Daniel S. MD Femoral Neck Fractures in Young Patients: State of the Art, Journal of Orthopaedic Trauma: January 2019 - Volume 33 - Issue - p S7-S11, <https://doi.org/10.1097/BOT.0000000000001366> , [Ziyaret Tarihi: 2 Şubat 2023]
- [5] Su, N., Yang, J., Xie, Y., Du, X., Chen, H., Zhou, H., & Chen, L. (2019). Bone function, dysfunction and its role in diseases including critical illness. International journal of biological sciences, 15(4), 776–787. <https://doi.org/10.7150/ijbs.27063>, [Ziyaret Tarihi: 2 Şubat 2023]
- [6] Joints, Britannica Kids, <https://kids.britannica.com/students/article/joint/275174> , [Ziyaret Tarihi: 2 Şubat 2023]
- [7] Cowan, PT., Kahai, P. (2022). Anatomy, Bones. In: StatPearls [Internet]. Treasure Island (FL): StatPearls, Available from: <https://www.ncbi.nlm.nih.gov/books/NBK537199/> , [Ziyaret Tarihi: 12 Şubat 2023]
- [8] Dial, B. L., & Lark, R. K. (2018). Pediatric proximal femur fractures. Journal of orthopaedics, 15(2), 529–535. <https://doi.org/10.1016/j.jor.2018.03.039>
- [9] Florencio-Silva, R., Sasso, G. R., Sasso-Cerri, E., Simões, M. J., & Cerri, P. S. (2015). Biology of Bone Tissue: Structure, Function, and Factors That Influence Bone Cells. BioMed research international, 2015, 421746. <https://doi.org/10.1155/2015/421746>, [Ziyaret Tarihi: 12 Şubat 2023]
- [10] Chen, X., Wang, Z., Duan, N., Zhu, G., Schwarz, E. M., & Xie, C. (2018). Osteoblast-osteoclast interactions. Connective tissue research, 59(2), 99–107. <https://doi.org/10.1080/03008207.2017.1290085>

- [11] Lin, C.-Y., & Kang, J.-H. (2021). Mechanical Properties of Compact Bone Defined by the Stress-Strain Curve Measured Using Uniaxial Tensile Test: A Concise Review and Practical Guide. *Materials*, 14(15), 4224. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/ma14154224>
- [12] Downey, P. A., & Siegel, M. I. (2006). Bone biology and the clinical implications for osteoporosis. *Physical therapy*, 86(1), 77–91. <https://doi.org/10.1093/ptj/86.1.77>
- [13] Hip Dislocation - OrthoInfo - AAOS. (n.d.). <https://orthoinfo.aaos.org/en/diseases--conditions/hip-dislocation/#:~:text=It%20takes%20time%20%E2%80%94%20sometimes%20is%20often%20recommended%20during%20recovery> , [Ziyaret Tarihi: 12 Şubat 2023]
- [14] Skeletal Tissues, Basicmedical Key, <https://basicmedicalkey.com/skeletal-tissues/#cesec13> , [Ziyaret Tarihi: 12 Şubat 2023]
- [15] 6.2 Bone Classification – Anatomy & Physiology, <https://open.oregonstate.education/aandp/chapter/6-2-bone-classification/> , [Ziyaret Tarihi: 12 Şubat 2023]
- [16] The Skeletal System, IB SEHS NOTES, <https://ibsehsnotes.wordpress.com/2015/05/12/1-1-the-skeletal-system/> , [Ziyaret Tarihi: 16 Şubat 2023]
- [17] Feng X. (2009). Chemical and Biochemical Basis of Cell-Bone Matrix Interaction in Health and Disease. *Current chemical biology*, 3(2), 189–196. <https://doi.org/10.2174/187231309788166398>
- [18] Bone Classification, Anatomy and Physiology, <https://pressbooks-dev.oer.hawaii.edu/anatomyandphysiology/chapter/bone-classification/> , [Ziyaret Tarihi: 16 Şubat 2023]
- [19] <https://study.com/academy/lesson/epiphysis-of-bone-definition-function.html> , [Ziyaret Tarihi: 16 Şubat 2023]
- [20] Femur Bone Anatomy, Registered Nurse RN , <https://www.registerednursern.com/femur-bone-anatomy/> , [Ziyaret Tarihi: 6 Şubat 2023]
- [21] Sheehan, S. E., Shyu, J. Y., Weaver, M. J., Sodickson, A. D., & Khurana, B. (2015). Proximal Femoral Fractures: What the Orthopedic Surgeon Wants to Know. *Radiographics: a review publication of the Radiological Society of North America, Inc*, 35(5), 1563–1584. <https://doi.org/10.1148/rg.2015140301>
- [22] Ram, G. G., & Govardhan, P. (2019). In-Hospital Mortality following Proximal Femur Fractures in Elderly Population. *Surgery journal (New York, N.Y.)*, 5(2), e53–e56. <https://doi.org/10.1055/s-0039-1692995>
- [23] Brunner, L. C., Eshilian-Oates, L., & Kuo, T. Y. (2003). Hip fractures in adults. *American family physician*, 67(3), 537–542.

- [24] Veronese, N., & Maggi, S. (2018). Epidemiology and social costs of hip fracture. *Injury*, 49(8), 1458–1460. <https://doi.org/10.1016/j.injury.2018.04.015>
- [25] Matthews AH, Davis DD, Fish MJ, et al. (2022) Avascular Necrosis. In: StatPearls [Internet]. Treasure Island (FL): StatPearls; Available from: <https://www.ncbi.nlm.nih.gov/books/NBK537007/> , [Ziyaret Tarihi: 16 Şubat 2023]
- [26] Lu, Y., & Uppal, H. S. (2019). Hip Fractures: Relevant Anatomy, Classification, and Biomechanics of Fracture and Fixation. *Geriatric orthopaedic surgery & rehabilitation*, 10, 2151459319859139. <https://doi.org/10.1177/2151459319859139>
- [27] Attum B, Pilson H. (2022) Intertrochanteric Femur Fracture. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Available from: <https://www.ncbi.nlm.nih.gov/books/NBK493161/> , [Ziyaret Tarihi: 20 Şubat 2023]
- [28] <https://www.orthopaedicsone.com/display/Main/Femoral+neck+fractures++Pauwels+classification> , [Ziyaret Tarihi: 20 Şubat 2023]
- [29] Femoral Neck Fractures, Garden Classifications. Physiopedia. [https://www.physio-pedia.com/Femoral\\_Neck\\_Fractures,\\_Garden\\_Classification](https://www.physio-pedia.com/Femoral_Neck_Fractures,_Garden_Classification) , [Ziyaret Tarihi: 20 Şubat 2023]
- [30] Riyaz N. N., Nithin S., „A prospective study to evaluate the outcome of operative treatment of patients with intertrochanteric fracture of femur with cephalomedullary nail and dynamic hip screw device,“ *Edorium Journals Orthopedic*, Bd. 1, pp. 1-7, 2015.
- [31] Sorrentino S, Deng F, Yu Jin T, et al. Anterior dislocation of the hip. Reference article, Radiopaedia.org, <https://doi.org/10.53347/rID-14838>, [Ziyaret Tarihi: 20 Şubat 2023]
- [32] MRI scan. (n.d.). Better Health Channel. <https://www.betterhealth.vic.gov.au/health/conditionsandtreatments/mri-scan> , [Ziyaret Tarihi: 27 Şubat 2023]
- [33] Hussain, S., Mubeen, I., Ullah, N., Shah, S. S. U. D., Khan, B. A., Zahoor, M., Ullah, R., Khan, F. A., & Sultan, M. A. (2022). Modern Diagnostic Imaging Technique Applications and Risk Factors in the Medical Field: A Review. *BioMed research international*, 2022, 5164970. <https://doi.org/10.1155/2022/5164970>
- [34] Song, Hyewon & Nguyen, Duc & Gong, Myoungsik & Lee, Sanghoon. (2016). A Review of Computer Vision Methods for Purpose on Computer-Aided Diagnosis. *Journal of International Society for Simulation Surgery*. 3. 1-8. <https://doi.org/10.18204/JISSiS.2016.3.1.001> .
- [35] X-rays. (n.d.). National Institute of Biomedical Imaging and Bioengineering. <https://www.nibib.nih.gov/science-education/science-topics/x-rays> , [Ziyaret Tarihi: 27 Şubat 2023]
- [36] Computed Tomography (CT). (2023, May 1). U.S. Food And Drug Administration. <https://www.fda.gov/radiation-emitting-products/medical-x-ray-imaging/computed-tomography-ct> , [Ziyaret Tarihi: 27 Şubat 2023]

- [37] *X-raydetector*. (2023, 26 Ekim). Wikipedi. [https://en.wikipedia.org/wiki/X-ray\\_detector](https://en.wikipedia.org/wiki/X-ray_detector) , [Ziyaret Tarihi: 27 Şubat 2023]
- [38] Computed Tomography (CT or CAT scan) Procedures, <https://www.radiologyinfo.org/en/info/bodyct> , [Ziyaret Tarihi: 27 Şubat 2023]
- [39] Computed Tomography (CT). (n.d.). National Institute of Biomedical Imaging and Bioengineering. <https://www.nibib.nih.gov/science-education/science-topics/computed-tomography-ct> , [Ziyaret Tarihi: 27 Şubat 2023]
- [40] Magnetic Resonance Imaging (MRI). (n.d.). National Institute of Biomedical Imaging and Bioengineering. <https://www.nibib.nih.gov/science-education/science-topics/magnetic-resonance-imaging-mri> , [Ziyaret Tarihi: 27 Şubat 2023]
- [41] *CT scan*. (2023, 30 Kasım). Wikipedi. [https://en.wikipedia.org/wiki/CT\\_scan](https://en.wikipedia.org/wiki/CT_scan) , [Ziyaret Tarihi: 27 Şubat 2023]
- [42] Lu, Y., & Uppal, H. S. (2019). Hip Fractures: Relevant Anatomy, Classification, and Biomechanics of Fracture and Fixation. *Geriatric orthopaedic surgery & rehabilitation*, 10, 2151459319859139. <https://doi.org/10.1177/2151459319859139>
- [43] Magnetic Resonance Imaging M.R.I Procedures, <https://bizbwana.com/product/clfpqkNSE00100817bata48in> . , [Ziyaret Tarihi: 27 Şubat 2023]
- [44] NCI Dictionary of Cancer Terms. (n.d.). National Cancer Institute. <https://www.cancer.gov/publications/dictionaries/cancer-terms/def/bone-marrow> , [Ziyaret Tarihi: 27 Şubat 2023]
- [45] Professional, C. C. M. (n.d.). MRI (Magnetic Resonance Imaging). Cleveland Clinic. <https://my.clevelandclinic.org/health/diagnostics/4876-magnetic-resonance-imaging-mri> , [Ziyaret Tarihi: 27 Şubat 2023]
- [46] Applied Sciences | Free Full-Text | Machine Learning-Based Label ..., <https://www.mdpi.com/2302124>. [Ziyaret Tarihi: 27 Şubat 2023]
- [47] *MRG: Guided Tour - Magnet Academy*. (tarih yok). <https://nationalmaglab.org/magnet-academy/read-science-stories/science-simplified/mri-a-guided-tour/> , [Ziyaret Tarihi: 27 Şubat 2023]
- [48] Cai, L., Gao, J., & Zhao, D. (2020). A review of the application of deep learning in medical image classification and segmentation. *Annals of translational medicine*, 8(11), 713. <https://doi.org/10.21037/atm.2020.02.44>
- [49] Lee, J. G., Jun, S., Cho, Y. W., Lee, H., Kim, G. B., Seo, J. B., & Kim, N. (2017). Deep Learning in Medical Imaging: General Overview. *Korean journal of radiology*, 18(4), 570–584. <https://doi.org/10.3348/kjr.2017.18.4.570>

- [50] Redmon, J., Divvala, S.K., Girshick, R.B., & Farhadi, A. (2015). You Only Look Once: Unified, Real-Time Object Detection. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 779-788.
- [51] He, K., Gkioxari, G., Dollár, P., & Girshick, R.B. (2017). Mask R-CNN. 2017 IEEE International Conference on Computer Vision (ICCV), 2980-2988.
- [52] Yadav, D.P.; Sharma, A.; Athithan, S.; Bhola, A.; Sharma, B.; Dhaou, I.B. Hybrid SFNet Model for Bone Fracture Detection and Classification Using ML/DL. *Sensors* 2022, 22, 5823. <https://doi.org/10.3390/s22155823>
- [53] Dimililer, K. (2017). IBFDS: Intelligent bone fracture detection system. *Procedia Computer Science*, 120, 260-267.
- [54] Rajpurkar, P., Irvin, J.A., Bagul, A., Ding, D.Y., Duan, T., Mehta, H., Yang, B., Zhu, K., Laird, D., Ball, R.L., Langlotz, C., Shpanskaya, K.S., Lungren, M.P., & Ng, A. (2017). MURA: Large Dataset for Abnormality Detection in Musculoskeletal Radiographs. *arXiv: Medical Physics*.
- [55] Jones, R. M., Sharma, A., Hotchkiss, R., Sperling, J. W., Hamburger, J., Ledig, C., O'Toole, R., Gardner, M., Venkatesh, S., Roberts, M. M., Sauvestre, R., Shatkhin, M., Gupta, A., Chopra, S., Kumaravel, M., Daluiski, A., Plogger, W., Nascone, J., Potter, H. G., & Lindsey, R. V. (2020). Assessment of a deep-learning system for fracture detection in musculoskeletal radiographs. *NPJ digital medicine*, 3, 144. <https://doi.org/10.1038/s41746-020-00352-w>
- [56] Lindsey, R., Daluiski, A., Chopra, S., Lachapelle, A., Mozer, M.C., Sicular, S., Hanel, D.P., Gardner, M., Gupta, A., Hotchkiss, R., & Potter, H.G. (2018). Deep neural network improves fracture detection by clinicians. *Proceedings of the National Academy of Sciences of the United States of America*, 115, 11591 - 11596.
- [57] Kim DH, MacKinnon T. Artificial intelligence in fracture detection: transfer learning from deep convolutional neural networks. *Clin Radiol*. 2018 May;73(5):439-445. <https://doi.org/10.1016/j.crad.2017.11.015> . Epub 2017 Dec 18. PMID: 29269036.
- [58] Ebsim, R., Naqvi, J., & Cootes, T. F. (2019). Automatic Detection of Wrist Fractures From Posteroanterior and Lateral Radiographs: A Deep Learning-Based Approach. *Lecture Notes in Computer Science*, 114–125. [https://doi.org/10.1007/978-3-030-11166-3\\_10](https://doi.org/10.1007/978-3-030-11166-3_10)
- [59] Sukru Demir, Sefa Key, Turker Tuncer, Sengul Dogan, An exemplar pyramid feature extraction based humerus fracture classification method, *Medical Hypotheses*, Volume 140, 2020, 109663, ISSN 0306-9877, <https://doi.org/10.1016/j.mehy.2020.109663>
- [60] Guan, Bin; Zhang, Guoshan; Yao, Jinkun; Wang, Xinbo; Wang, Mengxuan (2020). Arm fracture detection in X-rays based on improved deep convolutional neural network. *Computers & Electrical Engineering*, 81(), 106530–. <https://doi.org/10.1016/j.compeleceng.2019.106530>

- [61] Kitamura, Gene; Chung, Chul Y.; Moore, Barry E. (2019). Ankle Fracture Detection Utilizing a Convolutional Neural Network Ensemble Implemented with a Small Sample, De Novo Training, and Multiview Incorporation. *Journal of Digital Imaging*, (), -. <https://doi.org/10.1007/s10278-018-0167-7>
- [62] Kim J-H, Mo Y-C, Choi S-M, Hyun Y, Lee JW. Detecting Ankle Fractures in Plain Radiographs Using Deep Learning with Accurately Labeled Datasets Aided by Computed Tomography: A Retrospective Observational Study. *Applied Sciences*. 2021; 11(19):8791. <https://doi.org/10.3390/app11198791>
- [63] Jakub Olczak, Filip Emilson, Ali Razavian, Tone Antonsson, Andreas Stark & Max Gordon (2021) Ankle fracture classification using deep learning: automating detailed AO Foundation/Orthopedic Trauma Association (AO/OTA) 2018 malleolar fracture identification reaches a high degree of correct classification, *Acta Orthopaedica*, 92:1, 102-108, <https://doi.org/10.1080/17453674.2020.1837420>
- [64] Adams, M., Chen, W., Holcdorf, D., McCusker, M.W., Howe, P.D. and Gaillard, F. (2019), Computer vs human: Deep learning versus perceptual training for the detection of neck of femur fractures. *J Med Imaging Radiat Oncol*, 63: 27-32. <https://doi.org/10.1111/1754-9485.12828>
- [65] Urakawa, Takaaki; Tanaka, Yuki; Goto, Shinichi; Matsuzawa, Hitoshi; Watanabe, Kei; Endo, Naoto (2018). Detecting intertrochanteric hip fractures with orthopedist-level accuracy using a deep convolutional neural network. *Skeletal Radiology*, (), -. <https://doi.org/10.1007/s00256-018-3016-3>
- [66] Cheng CT, Ho TY, Lee TY, Chang CC, Chou CC, Chen CC, Chung IF, Liao CH., Application of a deep learning algorithm for detection and visualization of hip fractures on plain pelvic radiographs. *Eur Radiol*. 2019 Oct;29(10):5469-5477. <https://doi.org/10.1007/s00330-019-06167-y> . Epub 2019 Apr 1. PMID: 30937588; PMCID: PMC6717182.
- [67] Beyaz S, Açıcı K, Sümer E. Femoral neck fracture detection in X-ray images using deep learning and genetic algorithm approaches. *Jt Dis Relat Surg*. 2020;31(2):175-183. <https://doi.org/10.5606/ehc.2020.72163> . Epub 2020 Mar 26. PMID: 32584712; PMCID: PMC7489171.
- [68] Jiménez-Sánchez A, Kazi A, Albarqouni S, Kirchhoff C, Biberthaler P, Navab N, Kirchhoff S, Mateus D. Precise proximal femur fracture classification for interactive training and surgical planning. *Int J Comput Assist Radiol Surg*. 2020 May;15(5):847-857. <https://doi.org/10.1007/s11548-020-02150-x> . Epub 2020 Apr 25. PMID: 32335786.
- [69] Kitamura G. Deep learning evaluation of pelvic radiographs for position, hardware presence, and fracture detection. *Eur J Radiol*. 2020 Sep;130:109139. <https://doi.org/10.1016/j.ejrad.2020.109139> . Epub 2020 Jun 21. PMID: 32623269; PMCID: PMC7483754.

- [70] Lee, C., Jang, J., Lee, S. et al. Classification of femur fracture in pelvic X-ray images using meta-learned deep neural network. *Sci Rep* 10, 13694 (2020). <https://doi.org/10.1038/s41598-020-70660-4>
- [71] Tanzi, Leonardo; Vezzetti, Enrico; Moreno, Rodrigo; Aprato, Alessandro; Audisio, Andrea; Massà, Alessandro (2020). Hierarchical fracture classification of proximal femur X-Ray images using a multistage Deep Learning approach. *European Journal of Radiology*, 133(), 109373–. <https://doi.org/10.1016/j.ejrad.2020.109373>
- [72] Cheng, CT., Wang, Y., Chen, HW. et al. A scalable physician-level deep learning algorithm detects universal trauma on pelvic radiographs. *Nat Commun* 12, 1066 (2021). <https://doi.org/10.1038/s41467-021-21311-3>
- [73] Moharil, A., Singh, S. (2021). Detection of Proximal Femoral Bone Fracture Using Mask R-CNN. In: Pandian, A.P., Palanisamy, R., Ntalianis, K. (eds) *Proceedings of International Conference on Intelligent Computing, Information and Control Systems. Advances in Intelligent Systems and Computing*, vol 1272. Springer, Singapore. [https://doi.org/10.1007/978-981-15-8443-5\\_19](https://doi.org/10.1007/978-981-15-8443-5_19)
- [74] Sultana, F., Sufian, A., & Dutta, P. (2020). Evolution of Image Segmentation using Deep Convolutional Neural Network: A Survey. *Knowl. Based Syst.*, 201-202, 106062.
- [75] Redmon, J., Divvala, S.K., Girshick, R.B., & Farhadi, A. (2015). You Only Look Once: Unified, Real-Time Object Detection. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788.
- [76] Terven, J., Córdova-Esparza, D. M., & Romero-González, J. A. (2023, November 20). A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*, 5(4), 1680–1716. <https://doi.org/10.3390/make5040083>
- [77] Jocher, G. YOLOv5 by Ultralytics. 2020. Available online: <https://github.com/ultralytics/yolov5> , [Ziyaret Tarihi: 12 Eylül 2023]
- [78] Wu, P., Weng, H., Luo, W., Zhan, Y., Xiong, L., Zhang, H., & Yan, H. (2023). An improved Yolov5s based on transformer backbone network for detection and classification of bronchoalveolar lavage cells. *Computational and Structural Biotechnology Journal*, 21, 2985–3001. <https://doi.org/10.1016/j.csbj.2023.05.008>
- [79] Yang, Q., Meng, H., Gao, Y., & Gao, D. (2023, December 12). A real-time object detection method for underwater complex environments based on FasterNet-YOLOv7. *Journal of Real-Time Image Processing*, 21(1). <https://doi.org/10.1007/s11554-023-01387-4>
- [80] Jocher, G., Chaurasia, A., & Qiu, J. (2023). YOLO by Ultralytics (Version 8.0.0) [Computer software]. <https://github.com/ultralytics/ultralytics> , [Ziyaret Tarihi: 12 Eylül 2023]
- [81] Reis, D.; Kupec, J.; Hong, J.; Daoudi, A. (2023). Real-Time Flying Object Detection with YOLOv8. *arXiv preprint arXiv:2305.09972*.

- [82] Meng, X.; Liu, Y.; Fan, L.; Fan, J. YOLOv5s-Fog: An Improved Model Based on YOLOv5s for Object Detection in Foggy Weather Scenarios. *Sensors* 2023, 23, 5321. <https://doi.org/10.3390/s23115321>
- [83] Kulkarni, U.; Naregal, K. ; Farande, V.; Guttigoli, S.; Angadi, A. ; Ujwane, R. An Object Detection Approach for Automated Detection of Groove Line in Tube Yoke. *ITM Web of Conferences*. 2023 53. 10.1051/itmconf/20235301007
- [84] U. (n.d.). Brief summary of YOLOv8 model structure · Issue #189 · ultralytics/ultralytics. GitHub. <https://github.com/ultralytics/ultralytics/issues/189> , [Ziyaret Tarihi: 12 Eylül 2023]
- [85] Kirillov, A. (2019, December 17). PointRend: Image Segmentation as Rendering. arXiv.org. <https://arxiv.org/abs/1912.08193>
- [86] Roboflow: Give your software the power to see objects in images and video. (n.d.). <https://roboflow.com/> , [Ziyaret Tarihi: 14 Kasım 2023]
- [87] COCO - Common Objects in Context. <https://cocodataset.org/#home>. [Ziyaret Tarihi: 14 Kasım 2023]
- [88] Hip-fx Dataset by Hips. (2023, February). Roboflow Universe. Roboflow. <https://universe.roboflow.com/hips/hip-fx>. [Ziyaret Tarihi: 14 Kasım 2023]
- [89] ChestPelvisCSpineScans. (2022, May 23). Kaggle. <https://kaggle.com/datasets/pardonndlovu/chestpelviscspinescans> , [Ziyaret Tarihi: 14 Temmuz 2023]
- [90] Radiopaedia.org, the peer-reviewed collaborative radiology resource. Radiopaedia. <https://radiopaedia.org/> , [Ziyaret Tarihi: 14 Temmuz 2023]
- [91] Pelvis AP X-ray Dataset by ks. (2023, June). Roboflow Universe. Roboflow. <https://universe.roboflow.com/ks-fsm9o/pelvis-ap-x-ray> , [Ziyaret Tarihi: 14 Temmuz 2023]
- [92] Hip fracture detection Dataset by KMITL MedAI. (n.d.). (2023, February). Roboflow Universe. Roboflow. <https://universe.roboflow.com/kmitl-medai/hip-fracture-detection> , [Ziyaret Tarihi: 14 Temmuz 2023]
- [93] Fracture Detection Dataset by G H Rasoni College of Engineering Nagpur. (2023, September). Roboflow Universe. Roboflow. <https://universe.roboflow.com/g-h-raisoni-college-of-engineering-nagpur-inpeu/fracture-detection-xpemm> , [Ziyaret Tarihi: 20 Ekim 2023]
- [94] testset Dataset by puripongroboflow. (2023, January). Roboflow Universe. Roboflow. <https://universe.roboflow.com/puripongroboflow/testset-hlkqy> , [Ziyaret Tarihi: 14 Temmuz 2023]

[95] validate\_set\_hip\_bone Dataset by indiect. (2022, September). Roboflow Universe. Roboflow. [https://universe.roboflow.com/indiect/validate\\_set\\_hip\\_bone](https://universe.roboflow.com/indiect/validate_set_hip_bone), [Ziyaret Tarihi: 1 Ekim 2023]

[96] hၵၵbၵne Dataset by puripongroboflow. (2023, January). Roboflow Universe. Roboflow. <https://universe.roboflow.com/puripongroboflow/-h-b-ne>, [Ziyaret Tarihi: 15 Kasım 2023]

[97] Roboflow Universe: Open Source Computer Vision Community. (n.d.). Roboflow. <https://universe.roboflow.com/>, [Ziyaret Tarihi: 7 Haziran 2023]

[98] F. (n.d.). GitHub - facebookresearch/detectron2: Detectron2 is a platform for object detection, segmentation and other visual recognition tasks. GitHub. <https://github.com/facebookresearch/detectron2>, [Ziyaret Tarihi: 15 Ekim 2023]



## İNTİHAL RAPORU İLK SAYFASI

ASSMA HIJAZI

ORJİNALLİK RAPORU

%**5**

BENZERLİK ENDEKSİ

%**4**

İNTERNET KAYNAKLARI

%**1**

YAYINLAR

%**3**

ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

<b>1</b>	<b>Submitted to The Scientific &amp; Technological Research Council of Turkey (TUBITAK)</b> Öğrenci Ödevi	% <b>2</b>
<b>2</b>	<b>acikbilim.yok.gov.tr</b> İnternet Kaynağı	<% <b>1</b>
<b>3</b>	<b>acikerisim.baskent.edu.tr</b> İnternet Kaynağı	<% <b>1</b>
<b>4</b>	<b>www.researchgate.net</b> İnternet Kaynağı	<% <b>1</b>
<b>5</b>	<b>tr.garyelshaw.com</b> İnternet Kaynağı	<% <b>1</b>
<b>6</b>	<b>Submitted to Nottingham Trent University</b> Öğrenci Ödevi	<% <b>1</b>
<b>7</b>	<b>doctorpenguin.com</b> İnternet Kaynağı	<% <b>1</b>
<b>8</b>	<b>Submitted to Anadolu University</b> Öğrenci Ödevi	<% <b>1</b>
<b>9</b>	<b>openaccess.thecvf.com</b> İnternet Kaynağı	<% <b>1</b>