

T.C.
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
TIP FAKÜLTESİ
ACİL TIP ANABİLİM DALI

ACİL SERVİSTE PROKSİMAL FEMUR FRAKTÜRLERİNİN
TESPİTİNDE YAPAY ZEKANIN KULLANIMI

Hazırlayan
Arş. Gör. Dr. Ekrem Buğra GÖKÇEK

Danışman
Doç. Dr. Ayşe ERTEKİN

AFYONKARAHİSAR 2025

T.C.
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
TIP FAKÜLTESİ

Acil Tıp Anabilim Dalı

ACİL SERVİSTE PROKSİMAL FEMUR FRAKTÜRLERİNİN
TESPİTİNDE YAPAY ZEKANIN KULLANIMI

Arş. Gör. Dr. Ekrem Buğra GÖKÇEK
TIPTA UZMANLIK TEZİ

Danışman
Doç. Dr. Ayşe ERTEKİN

2025 - AFYONKARAHİSAR

BİLİMSEL UYGUNLUK SAYFASI

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve danışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Tezi Hazırlayanın

Adı Soyadı: Ekrem Buğra GÖKÇEK

İmza :

Danışmanın

Ünvanı Adı Soyadı: Doç. Dr. Ayşe ERTEKİN

İmza :

XXXXXX

KABUL ONAY SAYFASI

T. C.

AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ

TIP FAKÜLTESİ

ACİL TIP ANABİLİM DALI

Tez Başlığı : Acil Serviste Proksimal Femur Fraktürlerinin Tespitinde
Yapay Zekanın Kullanımı

Tezi Hazırlayan : Arş. Gör. Dr. Ekrem Buğra GÖKÇEK

Tez Savunma Tarihi :

Tez Kabul Tarihi :

Tez Danışmanı : Doç. Dr. Ayşe ERTEKİN

İş bu çalışma jürimiz tarafından ACİL TIP ANABİLİM DALI'nda TIPTA
UZMANLIK TEZİ olarak kabul edilmiştir.

Başkan

AFSÜ Tıp Fakültesi Acil Tıp AD

Prof. Dr. Şerife ÖZDİNÇ

Üye

AFSÜ Tıp Fakültesi Acil Tıp AD

Doç. Dr. Ayşe ERTEKİN

Üye

AFSÜ Tıp Fakültesi Acil Tıp AD

Dr. Öğr. Üyesi Oya AKPINAR ORUÇ

ONAY

DEKAN

Prof. Dr. Necip BECİT

TEŞEKKÜR

Tıpta uzmanlık eğitimimde bilgi ve tecrübeleriyle yol gösteren, her konuda yardımına koşan, öğrencisi olmaktan onur duyduğum anabilim dalı başkanımız Sayın Prof. Dr. Şerife ÖZDİNÇ'e,

Uzmanlık eğitimimin ve tezimin başından sonuna her konuda yardımına koşan, hep güler yüzlü ve yardımcı olan çok kıymetli tez hocam Doç. Dr. Ayşe Ertekin'e,

Uzmanlık eğitimimin her aşamasında bilgi ve tecrübelerini esirgemeyen değerli hocalarım Dr. Öğr. Üyesi Oya Akpınar Oruç, Dr. Öğr. Üyesi Hülya Sevil, Dr. Öğr. Üyesi Neşe Nur User'e,

Hem asistanlık döneminde hem uzmanlık döneminde hem de hocalık döneminde her zaman desteğini hissettiğim kıymetli hocam Dr. Öğr. Üyesi Mehmet SOYUGÜZEL'e,

Uzmanlık tezimin yazım aşamasında yardımlarını eksik etmeyen arkadaşlarım ; Arş. Gör. Dr. Özgür ÇETİN'e ve Dr. Burak TOZLUK'a

Asistanlık döneminin zorluklarını beraberce aştığımız tüm asistan arkadaşlarıma, hemşirelerimize, acil servis personeline ve intörn doktor arkadaşlarıma,

Yol arkadaşım, her konuda yanımda ve koşulsuz destekçim olan sevgili eşim Dr. Dilara ÇULHAOĞLU GÖKÇEK'e,

Maddi manevi her türlü desteklerini esirgemeyen canım ailem; Atilla GÖKÇEK, Dilek GÖKÇEK, Metehan GÖKÇEK' e

Sonsuz sevgi ve teşekkürlerimi sunarım.

Ekrem Buğra GÖKÇEK
Afyonkarahisar, Ekim 2025

ACİL SERVİSTE PROKSİMAL FEMUR FRAKTÜRLERİNİN TESPİTİNDE YAPAY ZEKANIN KULLANIMI

Arş. Gör. Dr. Ekrem Buğra GÖKÇEK

Afyonkarahisar Sağlık Bilimleri Üniversitesi
Tıp Fakültesi Acil Tıp Anabilim Dalı Tıpta Uzmanlık Tezi
Ekim 2025

Danışman: Doç. Dr. Ayşe ERTEKİN

ÖZET

Giriş ve Amaç: Bu çalışmanın amacı, proksimal femur fraktürlerinin acil serviste tanınmasında yapay zeka tabanlı bir derin öğrenme modelinin doğruluğunu ve etkinliğini değerlendirmek; bu modelin acil tıp asistanının tanı performansı ile karşılaştırmalı olarak analizini yapmaktır.

Gereç ve Yöntem: Bu çalışmaya 15.08.2024-15.08.2025 tarihleri arasında Afyonkarahisar Sağlık Bilimleri Üniversitesi Tıp Fakültesi Acil Servisine travma şikayetiyle başvuran 18-100 yaş arası hastaların pelvik ve femur direkt grafi görüntüleri dahil edildi. Toplanan görüntüler ‘kırık var’, ‘kırık yok’, ve kırık sınıflandırmasına göre gruplara ayrıldı. Bounding box yöntemiyle görüntüler işaretlendi. İşaretleme sonrası Yolov11 algoritması ile model eğitimi yapıldı. Eğitilen bu model, acil tıp asistanı ve altın standard ile kıyaslandı.

Bulgular: Toplam 4.000 görüntü taranmış, uygun bulunan 2.000 görüntü ile yapay zekâ modeli eğitilmiştir. Test aşamasında kullanılan 400 görüntü üzerinden, yapay zekâ modeli ile acil tıp asistanının “kırık var/yok” değerlendirmeleri Cohen’s Kappa analizi ile karşılaştırılmıştır. Elde edilen Kappa katsayısı 0,980 olup, bu değer istatistiksel olarak anlamlı bulunmuştur ($p < 0,001$). Femur kırığı sınıflandırması açısından yapay zekâ modelinin, acil tıp asistanının değerlendirmelerine göre şaft kırıklarında %100 doğruluk sağladığı; boyun kırıklarında %78, intertrokanterik kırıklarda %88,8 ve subtrokanterik kırıklarda ise %59,6 doğruluk oranına ulaştığı tespit edilmiştir.

Sonuç: YOLOv11 tabanlı yapay zekâ modeli, kırık var/yok ayırımında yüksek doğruluk göstermiş ve kırık tiplerinin sınıflandırılmasında da genel olarak başarılı bulunmuştur. Özellikle subtrokanterik kırıklarda duyarlılığın diğer kırık tiplerine göre daha düşük olması, bu alandaki veri eksikliğine bağlanmakta ve çalışmanın literatüre katkı potansiyelini ortaya koymaktadır. Elde edilen bulgular, yapay zekâ destekli bu tür sistemlerin hızlı karar verilmesi gereken acil servis koşullarında destekleyici bir tanısal araç olarak kullanılabileceğini düşündürmektedir.

Anahtar kelimeler: Yapay Zeka, Acil Servis, Femur, Kırık, YOLOv11

THE USE OF ARTIFICIAL INTELLIGENCE IN THE DETECTION OF PROXIMAL FEMUR FRACTURES IN THE EMERGENCY DEPARTMENT

Dr. Ekrem Buğra GÖKÇEK

Afyonkarahisar Health Sciences University,
Faculty of Medicine, Department of Emergency Medicine,
Research Thesis in Medicine

October 2025

Advisor: Assoc. Prof. Dr. Ayşe ERTEKİN

ABSTRACT

Objective: This study aims to evaluate the accuracy and effectiveness of a deep learning model based on artificial intelligence in the detection of proximal femur fractures in the emergency department and to conduct a comparative analysis of its diagnostic performance against that of emergency medicine physician assistant.

Material and Method: Radiographic images of the pelvis and femur obtained from patients aged 18 to 100 years who presented with trauma to the Emergency Department of Afyonkarahisar Health Sciences University Faculty of Medicine between August 15, 2024, and August 15, 2025, were included in this study. The collected images were categorized as “fracture present,” “no fracture,” and further classified according to fracture type. The images were labeled using the bounding box method. After labeling, the model was trained using the YOLOv11 algorithm. This trained model was compared with the emergency medicine physician assistant and the gold standard.

Result: A total of 4,000 images were reviewed, and 2,000 suitable images were used to train the artificial intelligence model. In the testing phase, a set of 400 images was used to compare the “fracture present/absent” assessments made by the artificial intelligence model emergency medicine physician assistant through Cohen’s Kappa analysis. The resulting Kappa coefficient was 0.980, indicating a statistically significant agreement ($p < 0.001$). Regarding fracture classification, the artificial intelligence model achieved an accuracy of 100% for shaft fractures, 78% for femoral neck fractures, 88.8% for intertrochanteric fractures, and 59.6% for subtrochanteric fractures, compared to the assessments made by the the emergency medicine physician assistant.

Conclusion: The YOLOv11-based artificial intelligence model demonstrated high accuracy in distinguishing the presence or absence of fractures and was generally successful in classifying fracture types. The relatively lower sensitivity observed in subtrochanteric fractures is attributed to the limited amount of data available for this category, highlighting the study's potential contribution to the existing literature. These findings suggest that such artificial intelligence -assisted systems may serve as supportive diagnostic tools in emergency department settings where rapid decision-making is crucial.

Keywords: Artificial intelligence, Emergency Department, Femur, Fracture, YOLOv11

İÇİNDEKİLER

	Sayfa
İÇ KAPAK.....	i
BİLİMSEL UYGUNLUK SAYFASI.....	ii
KABUL ONAY SAYFASI.....	iii
TEŞEKKÜR.....	iv
ÖZET.....	v
ABSTRACT.....	vi
İÇİNDEKİLER	vii
KISALTMALAR LİSTESİ.....	ix
TABLolar DİZİNİ	x
ŞEKİLLER DİZİNİ.....	xi
1. GİRİŞ VE AMAÇ	1
2. GENEL BİLGİLER	3
2.1. FEMUR	3
2.2. FEMURUN ANATOMİK YAPISI.....	3
2.2.1. Proksimal Uç	3
2.2.1.1. Caput Femoris (Femur Başı).....	4
2.2.1.2. Collum Femoris (Femur Boynu).....	4
2.2.1.3. Trochanter Major (Büyük Trokanter)	5
2.2.1.4. Trochanter Minor (Küçük Trokanter).....	5
2.2.1.5. Corpus Femoris (Femur Cismi)	5
2.2.2. Diafiz (Gövde).....	5
2.2.3. Distal Uç	6
2.3. FEMURUN FONKSİYONU VE ÖNEMİ	6
2.4. FEMURUN VASKÜLER YAPISI	6
2.5. FEMUR KIRIKLARI.....	7
2.5.1. Epidemiyoloji	8
2.5.2. Proksimal Femur Kırıkları.....	8
2.5.2.1. Femur Başı Kırıkları	9
2.5.2.2. Femur Boynu Kırıkları.....	9
2.5.2.3. İntertrokanterik Kırıklar.....	9
2.5.2.4. Subtrokanterik Kırıklar	10

2.5.3. Femur Kırıklarında Klinik Bulgular ve Tanı	10
2.5.3.1. Klinik Bulgular	11
2.5.3.2 Fizik Muayene	11
2.5.3.2.1. İnspeksiyon.....	11
2.5.3.2.2. Palpasyon	11
2.5.3.3 Görüntüleme	12
2.5.3.3.1. Direkt Grafi	12
2.5.3.3.2. Bilgisayarlı Tomografi	14
2.5.3.3.3. Manyetik Rezonans Görüntüleme.....	14
2.6. YAPAY ZEKA.....	15
2.6.1. Yapay Zeka Tarihçe.....	15
2.6.2. Yapay Zeka ve Tanımı.....	16
2.6.2.1. Makine Öğrenmesi.....	17
2.6.2.1.1. Denetimli Makine Öğrenmesi	17
2.6.2.1.2 Denetimsiz Makine Öğrenmesi.....	17
2.6.2.1.3. Pekiştirmeli Öğrenme.....	17
2.6.2.2. Derin Öğrenme.....	18
2.6.3. YOLO (You Only Look Once).....	20
3. GEREÇ VE YÖNTEM	21
3.1. DİREK GRAFİ ÇEKİM PROTOKOLÜ.....	21
3.2. GÖRÜNTÜ ÖN İŞLEME	21
3.3. ÇALIŞMA TASARIMI.....	21
3.4. DERİN ÖĞRENME	22
3.5. İSTATİKSEL ANALİZ	30
4. BULGULAR	31
5. TARTIŞMA	44
6. SONUÇ	50
7. KAYNAKLAR	51
8. EKLER.....	59
EK 1: ETİK KURUL İZNİ.....	59
EK 2: VERİ TOPLAMA FORMU.....	61

KISALTMALAR LİSTESİ

AP	: Anteroposterior
AVN	: Avasküler nekroz
BT	: Bilgisayarlı tomografi
CASNET	: Causal Associational Network
CBAM	: Convolutional Block Attention Module
CNN	: Convolutional Neural Network (evrişimli sinir ağı)
DRR	: Dijital rekonstrüksiyon grafileleri
FPN	: Feature Pyramid Network
GAN	: Generatif adversaryal ağlar
GPU	: Graphics Processing Unit (grafik işlem birimi)
MRG	: manyetik rezonans görüntüleme
MTL	: Multi-task learning (çok görevli öğrenme)
YOLO	: You Only Look Once
YZ	: Yapay Zeka

TABLÖLAR DİZİNİ

	Sayfa
Tablo 1. YOLOv11 eğitim parametreleri	23
Tablo 2. Hastaların radyolojik tanı dağılımları	25
Tablo 3. YOLOv11 modelinin veri setlerindeki test performansı	27
Tablo 4. Cinsiyete göre kırık tipleri dağılımı	31
Tablo 5. Altın standart ve acil tıp asistanı kırık tespiti kıyaslaması	32
Tablo 6. Altın standart ve yapay zekanın kırık tespiti kıyaslaması	33
Tablo 7. Acil tıp asistanı ve yapay zekanın kırık tespiti kıyaslaması	33
Tablo 8. Altın standart ve acil tıp asistanının kırık sınıflaması tespitinin kıyaslaması	36
Tablo 9. Acil Tıp Asistanının Femur Kırık Tiplendirme Performansı	36
Tablo 10. Yapay zekâ ve acil tıp asistanının kırık sınıflaması tespitinin kıyaslaması..	37
Tablo 11. Yapay zekanın acil tıp asistanına kıyasla femur kırık tiplendirme performansı	40
Tablo 12. Altın standart ve yapay zekanın kırık sınıflaması tespitinin kıyaslaması .	42
Tablo 13. Yapay zekanın altın standarta kıyasla femur kırık tiplendirme performansı	43

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1. Femur anatomisi.....	3
Şekil 2. Femur proksimal uç anatomisi.....	4
Şekil 3. Yapay zeka alt kümeleri.....	16
Şekil 4. Yapay nöronun matematiksel modeli.....	18
Şekil 5. Yapay sinir ağı	19
Şekil 6. CNN Tasviri	19
Şekil 7. Derin Öğrenme Modelinin Hazırlanış Şeması	22
Şekil 8. YOLOv11'in sınırlandırıcı kutular ile tespit ve sınıflandırma örneği.....	24
Şekil 9. Karışıklık matrisinin şematik gösterimi	25
Şekil 10. İlk Grup verileri için YOLOv11 modelinin eğitim-doğrulama metrikleri ve kayıp değerleri analizi	26
Şekil 11. İkinci grup verileri için YOLOv11 modelinin eğitim-doğrulama metrikleri ve kayıp değerleri analizi	26
Şekil 12. İlk grup veri setine göre sınırlayıcı kutu (bounding box) ve yapılan sınıflandırma grafikleri.....	28
Şekil 13. İkinci grup veri setine göre sınırlayıcı kutu (bounding box) ve yapılan sınıflandırma grafikleri.....	28
Şekil 14. YOLOv11 modelinin ilk grup veri seti için karışıklık matrisi	29
Şekil 15. YOLOv11 modelinin ikinci grup veri seti için karışıklık matrisi	29
Şekil 16. Altın Standardın İşaretlemesi(A) Acil Tıp Asistanının İşaretlemesi(B) Yapay Zekanın işaretlemesi(C)	39

1. GİRİŞ VE AMAÇ

Küresel ölçekte yaşlı nüfusun giderek artması, proksimal femur kırıklarının görülme sıklığında da önemli bir yükselişe yol açmaktadır. Yapılan projeksiyonlara göre, 2050 yılına kadar dünya genelinde kalça kırıklarının 6 milyonun üzerinde kişiyi etkilemesi öngörülmektedir (1).

Kalça eklemінде kuvvet iletiminin merkezi yapılarından biri olan proksimal femur, aşırı ya da yüksek şiddetli yüklenmelere maruz kaldığında yaralanmaya açık hale gelir (2). Yüksek mortalite oranı, komplikasyon sıklığı, mobilite kaybı ve yaşam kalitesindeki ciddi bozulma nedeniyle, proksimal femur kırığı olan hastalar ciddi ölçüde fiziksel ve psikososyal sıkıntılarla karşı karşıya kalmaktadır. Kalça eklemi travmalarını takiben, ilk değerlendirme ve tanı genellikle acil servis koşullarında gerçekleştirilmektedir. Bu süreçte, kırığın varlığını belirlemede direkt grafik çoğunlukla ilk tercih edilen görüntüleme yöntemi olmaktadır. Bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) gibi ileri görüntüleme yöntemleri ile kıyaslandığında, direkt grafi; erişilebilirliği yüksek, hızlı uygulanabilir, ekonomik ve klinik pratikte yorumlanması görece kolay bir yöntemdir. Bu bağlamda, direkt grafi görüntülerini doğru şekilde okuyabilmek, hekimler açısından tanı doğruluğu ve tedavi başarısını doğrudan etkileyen temel bir klinik yeterlilik olarak değerlendirilmektedir. Ancak özellikle acil servislerin yoğun ve zaman baskısı altındaki ortamlarında, ayrıca deneyimli hekim eksikliğinin bulunduğu durumlarda, küçük, non-deplese veya klinik olarak gizli seyreden (okkült) kırıkların gözden kaçırılması ya da yanlış tanı konulması riski önemli ölçüde artmaktadır (3).

Literatürdeki bazı çalışmalarda, yoğun ve acil klinik koşullarda tanı atlama veya yanlış tanı oranlarının %40'ın üzerine çıkabildiği bildirilmiştir. Bu durum, klinik tanı süreçlerinin güvenilirliğini olumsuz yönde etkilemekte, etkili tedavi yaklaşımlarının gecikmesine neden olmakta ve dolayısıyla hasta prognozunu kötüleştirebilmektedir (4,5). Bu doğrultuda, kemik kırıklarının tanısında yüksek doğruluk ve güvenilirlik sağlayabilecek destekleyici tanı araçlarına olan gereksinim hâlen sürmektedir. Akıllı tıp uygulamalarının çerçevesinde öncü teknolojilerinden biri olan yapay zeka (YZ) , özellikle makine öğrenmesi (MÖ) ve derin öğrenme(DÖ) yaklaşımlarının entegrasyonu ile birlikte tıbbi görüntü analizinde önemli bir ilerleme kaydederek etkili bir tanı destek aracı hâline gelmiştir (6). Yapay zakanın belirgin

avantajlarından biri, hedef yapılara ait ayırıcı özellikleri tanıyabilme kapasitesi sayesinde, bu bilgileri görüntü analizinde tanıya yönelik işlem algoritmalarına dönüştürebilmesidir. Literatürdeki önceki çalışmalar, YZ tabanlı sistemlerin; patolojik kesit görüntüleri, kapsül endoskopi, ultrason ve diğer radyolojik incelemelerdeki anormal bölgelerin saptanmasında başarılı sonuçlar verdiğini ve tanı doğruluğu ile tespit hassasiyetini anlamlı düzeyde artırdığını ortaya koymuştur (7–11).

Bu tez çalışması, YZ'nin acil servislerde direkt grafi görüntülerinin analizi üzerindeki etkilerini incelemeyi ve bu teknolojinin acil hekimlerine özellikle femur kırıklarında nasıl kolaylık sağlayabileceğini araştırmayı amaçlamaktadır. YZ'nin direkt grafik analizindeki yetenekleri, hızlı ve doğru teşhis konulmasına yardımcı olarak hasta bakımını iyileştirebilir ve acil servislerdeki iş yükünü azaltabilir (12). Bu bağlamda, çalışmamız YZ'nin acil tıptaki potansiyelini değerlendirmek ve bu teknolojinin klinik uygulamalardaki etkinliğini ortaya koymak için önemli bir adım olacaktır.

2. GENEL BİLGİLER


2.1. FEMUR

Femur, insan vücudundaki en uzun, en kalın ve en güçlü kemiktir (13). Vücut ağırlığının taşınmasında, hareketin sağlanmasında ve alt ekstremitenin ana iskelet yapısını oluşturmada temel rol üstlenir (14). Ortalama bir yetişkinde femur uzunluğu, boy uzunluğunun yaklaşık dörtte birine karşılık gelir (15).

Femurun yapısal dayanıklılığı, yoğun kortikal kemik dokusuna ve iç kısımda bulunan trabeküler mimariye dayanır. Özellikle alt ekstremitte yüklenmeleri sırasında hem statik hem de dinamik kuvvetlere direnç gösterir (16).

2.2. FEMURUN ANATOMİK YAPISI


Femur üç temel bölüme ayrılarak incelenir: proksimal uç, diafiz (gövde) ve distal uç (Şekil 1).



Şekil 1. Femur anatomisi

2.2.1. Proksimal Uç

Femurun proksimal ucu, kalça ekleminin stabilitesi ve alt ekstremitenin yük taşıma kapasitesi için kritik öneme sahiptir. Bu bölge, caput femoris (femur başı), collum femoris (femur boynu), trochanter major büyük trokanter) ve trochanter minor (küçük trokanter) gibi temel anatomik yapılardan oluşur (13)(Şekil-2).



Şekil 2. Femur proksimal uç anatomisi

2.2.1.1. Caput Femoris (Femur Başı)

Caput femoris, yaklaşık 2/3 oranında küre şeklindedir ve asetabulum ile eklem yaparak kalça eklemine oluşturur. Eklem yüzeyi, kalın ve dayanıklı bir hiyalin kıkırdak ile kaplıdır; bu kıkırdak, hem yük taşıyan hem de hareket eden bir eklem için sürtünmeyi azaltarak koruyucu bir ortam sağlar (14). Caput'un merkezinde yer alan fovea capitis femoris, ligamentum capitis femoris'in bağlandığı alan olup, burada küçük damarlar femur başına kısıtlı da olsa kan desteği sağlar (16). Bu yapı, özellikle travma sonrası iyileşme süreçlerinde önemli olabilir (17).

2.2.1.2. Collum Femoris (Femur Boynu)

Collum femoris, caput ile corpus femoris arasında uzanan, eğimli ve dar bir yapıdır. Yaklaşık 125°'lik kollodialfizer açı oluşturur, ancak bu açı bireyin yaşına, cinsiyetine ve anatomik varyasyonlara göre değişiklik gösterebilir (18). Femur boyununun görevi, kalça eklemine hareket serbestliğini artırmak ve yürüme sırasında oluşan stresleri absorbe etmektir. Ancak damarların bu bölgede seyretmesi nedeniyle, intrakapsüler kırıklar vasküler yapıların zarar görmesiyle birlikte avasküler nekroz (AVN) riski doğurabilir (19).

2.2.1.3. Trochanter Major (Büyük Trokanter)

Trochanter major, femurun dış (lateral) yüzeyinde, boynun hemen distalinde yer alan belirgin ve geniş bir çıkıntıdır. Anatomik olarak, gluteus medius, gluteus minimus, piriformis ve obturator internus gibi kasların tutunma noktasıdır (13). Bu kaslar, kalça abduksiyonu ve rotasyonunda rol oynar. Trochanter major, palpasyonla kolayca hissedilebilir ve klinik muayenede kalça patolojilerinin değerlendirilmesinde önemli bir anatomik işarettir (16).

2.2.1.4. Trochanter Minor (Küçük Trokanter)

Trochanter minor, femurun posterior-medial yüzeyinde, boynun hemen distalinde yer alır. Anatomik işlevi, iliopsoas kas grubunun (m. iliacus ve m. psoas major) tutunma noktası olmasıdır (14). İliopsoas kası, kalça fleksiyonu ve eksternal rotasyonda önemli görev üstlenir. Küçük trokanterin yapısal değişiklikleri veya patolojileri, özellikle travmatik kalça yaralanmalarında klinik önem taşıyabilir (19).

2.2.1.5. Corpus Femoris (Femur Cismi)

Corpus femoris, femurun en uzun kısmını oluşturur ve mekanik streslerin absorbe edilmesi ile yük aktarımının sağlanmasında başlıca rolü üstlenir (13). Gövde boyunca uzanan linea aspera, adduktor ve quadriceps kas gruplarının güçlü bir şekilde femura tutunduğu çizgisel bir çıkıntıdır. Femur cismi, hem kemik dayanıklılığı hem de kas fonksiyonlarının düzenlenmesi açısından iskelet sisteminin temel unsurlarından biridir (15).

2.2.2. Diafiz (Gövde)

Femur diafizi, proksimal ve distal uçları birbirine bağlayan uzun ve güçlü kemik bölümüdür. Hafif medial konkavlık göstererek, vücut ağırlığının optimal şekilde diz eklemine aktarılmasına yardımcı olur (18). Posterior yüzey boyunca uzanan linea aspera, adduktor kaslar ve quadriceps femoris grubu kaslarının yapışma noktasıdır (15). Diafizin kalın kortikal yapısı, mekanik streslere karşı dayanıklılık sağlar (20).

2.2.3. Distal Uç

Distal uęta medial ve lateral kondiller, interkondiler fossa ve patellar yüzey bulunur. Kondiller, tibia ile eklem yaparak diz eklemine oluşturur. Ayrıca patellar yüzey, patellanın femurla uyumlu hareketine olanak tanır (21). Distal femur, yük taşıma ve eklem stabilitesi açısından kritik öneme sahiptir. Özellikle interkondiler fossa, ön ve arka çapraz bağların tutunduęu anatomik bölgedir (22).

2.3. FEMURUN FONKSİYONU VE ÖNEMİ

Femur, vücut ağırlığını taşımanın yanı sıra kas-iskelet sisteminde birçok kasın tutunma yüzeyini oluşturarak hareketin koordinasyonunda görev alır (23). Femur aynı zamanda hematopoetik aktiviteye katkıda bulunan kırmızı kemik ilięini barındırır (24). Femurun dayanıklılığı ve mekanik işlevleri, günlük aktivitelerden atletik performansa kadar geniş bir yelpazede önem taşır. Femur hasarları, hem mobilite kaybına hem de yaşam kalitesinde ciddi azalmaya yol açabilir (14).

2.4. FEMURUN VASKÜLER YAPISI

Asetabulum, obturator arter, superior gluteal arter ve inferior gluteal arter olmak üzere üç temel kaynaktan kanlanır. Üst ve arka bölgelere superior gluteal arter, alt ve arka kısımlara ise inferior gluteal arter dolaşım sağlar. Medial yüzey ise obturator arterin asetabular dalı tarafından beslenir (25).

Femur başı ve boynunun ana kan kaynaęı, profunda femoris arterden ayrılan medial femoral sirkümfleks arterdir. Bu arter, retinaküler dalları aracılığıyla doğrudan femur başına kan taşır. Medial femoral sirkümfleks arterin bir dalı olan lateral epifizeal arter, femur başının yük taşıyan bölümünü ve yaklaşık olarak yarısını besler. Profunda femoris arterin bir dięer kolu olan lateral femoral sirkümfleks arter, femur başının vaskülarizasyonuna sınırlı katkı sağlar; ancak trokanterik bölgenin kanlanmasında daha etkin rol oynar. Medial ve lateral femoral sirkümfleks arterler, femur boynu çevresinde bir ekstrakapsüler arteriyel halka oluşturur. Lateral femoral sirkümfleks arterden çıkan ve femur boynuna doğru ilerleyen dallar, özellikle proksimal femur kırıklarında hasar görebilir. Bu durumda, femur başı kanlanması ciddi düzeyde bozulabilir (26). Obturator arterin bir dalı, ligamentum capitis femoris yolu ile femur başına ulaşarak kanlanmaya katkıda bulunur. Bu vasküler yapı, özellikle çocukluk

döneminde femur başı için daha anlamlı bir dolaşım kaynağıdır. Ancak erişkin bireylerde bu katkı oldukça sınırlıdır. Yine de, pediatrik olgular ve özellikle travmaya bağlı kalça çıkıklarında, bu damar dikkate alınması gereken bir unsurdur (27). İntrakapsüler femur kırıkları, bu damarların zarar görmesi sonucu AVN gibi ciddi komplikasyonlara yol açabilir (17).

2.5. FEMUR KIRIKLARI

Femur, vücutta yer alan en uzun ve en sağlam kemik olup, hem taşıyıcı işlevi hem de eklem stabilitesine katkısı nedeniyle travmatolojide klinik açıdan büyük önem taşır. Alt ekstremitenin temel yük taşıyıcı elemanı olan femur, proksimal, diafiz ve distal olmak üzere üç temel anatomik bölgeye ayrılır (13–15). Her anatomik bölge, farklı travma mekanizmaları ve biyo-mekanik özelliklere sahip olduğu için bu kırıkların oluşumu, seyri ve tedavi yaklaşımı birbirinden önemli derecede farklılık gösterir (14,20,23).

Proksimal femur kırıkları, yaşlı bireylerde özellikle düşük enerjili düşme sonrası, gençlerde ise yüksek enerjili travmalar (örneğin trafik kazaları) sonucu meydana gelir. Bu kırıklar arasında femur boynu kırıkları, en sık görülen ve aynı zamanda en fazla komplikasyon içeren formdur (25,26). Bu kırıklar intraartiküler konumda yer aldığı için femur başını besleyen damarların zedelenmesine neden olur ve bu durum sıklıkla AVN ve kaynamama ile sonuçlanır (27,28). Özellikle ilk 12–24 saat içinde cerrahi müdahale yapılmayan olgularda AVN riski %30–100 arasında değişebilmektedir (29,30).

Geriatrik hastalarda görülen kalça kırıkları, osteoporozun da katkısıyla çoğunlukla basit travmalarla ortaya çıkar. Bu kırıklar hastaneye yatışların önemli bir nedenini oluşturur ve hem morbidite hem de mortalite oranlarını yükseltir (28).

Femur diafiz kırıkları genellikle genç popülasyonda yüksek enerjili travmalar sonucu oluşur. Bu kırıklar çoğunlukla segmental, spiral ya da çok parçalı yapıdadır. Yoğun kas yapısının etkisiyle ciddi deplasman ve rotasyonel deformiteler görülebilir (31–33).

Distal femur kırıkları, femurun diz eklemine yakın 15 cm'lik bölümünde oluşan ve toplam femur kırıklarının %3–6'sını oluşturan kırıklardır (34). İki ayrı yaş

grubunu etkileyen bu kırıklar, bimodal özellik gösterir. Genç yaş grubunda trafik kazası gibi yüksek enerjili olaylar etkiliyken, geriatrik bireylerde genellikle basit düşmeler gibi düşük enerjili travmalarla ve ilişkilidir (35).

2.5.1. Epidemiyoloji

Pelvik kırıklar, tüm vücut kırıklarının yaklaşık %3'ünü oluşturmakla birlikte, genellikle yüksek enerjili travmalar sonucu meydana gelir. En sık karşılaşılan etiyolojik neden trafik kazalarıdır ve bu kırıkların yaklaşık %60'ı motorlu taşıt çarpışmalarıyla ilişkilidir. İkinci sırada ise özellikle yaşlı bireylerde görülen yüksekten ya da basit düşmelere bağlı oluşan kırıklar yer almakta olup, bu durum toplam olguların yaklaşık %30'unu kapsar. Epidemiyolojik veriler, pelvik kırıkların erkek bireylerde daha sık görüldüğünü ve olguların %55 ila %65'inin erkek hastalardan oluştuğunu göstermektedir (36).

Yaşlı bireylerde görülen kalça ve pelvis kırıkları, genellikle düşük enerjili travmalar, özellikle de basit düşmeler sonrası ortaya çıkmakta ve ciddi klinik sonuçlara yol açmaktadır. Bu kırıklar, özellikle ileri yaş grubunda yüksek mortalite oranlarıyla seyretmektedir. Trafik kazalarına bağlı ölümlerin yaklaşık üçte biri, pelvis kırıkları ve bu kırıkların neden olduğu komplikasyonlarla ilişkilidir. Proksimal femur kırıklarının %90'ı, 65 yaş ve üzerindeki bireylerde gözlenmekte ve bu durum yaşlı nüfusta önemli bir sağlık sorunu oluşturmaktadır. Kalça kırıkları, yaşlılarda hastaneye yatış nedenleri arasında en yaygın ikinci neden olup, bu hastalarda ciddi morbidite ve mortalite riski taşımaktadır. Kırıkların yaklaşık %90'ı düşme sonucu meydana gelirken, en sık ölüm nedeni şiddetli hemorajidir. Literatürde bildirilen bulgulara göre, kalça kırığı sonrası bir yıllık ölüm oranı %14 ile %36 arasında değişmektedir. Bu kırıkların artan yaşla birlikte daha sık görüldüğü, yaşlı popülasyonun büyümesine paralel olarak insidansın da yükseldiği bildirilmektedir. ABD'de yalnızca 2008 yılında 341.000 kalça kırığı vakası raporlanmış, 2040 yılına kadar bu sayının yaklaşık 582.000'e ulaşacağı tahmin edilmektedir (37,38).

2.5.2. Proksimal Femur Kırıkları

Proksimal femur, kalça ekleminin yapısına katılan ve alt ekstremitenin taşıyıcı hattını oluşturan karmaşık bir kemik yapıdır. Anatomik olarak dört bölgeye ayrılır: femur başı, femur boynu, intertrokanterik bölge ve subtrokanterik bölge. Her bölge,

biyomekanik yüklenme ve damar dağılımı açısından farklı özellikler gösterdiği için kırıkların tipi, prognozu ve tedavisi de farklılık gösterir (13–15,20).v Kalçaya ait proksimal femur kırıkları, trokanter minorun 5 cm distal sınırına kadar uzanan femur bölgesinde oluşan kırıkları içerir (39).

2.5.2.1. Femur Başı Kırıkları

Femur başı kırıkları, genellikle yüksek enerjili travmalar sonucunda meydana gelir ve sıklıkla travmatik kalça çıkığı, femur boynu kırığı ya da genç bireylerde asetabulum kırığı gibi diğer ciddi yaralanmalarla birlikte görülür. Bu tür kırıklar, kalça ekleminin en ciddi yaralanmaları arasında yer almakta olup, çoğunlukla alt ekstremitede çoklu travmalarla birlikte seyreder. Femur başının kanlanması bu durumlarda ciddi ölçüde bozulur ve buna bağlı olarak komplikasyon oranları yüksektir. Olguların yaklaşık %10'unda n. ischiadicus (siyatik sinir) hasarı eşlik eder; çoğu zaman bu sinir hasarı gerilme ve kontüzyona bağlı olup, redüksiyon sonrası süreçte fonksiyonel iyileşme gözlenebilir (40–42).

2.5.2.2. Femur Boynu Kırıkları

Proksimal femurun intrakapsüler kısmında yer alır ve femur başına kan taşıyan damarların seyrettiği bölgededir. Bu nedenle kırık sonrası femur başının kanlanması bozulabilir ve AVN riski doğar . Yaşlı bireylerde düşük enerjili travmalarla, genç bireylerde ise yüksek enerjili travmalarla oluşur. Klinik olarak bacakta kısılma, dış rotasyon ve ağırlık verememe gibi bulgularla tanınır (13,14).

Femur boynunun büyük kısmı intrakapsülerdir ve bu bölgede kemik periostunun kambiyum tabakası olmadığı için periferik kallus oluşmaz; kaynama endostealdir. Kalça eklemi içindeki eklem sıvısındaki hiyalüronik asitin damarlanmayı önleyici etkisi kırık kaynamasına olumsuz etki yaratır. Özellikle İntrakapsüler kırıklarda ciltte ekimoz görülmez. Femur boyun kırıklarında, kırık hematomunun oluşturduğu intrakapsüler basıncın femur başının kanlanmasını azaltabileceği bildirilmiştir (43).

2.5.2.3. İntertrokanterik Kırıklar

Trochanter major ile minor arasında yer alır ve ekstrakapsüler bölgededir. Kanlanması iyi olduğu için kaynama potansiyeli yüksektir (23). Kalça kırıklarında

prognoz, kırığın anatomik lokalizasyonuna bağılı olarak deęişkenlik gösterir. İntertrokanterik kırıklar, proksimal femur kırıkları içerisinde en sık karşılaşılan tipi olup, bu kırıkların yaklaşık %50'sini oluşturur (44). Görölme sıklığı açısından, intertrokanterik kırıklar, femur boyun kırıklarına göre yaklaşık dört kat daha fazladır (45–48). İntertrokanterik femur kırıkları, genellikle doğrudan veya dolaylı travmatik kuvvetlerin etkisiyle oluşur. Doğrudan kuvvetler, basit bir düşme ya da yüksekten düşme sonrası ortaya çıkabilir; bu durumda travma ya femur aksı boyunca iletilerek ya da doğrudan büyük trokanter üzerine binen basınçla kırığa yol açabilir (49). Yaşlı bireylerde kalça kırıkları çoğunlukla düşme gibi düşük enerjili travmalarla, genç hastalarda ise yüksek enerjili travmatik olaylar sonucunda gelişir. Travmaya bağılı olarak sıklıkla kalçada ağrı, şişlik ve ekimoz meydana gelir. Bu hastalarda, özellikle ciddi kanama riski ve altta yatan komorbiditeler göz önünde bulundurularak hemodinamik durumun dikkatle izlenmesi büyük önem taşır (50).

2.5.2.4. Subtrokanterik Kırıklar

Fielding'e göre, subtrokanterik bölge; küçük trokanterin hemen üzerinden geçen transvers bir çizgi ile, bu seviyenin yaklaşık üç katı distalinde yer alan alanı kapsar. Alternatif tanımlamalarda ise bu bölge, küçük trokanterin tepe noktası ile 5 cm distalindeki kısım arasında kalan alan olarak tarif edilir. Başka bir görüşe göre ise subtrokanterik bölge, küçük trokanterin üst kısmından başlayarak femur cismindeki istmusa kadar uzanır. Bu kırıklar, tüm femur kırıkları içinde %7 ila %20 oranında görölmektedir (51). Bu bölge yoğun kortikal yapısı nedeniyle kaynaması zor ve cerrahisi zorlu kırık grubudur. Biyomekanik olarak en fazla stres taşıyan bölge olması, implant yorgunluğu ve kaynamama riskini artırır. Yüksek enerjili travmalar veya osteoporoz zemininde kırık gelişebilir (13,23).

2.5.3. Femur Kırıklarında Klinik Bulgular ve Tanı

Hasta acil servise başvurduğunda öncelikli olarak vital bulgular değerlendirilir, hava yolu açıklığı güvence altına alınır ve intravenöz damar yolu açılır. Hastanın hemodinamik stabilitesi sağlandıktan sonra, varsa eşlik eden diğer patolojilerin değerlendirilmesine geçilir (52). Primer değerlendirme ve hayati tehlike oluşturan durumlara müdahale tamamlandıktan sonra, sekonder değerlendirme aşamasına geçilir. Bu evrede hastanın tam tıbbi öyküsü alınır, baş-boyun, toraks, batin, pelvis,

ekstremiteler ve omurga detaylı muayene edilir. Görüntüleme yöntemleri ve laboratuvar testleriyle eşlik eden patolojiler belirlenir (53).

2.5.3.1. Klinik Bulgular

Kırığın anatomik lokalizasyonuna göre gelişen klinik belirtiler değişkenlik gösterir.

- Proksimal femur kırıklarında tipik olarak kalça bölgesinde ani ve şiddetli ağrı, etkilenen bacakta kısılma, dışa rotasyon deformitesi, ayakta duramama ve hareketle belirginleşen hassasiyet gözlenir (15,54).

- Diafiz kırıklarında: Uylukta yaygın ağrı, palpasyonda krepitasyon, belirgin deformite ve hematoma görülebilir (14).

- Distal femur kırıklarında: Diz çevresinde şişlik, intraartiküler sıvı birikimi ve hareket kısıtlılığı ön plandadır (23).

2.5.3.2 Fizik Muayene

2.5.3.2.1. İnspeksiyon

Travma hastasının değerlendirilmesinde, tüm kıyafetleri çıkarılarak vücut yüzeyinin tamamen gözlenmesi sağlanmalıdır. Bu sayede olası açık yaralar, belirgin şekil bozuklukları ve deformiteler tespit edilir. Özellikle açık pelvis ve femur boyun kırıkları, enfeksiyon riski ve yumuşak doku hasarı nedeniyle daha kötü prognoz ile ilişkilidir. Pelvis ve femur kırıklarının bir göstergesi olarak yumuşak doku üzerindeki hematomlar dikkat çekicidir. Alt ekstremitelerde kısıklık tespiti, pelvis veya femurda vertikal yer değiştirmiş bir kırığın varlığına işaret edebilirken; dış rotasyon deformitesi, sıklıkla proksimal femur kırıklarını düşündürür (55,56).

2.5.3.2.2. Palpasyon

Travma hastasının değerlendirilmesinde, tüm eklem bölgeleri sistematik olarak muayene edilmelidir. Cilt ve cilt altı dokular, eklem çevresi ile birlikte dikkatle incelenmeli; travma bölgesinde hassasiyet, ısı artışı, şekil bozukluğu ve olası deformiteler değerlendirilmelidir. Palpasyon sırasında, karşı taraf ekstremiteleriyle

karşılaştırmalı değerlendirme yapılması, asimetrielerin ve patolojik bulguların daha doğru saptanmasına yardımcı olur (57).

Hemipelvis ve kalça eklemine ait kırıklarda, palpasyonla hareket kısıtlılığı ve krepitasyon saptanabilir. Ancak hemodinamik instabilite gösteren hastalarda, bu tür fizik muayene manevraları kanamayı artırabileceğinden, muayene hızlı ve tek seferde tamamlanmalıdır. Ayrıca, izole femur kırıklarında dahi önemli miktarda internal kanama gelişebileceği unutulmamalıdır. Muayene sırasında nörolojik ve sistemik değerlendirme ihmal edilmemeli; gerekirse kanama kontrolü sağlandıktan sonra kırık tespiti yapılmalıdır (52).

2.5.3.3 Görüntüleme

Femur kırıklarının tanısında görüntüleme yöntemleri kritik rol oynar. Direkt grafi, ekstremiteler kırıklarının saptanmasında ilk basamak görüntüleme yöntemi olarak tercih edilir. Ancak bazı olgularda, özellikle kırık hattının belirgin olmadığı durumlarda, kırığın tespitinde yetersiz kalabilmektedir (58). Kalça çevresi kırıklarında ilk değerlendirme için standart direkt grafi altın standart olarak kabul edilmektedir. Tüm travma merkezlerinde kolayca ulaşılabilir olmaları, düşük maliyetli olmaları ve hızlı şekilde uygulanabilmeleri, direkt grafiğin başlıca avantajları arasında yer alır. Değerlendirme amacıyla öncelikle anteroposterior (AP) ve lateral kalça grafileri çekilmelidir. Ancak, hastanın yaşadığı şiddetli ağrı nedeniyle lateral görüntülemenin yapılması bazı durumlarda güçlük yaratabilir (59).

2.5.3.3.1. Direkt Grafi

X-ışını, 1895 yılında Alman fizikçi Wilhelm Conrad Röntgen tarafından tesadüfen keşfedilmiştir. Röntgen görüntüleme, tıpta kullanılan en eski radyolojik tanı yöntemlerinden biri olup, günümüzde hâlâ temel görüntüleme aracı olarak önemini sürdürmektedir. X-ışınının bilinen neredeyse tüm fiziksel özellikleri, keşfinden sonraki ilk bir ay içerisinde Wilhelm Conrad Röntgen tarafından tanımlanmıştır. 1896 yılında, eşinin elini görüntüleyerek tıpta X-ışını ile yapılan ilk görüntülemeyi gerçekleştiren kişi de yine Röntgen olmuştur (60).

Görüntüleme amacıyla X-ışını tüpü kullanılır. Bu tüp, X-ışını jeneratöründen sağlanan elektrik enerjisini kullanarak X-ışını fotonları üretir. İçeride hızlandırılan

elektronlar, hedef malzeme ile etkileşime girerek X-ışınlarını oluşturur. Bu etkileşim sırasında elektronların kinetik enerjisinin büyük bölümü ısıya dönüşürken, bir kısmı da elektromanyetik radyasyon olarak salınır. Normalde her yöne yayılan bu X-ışınları, kurşun kaplama ve kolimatör sistemleri sayesinde belirli bir doğrultuda yönlendirilerek görüntü elde edilmesini sağlar. X-ışınının tıbbi görüntülemede kullanılmasını mümkün kılan temel özellik, vücut dokularını kısmen geçebilme yeteneğidir. İnsan vücudunda yer alan farklı yapıların yoğunluk, kalınlık ve atom numarası açısından gösterdiği farklılıklar, X-ışınlarının bu dokulardan geçişini değişken hale getirir. Her dokunun X-ışınına karşı gösterdiği geçirgenlik ve absorpsiyon oranı farklı olduğundan, X-ışını demetinin film üzerine düşen miktarı da dokuya göre farklılık gösterir. Bu farklılık sayesinde elde edilen görüntüler, siyah ve beyaz arasında değişen gri tonlarda oluşur ve böylece ilgili vücut bölgesinin anatomik yapısı görüntülenebilir (61).

Radyolojik görüntülerde görülen koyu alanlar, X-ışınlarını büyük oranda geçiren, yani düşük dansiteye (radyolusen) sahip yapıları yansıtır. Buna karşılık, açık ya da beyaz tonlar, X-ışınlarını geçirmeyip büyük oranda soğuran, yani yüksek dansiteli (radyoopak) dokulara karşılık gelir. Örneğin, kemik dokusu ve bazı yabancı cisimler görüntüde beyaz olarak görünürken, kas, yağ dokusu ve hava gibi yapılar daha az yoğun oldukları için siyaha yakın tonlarda izlenir (62). Üç boyutlu vücut yapılarının iki boyutlu görüntüleme yöntemleriyle değerlendirilmesi sonucunda, farklı anatomik düzeylerdeki yapıların görüntüleri üst üste biner. Bu duruma süperpozisyon adı verilir ve görüntüde detayların ayırt edilmesini zorlaştırabilir. Travmaya uğrayan uzvun değerlendirilmesinde, doğru tanı koyabilmek için radyolojik inceleme mutlaka iki farklı planda yapılmalıdır. Eğer eklem bölgesine yakın bir yaralanma şüphesi varsa, bu durumda oblik açıyla alınan ek görüntüler, olası patolojilerin daha net ortaya konmasına yardımcı olur (51).

Proksimal femur ve asetabulum kırıklarının değerlendirilmesinde, ilk tercih edilmesi gereken görüntüleme yöntemi standart AP pelvis grafisidir. Görüntülemenin doğru anatomik referans noktalarına göre yapılması tanı açısından büyük önem taşır. Görüntü kalitesini artırmak amacıyla, her iki bacak yaklaşık 15 derece iç rotasyona getirilmelidir. Merkez ışın, her iki spina iliaka anterior superior noktası ile symphysis pubisin üst kenarı arasında ortalanmalıdır. Bu grafide dikkatle incelenmesi gereken yapılar arasında; anterior ve posterior asetabular duvarlar, asetabular çatı, gözyaşı şekli

(teardrop), iliopektineal ve ilioiskial çizgiler yer alır.İliopektineal çizgi, pubik ramustan aynı taraftaki sakroiliak eklem kadar uzanan ön kolunu temsil ederken; ilioiskial çizgi, spina iliaka posterior superior'dan iskiüma kadar uzanarak arka kolunu gösterir (52).

2.5.3.3.2. Bilgisayarlı Tomografi

Konvansiyonel radyografiler, travma hastalarının ilk değerlendirmesinde hâlâ temel bir araç olarak kullanılmaktadır. Ancak çok düzlemli inceleme imkânı ve üç boyutlu görüntüleme kapasitesi sayesinde, özellikle karmaşık kırık vakalarında BT'nin önemi giderek artmıştır. BT; eklem içi fragmanların yer değiştirmesi, eklem yüzeyinde meydana gelen çökme, kemik kayıpları, implant seçimi, ayrıca minimal invaziv cerrahi planlaması gibi konularda detaylı bilgi sağlar. Aynı zamanda, ameliyat sonrası kırık uyumu ve yerleştirilen implantların değerlendirilmesinde de yüksek çözünürlüklü ve güvenilir veriler sunar (63).

Pelvis ve asetabulum gibi karmaşık yapıya sahip kemiklerin kırıklarının değerlendirilmesinde, BT önemli bir dönüm noktası olmuş ve klasik görüntüleme yöntemlerine göre belirgin avantajlar sağlamıştır. BT sayesinde; medial deplasman, marjinal impaksiyon, eklem içi serbest kemik parçaları, posterior instabilite, femur başı ile ilişkili yaralanmalar ve kırıkların detaylı sınıflandırılması daha doğru şekilde değerlendirilebilmektedir. Ayrıca, direkt grafi ile karşılaştırıldığında, diğer pelvik kırıkların tespitinde de BT'nin üstünlüğü çeşitli çalışmalarla ortaya konmuştur (64).

2.5.3.3.3. Manyetik Rezonans Görüntüleme

Kalça travmalarının değerlendirilmesinde, direkt grafiler ve BT en sık başvurulmuş tanı yöntemleridir. Ancak her iki yöntemin birlikte kullanıldığı durumlarda bile, bazı kalça kırıkları (%3–5 oranında) bu görüntüleme teknikleriyle gözden kaçabilmektedir (65). Klinik olarak güçlü travma bulguları taşıyan, ancak konvansiyonel radyografi ve BT ile kırık saptanamayan hastalar, MRG açısından değerlendirilmesi gereken uygun adaylar arasında yer alır (66,67). Ayrıca, kas ve yumuşak doku hasarları, labrum yırtıkları, osteokondral lezyonlar, eklem içi serbest cisimler ve ligamentum teres yaralanmaları gibi kırık dışı patolojilerin saptanabilmesi, MRG kalça travmalarında önemli ve tamamlayıcı bir tanı aracı haline getirmektedir (68).

2.6. YAPAY ZEKA


2.6.1. Yapay Zeka Tarihçe

Yapay zeka kavramı ilk olarak 1950’li yıllarda Alan Turing ve John McCarthy tarafından ortaya atılmış ve insan benzeri zekaya sahip makinelerin geliştirilmesi fikri tartışılmaya başlanmıştır. Ancak, o dönemdeki teknolojik sınırlamalar nedeniyle geliştirilen erken dönem modeller yeterince ilgi görmemiştir. İlk yaklaşımlar, karar verebilen ve insana benzer çıkarımlarda bulunabilen sistemlerin oluşturulmasına odaklanmıştır. 1960–1970’li yıllar arasında YZ uygulamaları ivme kazanmış; öncelikle komutları izleyebilen endüstriyel robot kollar geliştirilmiş, ardından insan konuşmasını taklit edebilen robot sistemleri ortaya çıkmıştır. Bu dönemde geliştirilen ve verilen talimatları algılayıp harekete geçebilen ilk mobil robot olan Shakey, YZ ve robotik alanında dönüm noktası olarak kabul edilmiştir. 1970 yılına gelindiğinde, glokom hastalığına yönelik olarak geliştirilen Causal Associational Network (CASNET) adlı bilgi tabanlı sistem, hekime hastalık yönetimi konusunda karar desteği sağlayabilen ilk örneklerden biri olmuştur. 1980’lerde, ayırıcı tanı koymaya yardımcı olan bilgisayar programları ve elektronik eğitim materyalleri geliştirilmeye başlanmış ve YZ uygulamaları sağlık alanında daha fazla ilgi görmeye başlamıştır. 2000’li yıllardan itibaren ise, MÖ ve DÖ gibi alt disiplinlerin ilerlemesiyle birlikte, yapay zekanın tıptaki kullanım alanları hızla genişlemiştir (69).

Günümüzde YZ, sağlık alanında çok çeşitli süreçlerde aktif olarak kullanılmaktadır. YZ, hastalıkların tanı ve teşhisinde, radyolojik görüntülerin ve biyopsi verilerinin yorumlanmasında, tedavi planlarının oluşturulmasında, ilaç dozlarının ve sürelerinin hesaplanmasında, hastalık seyrinin öngörülmesinde ve özellikle kanser gibi kompleks hastalıkların erken tanısında önemli katkılar sağlamaktadır. Bunun yanı sıra, robotik cerrahi uygulamaları YZ desteğiyle daha hassas, kontrollü ve minimal invaziv bir şekilde gerçekleştirilebilmektedir. Günümüzde radyoloji, cerrahi ve sağlık yönetimi gibi birçok tıbbi disiplinde YZ temelli sistemler başarıyla uygulanmakta olup, bu alandaki araştırmalar hız kesmeden devam etmektedir (70).

2.6.2. Yapay Zeka ve Tanımı

YZ, bilimsel literatürde; bir bilgisayarın ya da bilgisayar destekli bir sistemin, insana özgü bilişsel yetileri taklit ederek görevleri yerine getirme kapasitesi olarak tanımlanmaktadır. Bu yetiler arasında; anlama, anlam çıkarma, problem çözme, genelleme yapma ve önceki deneyimlerden öğrenerek yeni durumlara uyum sağlama gibi ileri düzey zihinsel süreçler yer almaktadır (71). Slage, YZ'yi, sezgilere dayalı programlama anlayışını temel alan bir yaklaşım olarak değerlendirmiştir (72). Popov, YZ'yi, insanların gerçekleştirdiği bilişsel ve davranışsal faaliyetlerin bilgisayar sistemleri aracılığıyla taklit edilmesini amaçlayan bir çalışma alanı olarak tanımlamıştır (73). Genesereth ve Nilsson, YZ'yi akıllı davranışları inceleyen ve bu davranışları yapay sistemler aracılığıyla yeniden üretmeyi hedefleyen bir araştırma alanı olarak tanımlamışlardır. Bu yaklaşımın temel amacı, doğada gözlemlenen zeki davranışların kuramsal temellerini oluşturmak ve bunları yapay ortamlarda modellemektir (74). Yapay zeka, son yıllarda tıp alanında giderek artan bir kullanım alanı bulmuştur. Özellikle teknolojik gelişmelerle yakından ilişkili olan radyoloji, bu dönüşümden en çok etkilenen branşlardan biri olmuştur. YZ destekli uygulamalar, tanı süreci başta olmak üzere birçok aşamada klinik karar destek sistemi olarak rol almaya başlamıştır. Çeşitli görüntüleme tekniklerinde, hem hız hem de doğruluk açısından önemli katkılar sunan YZ tabanlı sistemler, günümüzde radyolojik pratiğin ayrılmaz bir parçası hâline gelmektedir (75). YZ birbiri ile ilişkili olarak temelde 2 ana alt kümeye ayrılmaktadır; makine öğrenmesi ve derin öğrenme (Şekil 3).



Şekil 3. Yapay zeka alt kümeleri

2.6.2.1. Makine Öğrenmesi

Makine öğrenmesi, bilgisayar sistemlerinin önceden tanımlı kurallar olmaksızın, veri ve deneyimler aracılığıyla örüntüleri öğrenmesini ve bu öğrenme sonucunda belirli görevleri yerine getirebilmesini sağlayan bir YZ alt alanıdır. Bu disiplin, matematiksel modeller ve istatistiksel yöntemler yardımıyla sistemlerin veri içerisindeki anlamlı ilişkileri tanımasını ve elde edilen bilgileri geleceğe yönelik tahminlerde bulunmak veya karar vermek amacıyla kullanmasını amaçlar (76).

Makine öğrenme yöntemleri genel olarak üç ana kategoriye ayrılır: denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme.

2.6.2.1.1. Denetimli Makine Öğrenmesi

Bu öğrenme yaklaşımında, algoritmalar doğru çıktılarla eşleştirilmiş veri örnekleri üzerinden eğitilir. Model, bu etiketli veriler aracılığıyla girdiler ile çıktılar arasındaki ilişkiyi öğrenmeyi hedefler. Eğitim süreci tamamlandığında, sistem yeni ve daha önce etiketlenmemiş verilerle karşılaştığında da doğru tahminlerde bulunabilecek yetkinliğe ulaşır. Sınıflandırma ve regresyon problemleri bu yöntemin en yaygın kullanım alanları arasında yer alır. Bu yöntem, makine öğrenmesinde günümüzde en fazla tercih edilen tekniklerden biri olarak öne çıkmaktadır (77,78).

2.6.2.1.2 Denetimsiz Makine Öğrenmesi

Bu öğrenme türünde, algoritmalar önceden sınıflandırılmamış (etiketsiz) verilerle çalışır ve veriler arasında kendiliğinden oluşan benzerlikleri veya yapısal örüntüleri ortaya çıkarmayı amaçlar. Yani sistem, dışarıdan yönlendirme olmaksızın verilerdeki doğal gruplamaları veya ilişkileri keşfetmeye çalışır. Bu yaklaşıma en sık örnek olarak kümeleme (clustering) ve boyutsal indirgeme (dimensionality reduction) yöntemleri verilebilir (79).


2.6.2.1.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, makine öğrenmesinin bir alt dalı olup, bir ajanın çevresiyle etkileşim kurarak deneyim yoluyla öğrenmesini esas alır. Bu öğrenme yaklaşımında ajan, çevrede gerçekleştirdiği her eylemin ardından bir ödül alır ve temel amacı, zaman içinde beklenen toplam ödülü en üst düzeye çıkaracak eylem dizisini


öğrenmektir. Ajan, çevresel geri bildirimleri gözlemleyerek hangi eylemlerin hedefe ulaşmada daha etkili olduğunu deneyim yoluyla keşfeder. Böylece pekiştirmeli öğrenme, deneme-yanılma yoluyla karar alma süreçlerini optimize eden ve hedef odaklı davranış geliştiren bir yapı sunar (80–82).

2.6.2.2. Derin Öğrenme

Derin öğrenme , karmaşık problemlerin çözümünü mümkün kılan ve makine öğrenmesinin bir alt dalı olarak kabul edilen bir yaklaşımdır. Bu yöntemde, insan beynindeki nöron yapısını taklit eden çok katmanlı yapay sinir ağları kullanılır. Yapay sinir ağları, birbirine bağlı çok sayıda yapay nörondan oluşur; her nöron aldığı veriyi işler ve bu bilgiyi bir sonraki katmana aktarır. Bu aktarım süreci, ağ içerisindeki bağlantı ağırlıkları ve “bias” adı verilen ayarlama katsayılarının otomatik olarak güncellenmesi sayesinde gerçekleşir. DÖ algoritmalarının temel hedefi, belirlenen görevler için en doğru sonuçları üretmektir. Öğrenme süreci boyunca, yapay sinir ağındaki bağlantılar güçlendirilebilir, zayıflatılabilir veya yeniden yapılandırılabilir. Bu sayede ağ, verinin içindeki karmaşık desenleri daha iyi öğrenerek, daha doğru ve güvenilir çıktılar ortaya koyabilir (83). Yapay sinir ağının şematik ve matematiksel gösterimi şekil 4 ve 5’te gösterilmiştir.




Şekil 4. Yapay nöronun matematiksel modeli (84)



Şekil 5. Yapay sinir ağı (80)

Derin öğrenme, tıbbi görüntüleme alanında çeşitli görevleri üstlenmekte olup; başlıca kullanım alanları arasında görüntülerin ön işlenmesi ve çözünürlüğünün artırılması, görüntü sınıflandırması, lezyon lokalizasyonu, segmentasyon işlemleri ve lezyonların zaman içindeki takibi yer almaktadır (85).

Tıbbi görüntü analizinde, derin öğrenme sistemlerinin en yaygın olarak başvurduğu yöntemlerden biri evrişimli sinir ağıdır (Convolutional Neural Network – CNN). Bu yapılar, genellikle üç ana bileşenden oluşur: evrişim katmanları, veriden özellik çıkarımı yapan; havuzlama (pooling) katmanları, boyutları azaltarak öne çıkan bilgileri koruyan; ve tam bağlantılı katmanlar (fully connected layers), sınıflandırma veya regresyon gibi son aşama görevleri yerine getiren bölümlerdir (Şekil 6) (86).



Şekil 6. CNN Tasviri (87)

2.6.3. YOLO (You Only Look Once)

YOLO , bir görüntüde yer alan nesneleri eş zamanlı olarak tespit edip tanımlayabilen bir derin öğrenme mimarisidir ve gerçek zamanlı nesne algılama görevlerinde etkin şekilde kullanılmaktadır (88). YOLO algoritması, nesne tespitini bir regresyon problemi olarak ele alır ve yalnızca nesnelerin konumlarını değil, aynı zamanda bu nesnelere ait sınıf olasılıklarını da tahmin eder. Bu model CNN'yi kullanarak görüntüdeki nesneleri tanımlar ve her bir nesne için yalnızca tek bir ileri yayılım (forward pass) gerçekleştirilmesi yeterlidir. Bu özellik sayesinde, tüm görüntü tek adımda analiz edilerek hızlı ve etkin bir biçimde nesne algılama işlemi gerçekleştirilmiş olur (89). Tıbbi görüntüleme analizlerinde, özellikle kırıklar, tümörler ve benzeri patolojik durumların tespiti ve sınıflandırılması gibi anormalliklerin belirlenmesinde derin öğrenme yöntemleri yaygın olarak kullanılmaktadır (90). Derin öğrenme tabanlı sistemler, tıbbi alanlar dışında da çeşitli sektörlerde yaygın biçimde kullanılmaktadır. Örneğin; otonom araç teknolojilerinde MOBESE gibi sistemlerle yaya, araç veya plaka tanımlama, tarımda bitki hastalıklarının erken teşhisi, güvenlik ve izleme sistemlerinde yüz tanıma ve potansiyel tehdit algılama, insansız hava araçlarında arazi haritalama ve arama-kurtarma operasyonları ile endüstriyel üretim hatlarında ürün kusurlarının tespiti, bu uygulamalara örnek olarak gösterilebilir (91–95).

3. GEREÇ VE YÖNTEM

Bu çalışma Afyonkarahisar Sağlık Bilimleri Üniversitesi Klinik Araştırmalar Etik Kurulu 02.08.2024 tarih 2024/262 sayılı onayı alınarak yapılmaya başlanmıştır. Çalışmaya Afyonkarahisar Sağlık Bilimleri Üniversitesi Tıp Fakültesi Yetişkin Acil Servisine 15.08.2024-15.08.2025 tarihleri arasında travma kaynaklı röntgen çekilen pelvis ve femur kırığı veya şüphesi olan hastalar dahil edildi. Herhangi bir uygunsuz pozisyon, gölgelenme ve giysilerdeki alçı, atel ve metal nesneler (protez plak gibi) görüntü kalitesi düşen direkt grafi görüntüleri ile 18 yaş altındaki hastalar çalışma dışı bırakıldı.

3.1. DİREK GRAFİ ÇEKİM PROTOKOLÜ

Afyonkarahisar Sağlık Bilimleri Üniversitesi Acil servisinde bulunan Toshiba Rotanode (model: LTN-50) direkt grafi cihazı ile acile başvuran travma hastalarının AP olarak çekilmiş pelvis ve femur görüntüleri toplanmıştır.

3.2. GÖRÜNTÜ ÖN İŞLEME

Çalışmaya dahil edilen tüm hastaların görüntüleri değerlendirilerek iki adet tanı grubu oluşturuldu. Tanı kriterlerinde altın standart olarak uzman radyolog ve acil tıp uzmanının ortak kararı ile elde edilen nihai sonuçlar kabul edildi. DICOM formatında oluşturulmuş direkt grafi görüntüleri, hastanemizdeki resim arşivleme ve iletişim sistemlerinden (PACS) JPEG formatında dışa aktarıldı. Radyolog tarafından röntgen üzerinde, yalnızca fraktürü veya normal kemik dokusunun tamamını kapsayacak şekilde ilgi alanı (ROI - Region of Interest) bölgeleri manuel olarak belirlendi ve bu bölgeler uygun etiketlerle işaretlendi. Çalışmanın görüntü işleme sürecinde, 512×512 piksel boyutlarındaki ham görüntüler, belirli odak dilimleri kullanılarak 640×640 piksel boyutunda standartlaştırılmış görüntülere dönüştürüldü. Bu işlemler sonucunda, nesne algılama eğitimi için kullanılacak nihai görüntüler oluşturuldu.


3.3. ÇALIŞMA TASARIMI

Bu çalışmada retrospektif olarak temin edilen dijital pelvis grafileri kullanılmıştır. Toplamda 2000 adet femur AP radyografisi, 1000 tanesi femur kırığı içeren ve 1000 tanesi normal (kırık içermeyen) olarak iki ana sınıfa ayrılmıştır.

Görüntüler, kırık olup olmadığını ayırt edebilecek şekilde YZ modeline öğretilmiştir. İlk aşamada derin öğrenme temelli model, “kırık var (FRAKTÜR)” ve “kırık yok” (NORMAL)” şeklinde ikili sınıflandırma için eğitilmiştir. Bu temel sınıflandırmanın ardından ikinci aşamada kırık tespit edilen olgular, anatomik lokalizasyona göre dört alt gruba ayrılmıştır: intertrokanterik kırık, subtrokanterik kırık, femur boyun kırığı ve femur shaft kırığı. Böylece modelin sadece kırığı tanıması değil aynı zamanda anatomik sınıflamasını da yapması sağlanmıştır. YZ modeli, bu çok sınıflı ayrımı öğrenebilmesi için uygun şekilde etiketlenmiş veri seti ile eğitilmiş; eğitim, doğrulama ve test kümelerine bölünerek performansı değerlendirilmiştir.

3.4. DERİN ÖĞRENME

Bu tez çalışmasında, direkt grafi görüntüleri üzerinde analizler gerçekleştirilmiştir. Bu doğrultuda, çalışma planı şekil 7’de sunulmaktadır. Çalışmamızda, ilk aşamada modelin eğitimi için “kırık var (FRAKTÜR)” ve “kırık yok(NORMAL)” olmak üzere iki farklı gruba ait görüntüler kullanılmıştır. İkinci aşama içinse modelin eğitimi için intertrokanterik kırık, subtrokanterik kırık, femur boyun kırığı ve femur shaft kırığı olmak üzere dört farklı patolojiye ait görüntüler kullanılmıştır. Görseller, roboflow ortamına yüklenerek, tespit edilmek istenen bölgeler sınırlayıcı kutulara (bounding box) ayrılmış ve sınıflandırma için uygun etiketleme yapılmıştır. Çalışmada, ilk aşamada toplam 2000 hastaya ait, ikinci aşamada 1000 görüntülerden oluşan veri setinin %70’i eğitim, %10 doğrulama ve %20 test için ayrılmıştır. Bu çalışmada derin öğrenme modeli olarak bir nesne algılama algoritması olan YOLOv11 mimarisi kullanılmıştır.



Şekil 7. Derin Öğrenme Modelinin Hazırlanış Şeması


YOLOv11 modelinin hızlı eğitimi için NVIDIA A100 grafik işlemci birimi (GPU) kullanılmış ve CUDA işlevselliği etkinleştirilmiştir. Kullanılan CUDA sürümü 12.4 olup, tüm işlemler GPU üzerinde gerçekleştirilerek eğitim süresi önemli ölçüde kısaltılmıştır. Eğitim işleminde ultralytics 8.3, pytorch 2.6 ve opencv kütüphaneleri kullanılmıştır. Modelin eğitim parametreleri Tablo 1 'de sunulmaktadır.

Eğitim parametrelerinde, 300 epoch ve erken durma (EarlyStopping) aşırı öğrenmeyi önleyerek yeterli eğitim süresi sağlarken, batch boyutunun 16 olması modelin öğrenme sürecini hızlandırmaktadır. İmgz boyutu 640, modelin küçük nesneleri algılayabilmesi için idealdir. Adam optimizier, dinamik ağırlık güncellemeleri ile eğitim sürecini hızlandırırken, momentum 0.937 öğrenme hızını optimize eder. Box 7.5 ve cls 0.5 değerleri, konumlandırma ve sınıflandırma performansını dengelemek amacıyla seçilmiştir.

Tablo 1. YOLOv11 eğitim parametleri

Parametreler	cls	optimizatör	box	momentum	Imgsz	Batch	Epoch
Değerleri		Adam		0,937	640	16	300

Optimizasyon işlemi tamamlandıktan sonra YOLOv11 modelinin sınırlayıcı kutular ile tespit etme ve sınıflandırma başarısı örneği görüntü üzerinden şekil 8'de sunulmuştur.



Şekil 8. YOLOv11'in sınırlandırıcı kutular ile tespit ve sınıflandırma örneği

Elde edilen performans metriklerine ait formülasyon ve açıklamaları aşağıda verilmiştir (96).

$$\text{Doğruluk: } (TP + TN) / (TP + TN + FN + FP)$$


$$\text{Kesinlik (Precision): } TP / (TP + FP)$$

$$\text{Geri çağırma (Recall): } TP / (TP + FN)$$

F1 skoru: Kesinlik ve geri çağırma metriklerinin harmonik ortalamasıdır. Bu metrik, modelin hem kesinlik hem de duyarlılığını dengeler ve genellikle veri setlerinde dengesizliklerin bulunduğu durumlarda daha kapsamlı bir değerlendirme sağlar Formulasyonu; $2 \times \text{kesinlik} \times \text{geri çağırma} / \text{kesinlik} + \text{geri çağırma}$

Mean Average Precision (mAP): Bu metrik, sınırlayıcı kutu (bounding box) ve segmentasyon tespiti bağlamında, Intersection over Union (IoU) eşik değerinin %50 olduğu durumda hesaplanan Ortalama Kesinlik (Average Precision, AP) değerinin ortalamasını ifade eder. Modelin tahmin ettiği sınırlayıcı kutuların gerçek kutularla %50 veya daha fazla örtüşme oranına sahip olduğu durumlarda ortalama kesinliği ölçer. (TP: Gerçek pozitif, FP: Yalancı pozitif, TN: gerçek negatif, FN: yalancı negatif)

Elde edilen sonuçlara ait karışıklık matrislerinin formülasyonu şekil 9 da verilmiştir.




Şekil 9. Karışıklık matrisinin şematik gösterimi

Çalışmamıza dahil edilen hastaların radyolojik tanı dağılımları tablo 2’te verilmiştir.


Tablo 2. Hastaların radyolojik tanı dağılımları

Radyolojik Tanı	
Fraktür	1000
Normal	1000
İntertrokanterik kırık	250
Subtrokanterik kırık	250
Boyun kırığı	250
Şaft kırığı	250

İlk gruba ait tüm veri setlerindeki toplam 2000 görüntünün %80'i eğitim ve %20'si doğrulama için ayrılmıştır. İkinci gruba ait tüm veri setlerindeki toplam 1000 görüntünün %80'i eğitim ve %20'si doğrulama için ayrılmıştır. Test seti için 200 hastaya ait ham görüntü kullanılmıştır. YOLOv11'e ait eğitim-doğrulama işlemlerine ait metriklerin detaylı analizi ve kayıp değerleri şekil 10 've 11 de verilmiştir.



Şekil 10. İlk Grup verileri için YOLOv11 modelinin eğitim-doğrulama metrikleri ve kayıp değerleri analizi



Şekil 11. İkinci grup verileri için YOLOv11 modelinin eğitim-doğrulama metrikleri ve kayıp değerleri analizi

Test setinden elde edilen sonuçlara göre, tanımlanan lezyon gruplarının performans ölçütleri şu şekildedir (Tablo 3) :

İlk Grup;

mAP 50 (Box) değeri: 0,87

Kesinlik (Precision, Box) değeri: 0,90

Geri çağırma (Recall, Box) değeri: 0,86

F1 Skoru: 0,87

İkinci Grup;

mAP 50 (Box) değeri: 0,75

Kesinlik (Precision, Box) değeri: 0,94


Geri çağırma (Recall, Box) değeri: 0,86

F1 Skoru: 0,72


Tablo 3. YOLOv11 modelinin veri setlerindeki test performansı

Veri Seti	mAP 50 (Box)	Kesinlik (Precision, Box)	Geri çağırma (Recall, Box)	F1 Skoru
İlk Grup	0,87	0,90	0,86	0,87
İkinci Grup	0,75	0,94	0,86	0,72

Model veri setlerinde oluşturulan sınırlayıcı kutulara ve gerçekleştirilen sınıflandırmaya ait Kesinlik-Güven eğrisi, F1 skoru-Güven eğrisi, Kesinlik-Duyarlılık eğrisi ve Duyarlılık-Güven eğrisi grafikleri ilk grup veri seti için şekil 12’de, ikinci grup veri seti için şekil 13’de verilmiştir.




Şekil 12. İlk grup veri setine göre sınırlayıcı kutu (bounding box) ve yapılan sınıflandırma grafikleri




Şekil 13. İkinci grup veri setine göre sınırlayıcı kutu (bounding box) ve yapılan sınıflandırma grafikleri

Sınıflandırmanın yapıldığı veri setlerine ait görüntülerin karışıklık matrisleri (Confusion matrix) ilk grup veri seti için şekil 14'te, ikinci grup veri seti için şekil 15'te verilmiştir.



Şekil 14. YOLOv11 modelinin ilk grup veri seti için karışıklık matrisi



Şekil 15. YOLOv11 modelinin ikinci grup veri seti için karışıklık matrisi

3.5. İSTATİKSEL ANALİZ

Çalışma verilerin istatistiksel analizi SPSS 27.0 paket programı (SPSS, Chicago, Illinois) ile yapıldı. Çalışmada asistan hekim ve/veya yapay zekâ tarafından yapılan sınıflandırmaların, altın standart olarak kabul edilen uzman değerlendirmeleriyle olan uyum düzeyi Cohen's Kappa (κ) katsayısı ile analiz edildi. Elde edilen değerler Landis ve Koch (1977) tarafından önerilen sınıflamaya (0: Uyum yok, 0.01 – 0.20: Çok zayıf uyum, 0.21 – 0.40: Zayıf uyum, 0.41 – 0.60: Orta düzeyde uyum, 0.61 – 0.80: İyi uyum, 0.81 – 1.00: Mükemmel uyum) göre yorumlandı. Kappa katsayısının yanı sıra %95 güven aralıkları da hesaplanarak, anlamlılık düzeyi $p < 0,05$ olarak kabul edildi (97). Elde edilen performans metrikleri (duyarlılık, özgüllük, pozitif prediktif değer, negatif prediktif değer) YOLOv11'in sınırlandırıcı kutular ile tespit edildi. Kategorik değişkenler frekans ve yüzdelikler halinde sunuldu.

4. BULGULAR

Afyonkarahisar Sağlık Bilimleri Üniversitesi Tıp Fakültesi Acil Servisine 15.08.2024-15.08.2025 tarihleri arasında travma kaynaklı direkt grafi çekilen pelvis ve femur kırığı veya şüphesi olan hastalar incelenmiştir.

Bu çalışmada toplam 400 hastaya ait femur direkt grafi görüntüsü değerlendirmeye alınmıştır. Çalışmaya dahil edilen hastaların yaş ortalaması 60,85($\pm$ 1,1) olarak tespit edilmiştir. Hastaların 182'si (%45,5) kadın, 218'i (%54,5) erkekti.

Çalışmaya dahil edilen hastalardan 200 (%50) femur kırığı saptanmış görüntü test kıyaslaması için uzman hekim (altın standart) tarafından seçildi. Femur kırığı mevcut olan olguların yaş ortalaması 63,58($\pm$ 1,6) yıl olup, genel yaş ortalamasına kıyasla daha yüksek bulunmuştur.

Kırık tespit edilen 200 olgunun 89'u (%45,5) kadın, 111'i (%55,5) erkek idi. Cinsiyet dağılımı kırıklı hastalarda da genel dağılımla benzer şekilde seyretmiştir. Cinsiyet ile kırık tipi arasındaki ilişki incelendiğinde, kadınlarda en sık görülen kırık tipi %32,6 ile boyun kırığı iken; bunu %24,7 ile intertrokanterik, %23,6 ile subtrokanterik ve %19,1 ile shaft kırığı izlemekteydi. Erkek bireylerde ise en sık gözlenen kırık tipi %29,7 ile shaft kırığı olurken, diğer kırık tipleri sırasıyla subtrokanterik (%26,1), intertrokanterik (%24,3) ve boyun (%27) kırığı olarak tespit edilmiştir. Cinsiyete göre kırık tipi dağılımları Tablo 4'de sunulmuştur.

Tablo 4. Cinsiyete göre kırık tipleri dağılımı

	Femur Kırık Tipi				
	Şaft	Boyun	İntertorakanterik	Subtorakanterik	Toplam
Cinsiyet					
Kadın	17 (%19,1)	29 (%32,6)	22 (%24,7)	21 (%23,6)	89 (%100)
Erkek	33 (%29,7)	21 (%18,9)	28 (%25,2)	29 (%26,1)	111 (%100)
Toplam	50 (%25)	50 (%25)	50 (%25)	50 (%25)	200 (%100)

Altın standardın kırık var/yok değerlendirmesi ile acil tıp asistanı (ATA)'nın değerlendirmesi arasındaki tanısal uyum SPSS üzerinden yapılan çapraz tablo analizi, Cohen's Kappa testi ile analiz edilmiştir. Elde edilen Kappa katsayısı 1.000 olup, istatistiksel olarak anlamlı bulunmuştur ($p<0,001$). Buna göre; ATA'nın duyarlılığı (sensitivite) %100, özgüllüğü (spesifite) %100, pozitif prediktif değeri (PPV) %100 ve negatif prediktif değeri (NPV) %100 olarak hesaplanmıştır. Bu bulgular, ATA'nın femur kırığı tanısı koyma açısından altın standartla tam bir uyum içerisinde olduğunu ve yüksek tanısal doğruluk gösterdiğini ortaya koymaktadır (Tablo 5).

Tablo 5. Altın standart ve acil tıp asistanı kırık tespiti kıyaslaması

	Acil Tıp Asistanı		Toplam
	Yok	Var	
Altın Standart			
Yok	200 (%100)	0 (%0)	200 (%100)
Var	0 (%0)	200 (%100)	200 (%100)
Toplam	200 (%50)	200 (%50)	400 (%100)

Yapay zeka ile altın standart femur kırığı tespiti açısından tanı uyumları SPSS üzerinden yapılan çapraz tablo analizi , Cohen's Kappa testi ile değerlendirildi. Analiz sonucunda elde edilen Kappa katsayısı 0.980 olup, istatistiksel olarak anlamlı bulundu ($p <0,001$). Bu sonuç, YZ ile altına standart arasında kırık var/yok kararları açısından çok yüksek düzeyde bir uyum olduğunu göstermektedir. Özellikle kırık var olan tüm vakaların doğru şekilde tespit edildiği görülmüştür.

Yapay zekanın femur kırığı tespitine yönelik tanı performansı incelendiğinde, kırık varlığına ilişkin tüm pozitif olguların doğru şekilde tanımlandığı gözlenmiştir. Buna göre, YZ modeli çalışmada kullanılan 200 kırıklı vakanın tamamını doğru şekilde saptamış ve %100 duyarlılık (sensitivite) göstermiştir. Öte yandan, 200 kırık olmayan vakanın 196'sını doğru şekilde 'kırık yok' olarak sınıflandırmış; ancak 4 vakada yanlış pozitif sonuç vermiştir (Tablo 6). Bu bulgu, YZ'nin yaklaşık %98 özgüllük (spesifisite) oranına sahip olduğunu göstermektedir.

Tablo 6. Altın standart ve yapay zekanın kırık tespiti kıyaslaması

Yapay Zekâ			
	Yok	Var	Toplam
Altın Standart			
Yok	196 (%98)	4 (%2)	200 (%100)
Var	0 (%0)	200 (%100)	200 (%100)
Toplam	196 (%49)	204 (%51)	400 (%100)

Acil tıp asistanı ile YZ'nin femur kırığı var/yok tanısı açısından uyum düzeyi SPSS üzerinden yapılan çapraz tablo analizi , Cohen's Kappa analizi ile değerlendirildi. Elde edilen Kappa katsayısı 0.980 olup, bu değer istatistiksel olarak anlamlı bulundu ($p < 0,001$). Bulgular, her iki değerlendiricinin femur kırığı tespiti konusunda oldukça yüksek düzeyde bir uyum gösterdiğini ortaya koymaktadır. Özellikle ATA'nın kırık var dediği tüm vakalarda YZ'nin de aynı tanıyı koymuş olması, sistemin duyarlılık açısından güvenilir bir performans gösterdiğine işaret etmektedir. YZ'nin femur kırığı tespitine yönelik tanı performansı ATA'ya göre incelendiğinde, ATA'nın kırık dediği tüm pozitif olguları doğru şekilde tanımlandığı gözlenmiştir. Buna göre, YZ modeli çalışmada kullanılan 200 kırıklı vakanın tamamını doğru şekilde saptamış ve %100 duyarlılık (sensitivite) göstermiştir. ATA'nın 200 tane kırık yok dediği vakanın 196'sını doğru şekilde 'kırık yok' olarak sınıflandırmış; ancak 4 vakada yanlış pozitif sonuç vermiştir (Tablo 7). Bu bulgu, YZ'nin, ATA'ya göre yaklaşık %98 özgüllük (spesifisite) oranına sahip olduğunu göstermektedir.

Tablo 7. Acil tıp asistanı ve yapay zekanın kırık tespiti kıyaslaması

Yapay Zekâ			
	Yok	Var	Toplam
Acil Tıp Asistanı			
Yok	196 (%98)	4 (%2)	200 (%100)
Var	0 (%0)	200 (%100)	200 (%100)
Toplam	196 (%49)	204 (%51)	400 (%100)

Çalışmada, ATA'nın tespit ettiği femur kırığı tipi sınıflandırmasının, altın standart sınıflandırmasıyla olan uyumu değerlendirilmiştir. Altın standardın 50 şaft kırığı olarak tanımladığı olguların %98'inin ATA tarafından da doğru bir şekilde şaft kırığı olarak sınıflandırıldığı; yalnızca %2 oranında subtrokanterik kırık olarak yanlış değerlendirildiği görülmüştür. Boyun kırığı olarak sınıflandırılan 50 olgunun %96'sı ATA tarafından doğru tanınmış, %4'ü ise intertrokanterik kırık olarak değerlendirilmiştir. İntertrokanterik kırık tanısı alan 50 olgunun %94'ü ATA tarafından doğru sınıflandırılmış, %4'ü boyun, %2'si subtrokanterik kırık olarak kodlanmıştır. Subtrokanterik kırıklar içinde ise %90'lık yüksek doğruluk oranı elde edilirken, %10 oranında intertrokanterik kırık olarak yanlış sınıflandırma yapılmıştır (Tablo 8).

Sadece kırık saptanan 200 olgu üzerinden yapılan sınıflandırma uyumuna ilişkin istatistiksel analizde SPSS üzerinden yapılan çapraz tablo Cohen's Kappa testi ile değerlendirildi. Kohen's Kappa katsayısı 0,927 olarak bulunmuş olup bu değer mükemmele yakın düzeyde bir uyumu göstermektedir ($p<0,001$). Bu bulgu, ATA'nın femur kırığı tiplerini sınıflandırma becerisinin, altın standart ile yüksek düzeyde örtüştüğünü ortaya koymaktadır.

Femur şaft kırıkları açısından uzman hekimin tanıları altın standart olarak kabul edilerek, ATA'nın bu kırık tipini tespit etme performansı değerlendirilmiştir.

Uzman hekime göre 50 olgu şaft kırığı olarak sınıflandırılmıştır. ATA bu olguların 49'unu doğru şekilde şaft kırığı olarak tanımlamış, 1 olguyu ise subtrokanterik olarak hatalı biçimde sınıflamıştır. Bununla birlikte, altın standarda göre şaft kırığı olmayan 150 olgunun 150'si doğru biçimde şaft dışı olarak sınıflandırılmış ve hatalı olarak şaft kırığı olarak tanımlanan olgu bulunmamıştır (Tablo 8).

Bu veriler ışığında hesaplanan performans ölçütleri şunlardır (Tablo 9):

- ✓ Duyarlılık (Sensitivite) = %98
- ✓ Özgüllük (Spesifite) = %100
- ✓ Pozitif Prediktif Değer (PPV) = %100
- ✓ Negatif Prediktif Değer (NPV) = %99

Femur boyun kırıkları açısından uzman hekimin tanıları altın standart olarak kabul edilerek, ATA'nın bu kırık tipini tespit etme performansı değerlendirilmiştir. Altın standarda göre 50 olgu boyun kırığı olarak sınıflandırılmıştır. ATA bu olguların 48'ini doğru şekilde boyun kırığı olarak tanımlamış 2 olguyu ise intertrokanterik olarak hatalı biçimde sınıflamıştır. Bununla birlikte, altın standarda göre boyun kırığı olmayan 150 olgunun 148'i doğru biçimde dışlamış, ancak intertrokanterik kırık olan 2 olguyu hatalı olarak boyun kırığı olarak tanımlanmıştır (Tablo 8).

Bu veriler ışığında hesaplanan performans ölçütleri şunlardır (Tablo 9):

- ✓ Duyarlılık (Sensitivite) = %96
- ✓ Özgüllük (Spesifite) = %98,7
- ✓ Pozitif Prediktif Değer (PPV) = %96
- ✓ Negatif Prediktif Değer (NPV) = %98,7

Femur intertrokanterik kırıkları açısından uzman hekimin tanıları altın standart olarak kabul edilerek, ATA'nın bu kırık tipini tespit etme performansı değerlendirilmiştir. Altın standarda göre 50 olgu intertrokanterik kırık olarak sınıflandırılmıştır. ATA bu olguların 47'sini doğru şekilde intertrokanterik kırık olarak tanımlamış, 2 olguyu subtrokanterik kırık, 1 olguyu ise boyun kırığı olarak hatalı biçimde sınıflamıştır. Bununla birlikte, altın standarda göre intertrokanterik kırığı olmayan 150 olgunun 143'ünü doğru biçimde intertrokanterik dışı olarak sınıflandırılmış, 5'i subtrokanterik, 2'si boyun kırığı olan toplam 7 olguyu hatalı şekilde intertrokanterik kırık olarak tanımlanmıştır (Tablo 8).

Bu veriler ışığında hesaplanan performans ölçütleri şunlardır (Tablo 9):

- ✓ Duyarlılık (Sensitivite) = %94
- ✓ Özgüllük (Spesifite) = %95,3
- ✓ Pozitif Prediktif Değer (PPV) = %87
- ✓ Negatif Prediktif Değer (NPV) = %98

Femur subtrokanterik kırıkları açısından uzman hekimin tanıları altın standart olarak kabul edilerek, ATA'nın bu kırık tipini tespit etme performansı değerlendirilmiştir. Altın standarda göre 50 olgu subtrokanterik kırık olarak sınıflandırılmıştır. ATA bu olguların 45'ini doğru şekilde subtrokanterik kırık olarak

tanımlanmış, 5 olguyu intertrokanterik kırık olarak hatalı biçimde sınıflamıştır. Bununla birlikte, altın standarda göre subtrokanterik kırığı olmayan 150 olgunun 148'i doğru biçimde subtrokanterik dışı olarak sınıflandırılmış, 1'si şaft kırığı, 1'si intertrokanterik kırık olan 2 olguyu ise hatalı şekilde subtrokanterik kırık olarak tanımlanmıştır (Tablo 8).

Bu veriler ışığında hesaplanan performans ölçütleri şunlardır (Tablo 9):

- ✓ Duyarlılık (Sensitivite) =%90
- ✓ Özgüllük (Spesifite) =%98,7
- ✓ Pozitif Prediktif Değer (PPV) =%95,7
- ✓ Negatif Prediktif Değer (NPV) =%96,7

Tablo 8. Altın standart ve acil tıp asistanının kırık sınıflaması tespitinin kıyaslaması

	Acil Tıp Asistanı				
	Şaft	Boyun	İntertorakanterik	Subtorakanterik	Toplam
Altın Standart					
Şaft	49 (%98)	0 (%)	0 (%)	1 (%2)	50 (%100)
Boyun	0 (%)	48(%96)	2(%4)	0 (%)	50 (%100)
İntertorakanterik	0 (%)	2 (%4)	47 (%94)	1 (%2)	50 (%100)
Subtorakanterik	0 (%)	0 (%)	5 (%10)	45 (%90)	50 (%100)
Toplam	49 (%24,5)	50(%25)	54(%27)	47 (%23,5)	200 (%100)

Tablo 9. Acil Tıp Asistanının Femur Kırık Tiplendirme Performansı

Kırık Tipi	Duyarlılık (%)	Özgüllük (%)	PPV (%)	NPV (%)
Şaft	98	100	100	99,3
Boyun	96	98,7	96	98,7
İntertorakanterik	94	95,3	87	98
Subtorakanterik	90	98,7	95,7	96,7

(PPV: Pozitif Prediktif Değer, NPV: Negatif Prediktif Değer)

Çalışmada, ATA'nın ve YZ modelinin femur kırığı tiplendirmesi konusundaki doğruluk oranları karşılaştırılmıştır. YZ modelinin ATA'ya göre sınıflandırma doğruluğu SPSS üzerinden yapılan çapraz tablo analizi, Cohen's Kappa testi ile değerlendirildi. Kohen's Kappa katsayısı 0,759 olup, istatistiksel olarak anlamlı bir uyum saptanmıştır ($p<0,001$). Ancak bu değer, ATA'nın performansına kıyasla daha düşük seviyede olduğu tespit edilmiştir.

Femur kırığı sınıflandırması incelendiğinde; ATA'nın altın standarta göre, şaft kırıklarında %98 doğruluk(49/50), boyun kırıklarında %96 doğruluk (48/50), intertrokanterik kırıklarda %94 doğruluk (47/50) ve subtrokanterik kırıklarda %90 doğruluk (45/50) sağladığı saptanmıştır. YZ modeli, ATA'nın sınıflandırdığı kırıklara göre şaft kırıklarında %100 doğruluk sağlarken (49/49), boyun kırıklarında %78 doğruluk (39/50), intertrokanterik kırıklarda %88,8 doğruluk (48/54) ve subtrokanterik kırıklarda %59,6 doğruluk (28/47) ile daha düşük başarı göstermiş olduğu tespit edilmiştir (Tablo 10).

Tablo 10. Yapay zekâ ve acil tıp asistanın kırık sınıflaması tespitinin kıyaslaması

	Yapay Zekâ				
	Şaft	Boyun	İntertorakanterik	Subtorakanterik	Toplam
Acil Tıp Asistanı					
Şaft	49 (%100)	0 (%0)	0 (%0)	0 (%0)	49 (%100)
Boyun	3 (%6)	38 (%76)	9 (%18)	0 (%0)	50 (%100)
İntertorakanterik	0 (%0)	2 (%3,7)	48 (%88,9)	4 (%7,4)	54 (%100)
Subtorakanterik	5 (%10,6)	0 (%0)	14 (%29,8)	28 (%59,6)	47 (%100)
Toplam	57 (%28,5)	40 (%20)	71 (%35,5)	32 (%16)	200 (%100)

Femur şaft kırıkları açısından ATA'nın tanıları altın standart olarak kabul edilerek, yapay zekânın bu kırık tipini tespit etme performansı incelenmiştir. ATA'ya göre 49 olgu şaft kırığı olarak tanımlanmış olup, yapay zekâ bu olguların tamamını doğru şekilde sınıflandırmıştır. Ancak, ATA tarafından şaft kırığı olmayan olarak işaretlenen 151 olgudan 143 olgu YZ tarafından doğru şekilde şaft kırığı olmayan olarak sınıflandırılmıştır. 8 olguyu hatalı işaretlemiştir ; 3'ü boyun kırığı , 5 i subtorakanterik kırık olan görüntüleri şaft kırığı olarak etiketlemiştir (Tablo 10).

Bu veriler ışığında hesaplanan performans ölçütleri şunlardır (Tablo 11):

- ✓ Duyarlılık (Sensitivite): %100
- ✓ Özgüllük (Spesifite): %94,7
- ✓ Pozitif Prediktif Değer (PPV): %86
- ✓ Negatif Prediktif Değer (NPV): %100

Femur boyun kırıkları açısından ATA'nın tanıları altın standart olarak kabul edilerek, yapay zekânın bu kırık tipini tespit etme performansı değerlendirilmiştir. ATA'ya göre 50 olgu boyun kırığı olarak sınıflandırılmıştır. Yapay zekâ bu olguların 38'ini doğru şekilde boyun kırığı olarak tanımlamış, 12 olgunun 3'ünü şaft kırığı, 9'unu intertrokanterik kırık tipi olarak hatalı biçimde sınıflamıştır. Bununla birlikte, ATA'ya göre boyun kırığı olmayan 150 olgunun 148'i doğru biçimde boyun dışı olarak sınıflandırılmış, intertrokanterik kırık olan 2 olguyu ise yanlış biçimde boyun kırığı olarak değerlendirilmiştir (Tablo 10).

Bu veriler ışığında hesaplanan performans ölçütleri şunlardır (Tablo 11):

- ✓ Duyarlılık (Sensitivite): %76
- ✓ Özgüllük (Spesifite): %98,7
- ✓ Pozitif Prediktif Değer (PPV): %95
- ✓ Negatif Prediktif Değer (NPV): %92,5

Çalışmada, ATA tarafından intertrokanterik kırık olarak tanımlanan 54 olgu üzerinden YZ sınıflandırma başarısı analiz edilmiştir. YZ bu 54 olgunun 48'ini doğru bir şekilde intertrokanterik kırık olarak tanımlamıştır , ancak 6 olgunun 2'sini boyun kırığı , 4 'ünü subtorakanterik kırık şeklinde sınıflandırarak hata yapmıştır. Bununla birlikte, ATA'ya göre intertorakanterik kırığı olmayan 146 olgunun 123' ünü doğru biçimde intertorakanterik dışı olarak sınıflandırılmış, 14 subtorakanterik kırığı ve 9 boyun kırığı olan toplam 23 olguyu intertrokanterik kırık olarak hatalı değerlendirmiştir. (Tablo 10).

Bu verilere dayanarak hesaplanan performans ölçütleri şu şekildedir (Tablo 11):


- ✓ Duyarlılık (Sensivite): %88,9
- ✓ Özgüllük (Spesifite): %84,25
- ✓ Pozitif Prediktif Değer (PPV): %67,61
- ✓ Negatif Prediktif Değer (NPV): %95,35

Femur subtrokanterik kırıkları açısından ATA'nın tanıları altın standart olarak kabul edilerek, YZ'nin bu kırık tipini tespit etme performansı değerlendirilmiştir. ATA'ya göre 47 olgu subtrokanterik kırık olarak sınıflandırılmıştır. YZ bu olguların 28'ini doğru şekilde subtrokanterik kırık olarak tanımlamış, 19 olgunun ise 5'i şaft kırığı, 14'ü intertrokanterik kırık olarak hatalı biçimde sınıflamıştır. Bununla birlikte, ATA'ya göre subtrokanterik kırığı olmayan 153 olgunun 149'ü doğru biçimde subtrokanterik dışı olarak sınıflandırılmış, intertrokanterik kırık olan 4 olguyu intertrokanterik kırık olarak hatalı değerlendirilmiştir (Tablo 10).

Bu veriler ışığında hesaplanan performans ölçütleri şunlardır (Tablo 11):

- ✓ Duyarlılık (Sensivite) = %59,6
- ✓ Özgüllük (Spesifite) = %97,39
- ✓ Pozitif Prediktif Değer (PPV) = %87,5
- ✓ Negatif Prediktif Değer (NPV) = %88,7

Ayrıca ATA'nın sınıflandırma aşamasında hatalı değerlendirdiği sekiz kırık olgusu, YZ tarafından doğru şekilde tanımlanmıştır. (Şekil 16)



Şekil 16. Altın Standardın İşaretlemesi(A) Acil Tıp Asistanının İşaretlemesi(B) Yapay Zekanın işaretlemesi(C)

Tablo 11. Yapay zekanın acil tıp asistanına kıyasla femur kırık tiplendirme performansı

Kırık Tipi	Duyarlılık (%)	Özgüllük (%)	PPV (%)	NPV (%)
Şaft	100	94,7	86	100
Boyun	76	98,7	95	92,5
İntertrokanterik	88,9	84,25	67,61	95,35
Subtrokanterik	59,6	97,39	87,5	88,7

PPV: Pozitif Prediktif Değer, NPV: Negatif Prediktif Değer

Bu çalışmada, YZ modelinin femur kırığı tiplerini sınıflandırma başarısı, altın standart olarak kabul edilen uzman hekimin değerlendirmesi ile karşılaştırılmıştır. Analize yalnızca kırık saptanan 200 olgu dahil edildi. SPSS üzerinden yapılan çapraz tablo analizinde, YZ'nin kırık tiplerini doğru sınıflandırma performansı, Kohen's Kappa katsayısı 0,787 olarak hesaplanmıştır. Bu değer, istatistiksel olarak anlamlı olup ($p < 0,001$), YZ ile altın standart arasında yüksek düzeyde bir uyum olduğu saptanmıştır.

Femur kırık sınıflaması düzeyinde değerlendirildiğinde, YZ modeli şaft kırıklarının tamamını doğru sınıflandırdığı tespit edilmiştir (50/50, %100). Ancak boyun kırıklarında doğruluk oranı %78 (39/50), intertrokanterik kırıklarda %96 (48/50) ve subtrokanterik kırıklarda %62 (31/50) olarak saptanmıştır (Tablo 12).

Femur şaft kırıkları açısından uzman hekimin tanıları altın standart olarak kabul edilerek, YZ'nin bu kırık tipini tespit etme performansı değerlendirilmiştir. Altın standarda göre 50 olgu şaft kırığı olarak sınıflandırılmıştır. YZ bu olguların tamamını doğru şekilde şaft kırığı olarak tanımlamıştır, bu da %100 duyarlılığa işaret etmektedir. Bununla birlikte, altın standarda göre şaft kırığı olmayan 150 olgunun 143'ü doğru biçimde şaft dışı olarak sınıflandırılmış, ancak 7 olguyu hatalı işaretlemiştir ; 3'ünü boyun kırığı, 4'ünü subtrokanterik kırığı olan görüntüleri şaft kırığı olarak etiketlemiştir. Yanlış negatif olgu bulunmamaktadır (Tablo 12).

Bu veriler ışığında, yapay zekânın şaft kırıkları için sınıflama performans ölçütleri şu şekildedir (Tablo 13):

- ✓ Duyarlılık (Sensitivite): %100
- ✓ Özgüllük (Spesifite): %95,3
- ✓ Pozitif Prediktif Değer (PPV): %87,7
- ✓ Negatif Prediktif Değer (NPV): %100

Femur boyun kırıkları açısından uzman hekimin tanıları altın standart olarak kabul edilerek, YZ'nin bu kırık tipini tespit etme performansı değerlendirilmiştir. Uzman hekime göre 50 olgu boyun kırığı olarak sınıflandırılmıştır. YZ bu olguların 39'unu doğru şekilde boyun kırığı olarak tanımlamıştır, ancak 11 olgunun 3'ünü şaft kırığı, 8'ini intertorakanterik kırık olarak hatalı biçimde sınıflandırılmıştır. Bununla birlikte, altın standarda göre boyun kırığı olmayan 150 olgunun 149'u doğru biçimde boyun kırığı olmayan olarak sınıflandırılmış, bir intertorkanterik kırık olgusu ise yanlış biçimde boyun kırığı olarak etiketlenmiştir (Tablo 12).

Bu veriler ışığında, yapay zekânın boyun kırıkları için sınıflama performans ölçütleri şu şekildedir (Tablo 13):

- ✓ Duyarlılık (Sensitivite): %78
- ✓ Özgüllük (Spesifite): %99,33
- ✓ Pozitif Prediktif Değer (PPV): %97,5
- ✓ Negatif Prediktif Değer (NPV): %93

Femur intertrokanterik kırıkları açısından uzman hekimin tanıları altın standart olarak kabul edilerek, YZ bu kırık tipini tespit etme performansı değerlendirilmiştir. Altın standarda göre 50 olgu intertrokanterik kırık olarak sınıflandırılmıştır. YZ bu olguların 48'ini doğru şekilde intertrokanterik kırık olarak tanımlamıştır, ancak 1 olgu boyun kırığı olarak 1 olguda subtorakanterik kırığı olarak hatalı biçimde sınıflandırılmıştır. Bununla birlikte, altın standarda göre intertrokanterik kırığı olmayan 150 olgunun 127'i doğru biçimde intertrokanterik dışı olarak sınıflandırılmış, 23 olguyu hatalı işaretlemiştir; 8'ini boyun kırığı, 15'ini subtorakanterik kırığı olan görüntüleri intertrokanterik kırık olarak etiketlenmiştir (Tablo 12).

Bu veriler ışığında, yapay zekânın intertrokanterik kırıklar için sınıflama performans ölçütleri şu şekildedir (Tablo13):

- ✓ Duyarlılık (Sensitivite): %96
- ✓ Özgüllük (Spesifite): %84,7
- ✓ Pozitif Prediktif Değer (PPV): %67,7
- ✓ Negatif Prediktif Değer (NPV): %98

Subtrokanterik femur kırıkları açısından uzman hekimin tanıları altın standart olarak kabul edilerek, YZ'nin bu kırık tipini tespit etme performansı değerlendirilmiştir. Altın standarda göre 50 olgu subtrokanterik kırık olarak sınıflandırılmıştır. Yapay zekâ bu olguların 31'ini doğru şekilde subtrokanterik kırık olarak tanımlamıştır, ancak 19 olgu farklı kırık tipleri olarak 4'ü şaft kırığı , 15'i intertorakanterik kırık şeklinde hatalı olarak sınıflandırmıştır. Bununla birlikte, altın standarda göre subtrokanterik kırığı olmayan 150 olgunun 149'sı doğru biçimde subtrokanterik dışı olarak sınıflandırılmış, intertorakanterik olan 1 olgu ise yanlış biçimde subtrokanterik kırık olarak etiketlenmiştir (Tablo 12).

Bu veriler ışığında, yapay zekânın subtrokanterik kırıklar için sınıflama performans ölçütleri şu şekildedir (Tablo 13):

- ✓ Duyarlılık (Sensitivite): %62
- ✓ Özgüllük (Spesifite): %99,3
- ✓ Pozitif Prediktif Değer (PPV): %96,7
- ✓ Negatif Prediktif Değer (NPV): %88,7

Tablo 12. Altın standart ve yapay zekanın kırık sınıflaması tespitinin kıyaslaması

	Yapay Zekâ				
	Şaft	Boyun	İntertorakanterik	Subtorakanterik	Toplam
Altın Standart					
Şaft	50 (%100)	0 (%0)	0 (%0)	0 (%0)	50 (%100)
Boyun	3 (%6)	39 (%78)	8 (%16)	0 (%0)	50 (%100)
İntertorakanterik	0 (%0)	1 (%2)	48 (%96)	1 (%2)	50 (%100)
Subtorakanterik	4 (%8)	0 (%0)	15 (%30)	31 (%62)	50 (%100)
Toplam	57 (%28,5)	41 (%20,5)	71 (%35,5)	32 (%16)	200 (%100)

Tablo 13. Yapay zekanın altın standartla kıyasla femur kırık tiplendirme performansı

Kırık Tipi	Duyarlılık (%)	Özgüllük (%)	PPV (%)	NPV (%)
Şaft	100	95,3	87,7	100
Boyun	78	99,3	97,5	93
İntertrokanterik	96	84,7	67,7	98
Subtrokanterik	62	99,3	96,7	88,7

PPV: Pozitif Prediktif Değer, NPV: Negatif Prediktif Değer

5. TARTIŞMA

Son yıllarda YZ günlük hayatımızda aktif olarak kullanılmaktadır(98)(99). Tıp camiası da artık YZ den faydalanmaktadır (100). Bu faydalanma radyoloji alanından kullanılmaktadır (101). Derin öğrenme alanındaki hızlı ilerlemeler, yapay zekâ sistemlerinin insan performansına yakın sonuçlar üretebilmesini mümkün kılmış, böylece görüntülemeleri yorumlamada deneyimli radyologlarla kıyaslanabilir düzeye ulaşmasını sağlamıştır (102,103). Acil serviste, kırıkların %3,7 ila %4,1'i atlanabilmektedir (104)(58,105). Acil serviste kaçırılan tanıların %70 ila %80'i kırıklardan oluşmaktadır (106)(107). Bu hatalar, hekimlerin çalışma saatlerinin fazla olması ve ortopedi uzmanı bulunmadığı birimlerde özellikle daha olasıdır (108). Bu durumun hasta açısından sonuçları oldukça ciddi olabilir; bunlar arasında fonksiyonel kapasitenin kaybı, kırık kaynamasında gecikme veya kaynamama riski ile birlikte travma sonrası osteoartrit gelişimi yer almaktadır (109). Bu eksikliği gidermek amacıyla, proksimal femur kırıkları ve genel travma olgularında radyografik tanıya destek sağlayacak yapay zekâ tabanlı yazılımlar geliştirilmiştir (110)(111)(112).

Mutasa ve arkadaşları tarafından gerçekleştirilen çalışmada, femur boyun kırıklarının radyografik tanısı ve Garden sınıflamasına göre ayrımı amacıyla iki aşamalı bir konvolüsyonel sinir ağı (CNN) yaklaşımı kullanılmış; sınırlı veri setinden maksimum verim alabilmek için dijital rekonstrüksiyon grafipleri (DRR) ve generatif adversaryal ağlar (GAN) gibi ileri düzey veri artırma tekniklerine başvurulmuştur. Gerçek ve yapay görüntülerden oluşan 9.063 görüntü ile eğitilen modelin kırık tespitindeki duyarlılık ve özgüllük oranları sırasıyla %91 ve %93 olarak bildirilmiştir (113). Benzer şekilde, Bae ve arkadaşlarının çalışmasında ResNet18 ile entegre edilmiş CBAM++ (Convolutional Block Attention Module) tabanlı bir derin öğrenme modeli geliştirilmiş ve 4.189 direkt grafi üzerinde %97,3 duyarlılık ve %98,7 özgüllük elde edilmiştir. Her iki çalışmada da güçlü CNN temelli mimariler ve geniş veri setleri kullanılarak yüksek doğruluk oranlarına ulaşılmıştır (114).

Buna karşılık, çalışmamızda daha güncel ve gerçek zamanlı nesne tanıma algoritması olan YOLOv11 tabanlı bir yapay zekâ modeli kullanılmış; yalnızca 2.000 gerçek görüntü içeren, dengeli ve kompakt bir veri setiyle, herhangi bir veri artırma yöntemine başvurulmaksızın eğitim gerçekleştirilmiştir. Buna rağmen modelimiz, kırık var/yok ayrımında %100 duyarlılık ve %98 özgüllük ile oldukça yüksek bir başarı

göstermiştir. Bu sonuçlar, YOLOv11'in yalnızca sınırlı veri ile dahi yüksek ayırt edici performans gösterebildiğini ve klasik CNN mimarileriyle desteklenmiş daha büyük modellerle rekabet edebilecek düzeyde başarılı olduğunu ortaya koymaktadır. Ayrıca, YOLOv11'in hızlı çalışma yapısı ve düşük işlem süresi sayesinde, klinik ortamlarda anlık karar desteği sağlamaya uygun bir çözüm sunduğu düşünülmektedir.

Yu ve arkadaşları tarafından gerçekleştirilen çalışmada, proksimal femur kırıklarının yapay zekâ destekli tanısı ve lokalizasyonu amacıyla Inception-V3 tabanlı, ImageNet ile önceden eğitilmiş bir derin öğrenme modeli kullanılmıştır. Bu model, kırık varlığı tespitinde yüksek performans göstermiş olup; duyarlılık %97,1 , özgüllük ise %96,7 olarak bildirilmiştir. Bununla birlikte, kırık lokalizasyonu açısından performans kırık tipine göre belirgin farklılık göstermiştir: boyun kırıklarında %84,1 , intertrokanterik kırıklarda %77, subtrokanterik kırıklarda ise yalnızca %20 duyarlılık elde edilmiştir (115). Çalışmamızda ise, YOLOv11 tabanlı modelimiz ile benzer düzeyde genel doğruluk elde edilmiş; 200 kırıklı olgunun tamamı doğru şekilde tespit edilerek %100 duyarlılık sağlanmıştır. Ayrıca, 200 kırık dışı olgudan 196'sı doğru şekilde 'kırık yok' olarak sınıflandırılmış ve %98 özgüllük hesaplanmıştır. Kırık tipi bazında yapılan değerlendirmede modelimizin duyarlılığı; femur boyun kırıklarında %78, intertrokanterik kırıklarda %96 ve subtrokanterik kırıklarda %62 olarak saptanmıştır. Özellikle subtrokanterik kırık grubunda, Yu ve arkadaşlarının çalışmasında bildirilen %20'lik duyarlılığa kıyasla daha yüksek bir başarı elde edilmiş olması dikkat çekicidir. Bu sonuçların, daha gelişmiş bir model mimarisi olan YOLOv11'in kullanılmasıyla ilişkili olabileceği düşünülmektedir. Sonuç olarak, modelimiz yalnızca kırık varlığını değil, aynı zamanda kırık tipini de klinik açıdan anlamlı bir doğrulukla sınıflandırabilme potansiyeline sahiptir.

Wei ve arkadaşları tarafından geliştirilen YOLOv11 tabanlı çok görevli öğrenme (multi-task learning, MTL) modeli, kas-iskelet sistemi direkt grafik görüntülerinde kırık tespitinde %95,3 doğruluk oranı ile yüksek performans göstermiştir (116). Bu çalışmada kullanılan model mimarisi, bizim çalışmamızda tercih edilen YOLOv11 altyapısıyla örtüşmektedir. Kırık tespiti açısından her iki çalışmada da benzer şekilde yüksek doğruluk oranlarına ulaşılmış olup, çalışmamızda 200 kırıklı olgunun tamamı doğru şekilde sınıflandırılmış ve %100 duyarlılık elde edilmiştir. Bu sonuç, Wei ve arkadaşlarının çalışmasıyla paralel olarak, YOLOv11 mimarisinin kırık tespitinde etkinliğini ve güvenilirliğini desteklemektedir.

YOLOv11'in hem yüksek doğruluk oranı hem de gerçek zamanlı görüntü işleme kapasitesi sayesinde, acil servis gibi hızlı karar verilmesi gereken klinik ortamlarda önemli bir avantaj sunduğu düşünülmektedir. Özellikle kırık varlığı tespitinin hızlı ve doğru bir şekilde yapılabilmesi, tedaviye erken yön verilmesini sağlayarak hasta yönetimini kolaylaştırabilir.

Guy ve arkadaşları tarafından 2020 yılında gerçekleştirilen çalışmada, proksimal femur kırıklarının tanısında derin öğrenme tabanlı bir algoritmanın performansı değerlendirilmiştir. Çalışmada 1.309 radyografi kullanılmış; veri artırma yöntemleri ile toplamda 10.472 görüntü elde edilmiş ve TensorFlow altyapısı üzerinde çalışan, CNN tabanlı Microsoft Lobe modeli ile eğitim gerçekleştirilmiştir. Elde edilen sonuçlara göre, femur boyun kırıkları için duyarlılık %61, özgüllük %67; intertrokanterik kırıklar için ise duyarlılık %67, özgüllük %70 olarak bildirilmiştir. Ayrıca PPV femur boyun için %55, intertrokanterik kırıklar için %56; NPV ise sırasıyla %74 ve %78 olarak raporlanmıştır (117). Buna karşın, çalışmamızda yaklaşık 2.000 radyografik görüntü ile eğitilmiş, YOLOv11 mimarisi tabanlı daha güncel ve nesne tanıma odaklı bir model kullanılmıştır. Eğitim veri sayısı literatürdeki birçok çalışmaya kıyasla daha düşük olmasına rağmen, femur boyun kırıkları için %78 duyarlılık, %99,33 özgüllük; intertrokanterik kırıklar için ise %96 duyarlılık, %84,7 özgüllük elde edilmiştir. Ayrıca femur boyun için PPV %97,5, NPV %93; intertrokanterik kırıklar için PPV %67,7 ve NPV %98 olarak hesaplanmıştır. Bu bulgular, daha küçük ve dengeli bir veri setiyle, ileri nesil bir mimari olan YOLOv11'in güçlü sınıflandırma ve lokalizasyon kapasitesi sayesinde, literatürdeki daha büyük veri setli çalışmalardan üstün performans elde edilebileceğini ortaya koymaktadır. Dolayısıyla çalışmamız, hem model mimarisi hem de veri verimliliği açısından anlamlı bir katkı sunmaktadır.

Beyaz ve arkadaşları tarafından gerçekleştirilen çalışmada, AP grafilerinde femur boyun kırıklarının tespiti amacıyla derin öğrenme algoritmaları ve genetik algoritmalar bir arada kullanılmıştır. Çalışmada, 65 hastaya ait 234 AP pelvis grafisi toplanmış ve veri artırma yöntemleri ile toplam 2.106 görüntüye ulaşılmıştır. Geliştirilen modelin femur boyun kırığı tespiti performansı; duyarlılık %83, özgüllük %73 ve doğruluk %77 olarak raporlanmıştır (118). Çalışmamızda ise, daha güncel ve nesne tanıma odaklı YOLOv11 mimarisi kullanılmış; veri artırma yöntemleri uygulanmaksızın, yalnızca 2.000 gerçek görüntü üzerinden model eğitilmiştir.

Modelimizin femur boyun kırığı tespiti performansı; duyarlılık %78, özgüllük %99,33 ve genel doğruluk %78 olarak hesaplanmıştır. Bu bağlamda, duyarlılık açısından benzer oranlar elde edilmiş olsa da, özgüllük oranının belirgin şekilde daha yüksek olması, yanlış pozitif oranlarının düşüklüğünü ve modelin güvenilirliğini göstermektedir. Ayrıca YOLOv11 kullanımı ve görüntü arttırılmadan yapılan çalışmaların başarı oranı daha yüksek olduğu dikkat çekmektedir.

Twinpraia ve arkadaşları tarafından yapılan çalışmada, YOLOv4-tiny tabanlı bir yapay zekâ modeli kullanılarak kalça kırıklarının tespiti ve sınıflandırılması hedeflenmiş; model, kırık varlığını tespit etmede %96,2 duyarlılık, %94,6 özgüllük ve $\kappa=0,862$ gibi yüksek performans değerleri elde etmiştir. Ayrıca, kırık tipine göre yapılan analizde femur boyun kırığı için %94,1, intertrokanterik kırıklar için %100 ve subtrokanterik kırıklar için de %100 özgüllük bildirilmiştir. Bu sonuçlar, modelin deneyimli radyolog ve ortopedi uzmanlarının değerlendirmelerine yakın doğrulukta çalıştığını göstermektedir (119). Benzer şekilde, çalışmamızda YOLOv11 mimarisi kullanılarak geliştirilen yapay zekâ modeli, 2.000 gerçek radyografik görüntü ile eğitilmiş ve test edilmiştir. Modelimiz, kırık var/yok ayrımında %100 duyarlılık ve %98 özgüllük elde etmiş; Cohen's Kappa katsayısı ise 0,980 olarak hesaplanmıştır. Bu değer, insan gözlemcilerle neredeyse mükemmel düzeyde bir uyum sağlandığını göstermektedir. Ayrıca, kırık tipi sınıflandırmasında özgüllük oranlarımız Twinpraia ve arkadaşlarının çalışmasına oldukça yakın olup, özellikle subtrokanterik kırıklar açısından benzer düzeyde başarı sağlanmıştır. Literatürde subtrokanterik kırıklarla ilgili sınıflandırma temelli çalışmaların sayıca az olması nedeniyle, bu alanda yapılan karşılaştırmalı değerlendirmelerin literatüre katkı sağlayacağı düşünülmektedir. YOLO mimarisinin evrilen versiyonlarının (YOLOv4-tiny'den YOLOv11'e) yüksek doğruluk ve işlem hızı ile acil servislerde ve uzman erişiminin sınırlı olduğu klinik ortamlarda etkili bir klinik karar destek aracı olabileceği öngörülmektedir.

Justin D. Ve arkadaşlarının yaptığı çalışmada makalenin, derin öğrenme tabanlı algoritmaların kalça kırıklarının hem tespitinde hem de fonksiyonel alt sınıflandırılmasında klinik olarak anlamlı düzeyde doğruluk sağlayabildiğini ortaya koymaktadır. Çalışmada kullanılan DenseNet-169 mimarisi, kırık tespitinde %93,7, alt sınıflandırmada ise %90,8 doğrulukla en az uzman hekim performansına ulaşmıştır (120). Bizim çalışmamızda acil tıp asistanı ve yapay zeka kıyaslandığında benzer sonuçlar elde edilmiş olup yapay zekânın özellikle subtrokanterik kırıklarda daha fazla

sınıflama hatası yaptığı görülmüştür. Bununla ilgili daha çok çalışma ve veri gerektiği düşünülmektedir. Özellikle acil servis ve eğitim ortamlarında, modelin sağladığı yapay zekâ desteğinin asistan hekimlerin tanısal doğruluğunu belirgin ölçüde artırarak uzman seviyesine yaklaştırdığı dikkat çekicidir. Bunun, yanlış tanı oranlarını azaltarak ileri görüntülemelere duyulan ihtiyacı düşürebileceği ve cerrahiye kadar geçen süreyi kısaltarak hasta prognozunu iyileştirebileceği söylenebilir.

Urakawa ve arkadaşlarının yaptığı çalışmada, derin öğrenme tabanlı CNN (VGG_16) modeli intertrokanterik kalça kırıklarının tanısında ortopedistlerden daha yüksek doğruluk göstermiştir. Özellikle %95'in üzerinde doğruluk ve özgüllük oranlarıyla, yapay zekâ algoritmasının radyografilerde kırık saptamada güvenilir bir performans sunduğu bildirilmiştir (111). Bizim çalışmamızda YZ , uzman hekime göre femur intertrokanterik kırık ayırımında duyarlılığı %96, özgüllüğü %84,7 olarak benzer sonuçlar elde etmiştir. Bu bulgular, yapay zekânın intertrokanterik kırıkları tespit etmede yüksek duyarlılık sergilediğini göstermektedir. Ancak özgüllüğün bir miktar düşük olması, bazı farklı kırık tiplerinin intertrokanterik olarak sınıflandırıldığını ortaya koymaktadır. Bu durum, algoritmanın özellikle tipler arası ayırt etme hassasiyetinin artırılması gerektiğini düşündürmektedir. Bununla beraber acil servislerde ortopedist bulunmadığında veya yoğun başvurular sırasında yapay zekâ destekli karar sistemlerinin klinik tanıya katkı sağlayabileceğini göstermektedir.

Beyaz ve arkadaşlarının çalışmasında, femur boyun kırıklarının direkt grafik görüntülerinden tespiti amacıyla derin öğrenme temelli yaklaşımlar kullanılmış ve iki farklı veri seti ile analiz gerçekleştirilmiştir. Dengesiz veri seti 2.106 görüntüden (1.341 kırık, 765 normal), dengeli veri seti ise toplam 2.682 görüntüden (eşit sayıda kırık ve normal) oluşmaktadır. Çalışmada, derin öğrenme modellerinin klasik yöntemlere kıyasla anlamlı düzeyde üstünlük sağladığı gösterilmiştir ve dengeli veri setlerinin daha olumlu sonuç verdiği görülmüştür (121).

Benzer şekilde, çalışmamızda da toplam 2.000 görüntüden oluşan ve eşit sayıda kırık (n=1.000) ve kırık olmayan (n=1.000) örnek içeren dengeli bir veri seti kullanılmıştır. Dengeli veri seti sayesinde modelin sınıflandırma başarısının daha objektif ve genellenebilir olduğu düşünülmektedir. Bu yönüyle çalışmamızın, hem veri yapısının sağlamlığı hem de modelin yüksek doğruluk oranlarıyla birlikte değerlendirildiğinde literatüre anlamlı bir katkı sağladığı kanaatindeyiz.

Cha ve arkadaşları tarafından yapılan sistematik derlemede YZ ve MÖ'nün kalça kırıklarının tanısı ve sınıflamasında kullanımını incelemiştir. Çalışmaya dâhil edilen 14 araştırmada, YZ'nin kırık sınıflamasında, YZ'nin doğruluk oranı %86–98,5 aralığında saptanmıştır (122). Bizim çalışmamızda yapay zekanın kırık sınıflaması doğruluk oranı %84 olup literatür derlemesinin ortalamasının altında kalmış olup literatüre katkı sağlanacağı düşünülmektedir. Veri sayıları ve dağılımları arttırılarak ve daha net görüntülerle modelin başarı oranının arttırılabilir.

Potter ve arkadaşlarının yaptığı çalışmada proksimal femur kırıklarını direkt grafiden saptamak için derin öğrenmeye dayalı bir model geliştirmiştir. VarifocalNet tabanlı Feature Pyramid Network (FPN) mimarisi, 823 kalça radyografisi (468 kırıklı, 355 kontrol) üzerinde test edilmiştir. Model, %95 duyarlılık ve %94 özgüllük elde ederek klinik açıdan anlamlı sonuçlar ortaya koymuştur. Model, kırığın yerini gösteren lokalizasyon özelliği sayesinde klinisyenlerin doğrulamayı kolayca yapabilmesine olanak tanımaktadır (123). Bizim çalışmamızda veri seti daha yüksek olmasına rağmen benzer sonuçlar elde edilmiş olup , farklı yapay zeka modellerinde farklı sayıda veri setleri ile aynı sonuçlar alınabileceği görüşmüş olup literatür adına anlamlı bir katkı sağlayacağı düşünülmektedir.

Yılmaz ve arkadaşlarının yaptığı çalışmada, pelvis direkt grafilerinde kalça kırıklarının tespiti için derin öğrenme tabanlı otomatik bir sistem geliştirilmiş ve 35 klinisyenle karşılaştırılmıştır. Araştırmada doğrudan obje tespitine dayalı kullanılan model YOLOv5, kırık tespitinde %92,66 doğruluk sağlarken. Buna karşılık klinisyenlerin ortalama doğruluğu %84,53 olarak bulunmuştur. Ayrıca YZ modelleri, klinisyenlere kıyasla çok daha kısa sürede sonuç vermiştir (124). Benzer sonuçlar elde edilen çalışmamızda YZ'nin, ATA'nın kırık yok dediği 4 vakayı 'kırık var 'olarak değerlendirmesi, sistemin düşük düzeyde yanlış pozitif üretme eğilimini göstermektedir. Ancak kırıklı olguların tümünün doğru tanımlanması, klinik açıdan önemli bir avantaj sağlamaktadır.

6. SONUÇ

Acil servislere çok sayıda travma hastası başvurmaktadır ve bu başvuruların önemli bir kısmı yüksek enerjili travmalara bağlı femur kırıkları ile ilgilidir. Acil servis yoğunluğu, zaman baskısı ve deneyimsiz hekim varlığı gibi faktörler, bazı femur kırıklarının atlanmasına neden olabilmektedir. Bu sorunu azaltmak amacıyla, femur kırıklarını hem tespit edebilen hem de sınıflandırabilen bir yapay zekâ modeli geliştirilmiştir. Çalışmada, acil servisimize başvuran 2.000 vakadan elde edilen direkt radyografilerle YOLOv11 tabanlı bir yapay zekâ algoritması eğitilmiş ve test edilmiştir. Elde edilen sonuçlar, modelin kırık var/yok ayrımında oldukça yüksek bir başarıya sahip olduğunu göstermektedir. Kırık sınıflandırma performansı da genel olarak başarılı bulunmuş; ancak subtrokanterik kırıklarda duyarlılığın diğer kırık tiplerine göre daha düşük olduğu tespit edilmiştir. Bu bulgunun, literatürde subtrokanterik kırıklarla ilgili çalışmaların sınırlı sayıda olmasına bağlı olduğu düşünülmekte olup, çalışmamızın bu alandaki bilgi eksikliğini kısmen de olsa tamamlayabileceği kanaatindeyiz.

Yapay zekâ temelli görüntüleme ve sınıflandırma sistemlerinin, özellikle ortopedi uzmanının bulunmadığı veya deneyimsiz hekimlerin görev yaptığı acil servislerde, hızlı tanıya yardımcı olacak destek araçları olarak kullanılabileceği düşünülmektedir. Bununla birlikte, çalışmamızın genellenebilirliğini artırmak ve klinik entegrasyonu güçlendirmek adına, daha geniş örneklem gruplarında, çok merkezli ve ulusal düzeyde yapılacak ileri çalışmalara ihtiyaç bulunmaktadır.

7. KAYNAKLAR

1. Kannus P, Parkkari J, Sievänen H, Heinonen A, Vuori I, Järvinen M. Epidemiology of hip fractures. *Bone*. 18(1):57–63.
2. Bhandari M, Swiontkowski M. Management of acute hip fracture. *N Engl J Med*. 2017;377(21):2053–62.
3. Jamjoom BA, Davis TRC. Why scaphoid fractures are missed. A review of 52 medical negligence cases. *Injury* [Internet]. 2019 Jul 1;50(7):1306–8. Available from: <https://doi.org/10.1016/j.injury.2019.05.009>
4. Guly HR. Diagnostic errors in an accident and emergency department. *Emerg Med Journal*. 2001;18(4):263–9.
5. Liu P., Lu L, Liu S, et al. Mixed reality assists the fight against COVID-19. *Intell Med*. 2021;1(1):16–8.
6. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019;25(1):44–56.
7. Chen K, Zhai X, Sun K, Wang H, Yang C., Li M. A narrative review of machine learning as promising revolution in clinical practice of scoliosis. *Ann Transl Med*. 2021 Jan 9.
8. Wang S, Yang DM, Rong R, Zhan X, Xiao G. Pathology Image Analysis Using Segmentation Deep Learning Algorithms. *Am J Pathol* [Internet]. 2019 Sep 1;189(9):1686–98.
9. Norman B, Padoa V, Noworolski A, Link TM, Majumdar S. Applying Densely Connected Convolutional Neural Networks for Staging Osteoarthritis Severity from Plain Radiographs. *J Digit Imaging* [Internet]. 2019;32(3):471–7.
10. Nguyen DT, Pham TD, Batchuluun G, Yoon HS, Park KR. Artificial Intelligence-Based Thyroid Nodule Classification Using Information from Spatial and Frequency Domains. *J Clin Med* [Internet]. 2019;8(11).
11. Ding Z, Shi H, Zhang H, Meng L, Fan M, Han C, et al. Gastroenterologist-Level Identification of Small-Bowel Diseases and Normal Variants by Capsule Endoscopy Using a Deep-Learning Model. *Gastroenterology* [Internet]. 2019 Oct 1;157(4):1044-1054.e5.
12. Jiménez-Sánchez A, Kazi A, Albarqouni S, Kirchhoff C, Biberthaler P, Navab N, et al. Precise proximal femur fracture classification for interactive training and surgical planning. *Int J Comput Assist Radiol Surg*. 2020 Oct;15.
13. Standring, Susan. *Gray's Anatomy: The Anatomical Basis of Clinical Practice*. 41st ed. London: Elsevier; 2016. 1373–1377 p.
14. Moore, Keith L., Dalley, Arthur F., Agur, Anne M.R. *Clinically Oriented Anatomy*. 7th ed. Wolters Kluwer, editor. Philadelphia: Wolters Kluwer; 2017. 607–611 p.
15. Netter, Frank H. *Atlas of Human Anatomy*. 6th Edition. Philadelphia: Elsevier; 2014. 319-321,532 p.
16. Platzer, Werner. *Color Atlas of Human Anatomy Vol 1 Locomotor System*. 6th Edition. Stuttgart: Thieme; 2008. 206–208 p.

17. Gray Henry, Warren Harmon. *Anatomy of the Human Body*. Philadelphia: Lea & Febiger; 1918. 242–254 p.
18. Drake RL, Vogl WA, Mitchell AWM. *Gray's Anatomy for Students*. 4th Edition. Elsevier; 2019. 518 p.
19. Sinnatamby CS. *Last's Anatomy: Regional and Applied*. 12 Edition. Edinburgh: Churchill Livingstone; 2011. 278–280 p.
20. Snell RS. *Clinical Anatomy by Regions*. 9. Edition. Wolters Kluwer; 2012. 213 ,452-457.
21. Williams PL, Warwick R, Dyson M, Bannister LH. *Gray's Anatomy*. 38th ed. Edinburgh: Churchill Livingstone; 1995. 528–533 p.
22. Clemente CD. *Anatomy: A Regional Atlas of the Human Body*. 3rd Edition. Baltimore: Urban & Schwarzenberg; 1985. 291 p.
23. Kapandji IA. *Physiology of the Joints, Volume 2: Lower Limb*. 6th Edition. Vol. 2. Edinburgh: Churchill Livingstone; 2007. 88 p.
24. Kaushansky K, Prchal JT, Burns LJ, Lichtman MA, Levi M, Linch DC. *Molecular and Cellular Hamatology*. In: *Williams Hematology*. 9th Edition. New York: McGraw-Hill Education; 2015.
25. Seeley MA, Georgiadis AG, Sankar WN. Hip Vascularity: A Review of the Anatomy and Clinical Implications. *Journal of the American Academy of Orthopaedic Surgeons*. 2016 Aug;24:515–26.
26. Chung SM. The arterial supply of the developing proximal end of the human femur. *Journal of Bone and Joint Surgery – American Volume*. 1976 Oct;58(7):961–70.
27. Trueta J, Harrison MH. The normal vascular anatomy of the femoral head in adult man. *Journal of Bone and Joint Surgery – British Volume*. 1953 Aug;35-B(3).
28. Özkan S, Adanaş C. Current Approaches in Femoral Neck Fractures. *Van Medical Journal (Van Med J)*. 2018;25(1):76–81.
29. Zuckerman JD. Hip fracture. *New England Journal of Medicine*. 1996;334(23).
30. Richmond J, Aharonoff GB, Zuckerman JD, Koval KJ. Mortality risk after hip fracture. *J Orthop Trauma*. 2003;17(8):2–5.
31. Ege R. *Travmatoloji: Kırıklar ve Eklem Yaralanmaları*. 4. baskı. Ankara: Kadioğlu Matbaası; 1989.
32. Mooney V, Claudi BF. Fracture of the Shaft of the Femur. In: Rockwood CA, Green DP, editors. *Fractures in Adults*. 2nd ed. Philadelphia: Lippincott Company; 1984. p. 1357–427.
33. Taylar JC. Fracture of Lower Extremity. In: Crenshaw AH, editor. *Campbell's Operative Orthopaedics*. 8th ed. St. Louis: Mosby-Year Book; 1992. p. 785–893.
34. Gwathmey WFJ, Jones-Quaidoo SM, Kahler D, Hurwitz S., Cui Q. Distal femoral fractures: current concepts. *Journal of the American Academy of Orthopaedic Surgeons*. 2010;18(10).

35. Gangavalli AK, Nwachuku CO. Management of Distal Femur Fractures in Adults: An Overview of Options. *Orthopedic Clinics of North America*. 2016;47(1):85–96.
36. Flaherty JJ, Kelley R, Burnett B. Relationship of pelvic bone fracture patterns to injuries of urethra and bladder. *Journal of Urology*. 1968;99(3):297–300.
37. Iwasaki K, Yamamoto T, Motomura G. Subchondral insufficiency fracture of the femoral head in young adults. *Clin Imaging*. 2011;35(3):208–13.
38. Isaac B, Vettivel S, Prasad R. Prediction of the femoral neck-shaft angle from the length of the femoral neck. *Clinical Anatomy*. 1997;10(5):318–23.
39. Mavrogenis AF. Complications after hip nailing for fractures. *Orthopedics*. 2016;39(1):108–16.
40. Helfet DL, Lorich DG. Surgical Dislocation of the Hip for Fractures of the Femoral Head. *J Orthop Trauma*. 2005;19:334–42.
41. Pipkin G. Treatment of grade IV fracture-dislocation of the hip. *Journal of Bone and Joint Surgery – American Volume*. 1957 Oct;39-A(5):1027–42.
42. Lavelle DG. Hip Fracture. In: Canale ST, editor. *Campbell's Operative Orthopaedics*. 10th ed. St. Louis; 2003. p. 2873–938.
43. Swiontkowski MF, Tepic S, Perren SM, Moor R, Ganz R, Rahn BA. Laser Doppler flowmetry for bone blood flow measurement: correlation with microsphere estimates and evaluation of the effect of intracapsular pressure on femoral head blood flow. *Journal of Orthopaedic Research*. 1986;4(3):362–71.
44. Koval KJ, Zuckerman JD. Intertrochanteric fractures. In: *Handbook of Fractures*. 3. Philadelphia: Lippincott Williams & Wilkins; 2006. p. 285–92.
45. Anderson GH, Raymakers R, Gregg PJ. Overview of common hip fractures in adults. *Journal of Bone and Joint Surgery – British Volume*. 1993 May;75(3):441–4.
46. Hinton RY, Lennox DW, Ebert FR, Jacobsen SJ, Smith GS. Relative rates of fracture of the hip in the United States. Geographic, sex, and age variations. *Journal of Bone and Joint Surgery – American Volume*. 1995 May;77(5):695–702.
47. Lewinnek GE, Kelsey JL, White AAI, Kreiger NJ. The significance and a comparative analysis of the epidemiology of hip fractures. *Clin Orthop Relat Res*. 1980 Oct;(152):35–43.
48. Ege R. Femur Proksimal Uç Kırıkları. In: *Travmatoloji: Kırıklar, Eklem ve Diğer Yaralanmalar*. 4. baskı. Ankara: Kadioğlu Matbaası; 1989. p. 2891–3143.
49. Browner DB, Jupiter JB, Levine AM, Trafton PG. Intertrochanteric femur fracture. In: *Skeletal Trauma*. W.B. Saunders Company; 1996. p. 1833–926.
50. Overview of common hip fractures in adults - UpToDate [Internet]. [cited 2025 May 22].
51. Bergman GD, Winkquist RA, Mayo KA, Hansen ST. Subtrochanteric Fractures of the Femur. *Journal of Bone and Joint Surgery – American Volume*. 1987;69-A(7):1032–40.

52. Kınık H. Pelvis Kırıkları ve Tedavisi. *Türk Ortopedi ve Travmatoloji Dergisi*. 2008;7:40–50.
53. Advanced Trauma Life Support Student Course Manual. 10th ed. Chicago: American College of Surgeons; 2018.
54. Bickley LS, Szilagyi PG. Bates' Guide to Physical Examination and History Taking. 13th ed. Wolters Kluwer; 2020. 803 p.
55. Tile M. Pelvic ring fractures: should they be fixed? *Journal of Bone and Joint Surgery*. 1988;70(1):1–12.
56. Hak DJ, Olson SA, Matta JM. Diagnosis and management of closed internal degloving injuries associated with pelvic and acetabular fractures: the Morel-Lavallée lesion. *Journal of Trauma*. 1997;42(6):1046–51.
57. Gogas Yavuz D, Cetin O. Fizik Muayene Kitabı. 1st ed. Marmara University; 2011. 41 p.
58. Wei CJ, Tsai WC, Tiu CM, Wu HT, Chiou HJ, Chang CY. Systematic analysis of missed extremity fractures in emergency radiology. *Acta radiol*. 2006;47(7):710–7.
59. Schmidt AH, Loegering R. Imaging Considerations in Orthopedic Trauma. In: Tornetta P; RW; CBCM; MMM; MM, editor. *Rockwood and Green's Fractures in Adults*. Philadelphia: Wolters Kluwer; 2020. p. 318–77.
60. Tuncel E. Klinik Radyoloji. 2. baskı. İstanbul: Nobel Tıp Kitabevleri; 2012.
61. Zink FE. X-ray Tubes. *RadioGraphics*. 1997;17:1259–68.
62. Geiderman J, Katz D. Rosen's Emergency Medicine. In: *Rosen's Emergency Medicine*. 10th ed. Philadelphia: Elsevier; 2023. p. 580–600.
63. Tannast M, Najibi S, Matta JM. Two to Twenty-Year Survivorship of the Hip in 810 Patients with Operatively Treated Acetabular Fractures. *Journal of Bone and Joint Surgery [Internet]*. 2012 Sep 5 [cited 2025 May 24];94(17):1559–67.
64. Azar FM;, Beaty JH. *Campbell's Operative Orthopaedics*. 14th ed. Philadelphia: Elsevier; 2021. 2973–3011 p.
65. Schmaranzer F, Lerch TD, Todorski IAS, Tannast M, Steppacher S. Radiology of the Hip Joint. 2019 [cited 2025 May 24];19–32. Available from: https://link.springer.com/chapter/10.1007/978-3-030-18838-2_2
66. Haubro M, Stougaard C, Torfing T, Overgaard S. Sensitivity and specificity of CT- and MRI-scanning in evaluation of occult fracture of the proximal femur. *Injury [Internet]*. 2015 Aug 1 [cited 2025 May 24];46(8):1557–61.
67. Collin D, Geijer M, Göthlin JH. Computed tomography compared to magnetic resonance imaging in occult or suspect hip fractures. A retrospective study in 44 patients. *Eur Radiol [Internet]*. 2016 Nov 1 [cited 2025 May 24];26(11):3932–8.
68. Schmaranzer F, Todorski IAS, Lerch TD, Schwab J, Cullmann-Bastian J, Tannast M. Intra-articular Lesions: Imaging and Surgical Correlation. *Semin Musculoskelet Radiol [Internet]*. 2017 Nov 1 [cited 2025 May 24];21(5):487–506.

69. Kaul V, Enslin S, Gross SA. History of artificial intelligence in medicine. *Gastrointest Endosc.* 2020;92(4):807–12.
70. Mintz Y, Brodie R. Introduction to artificial intelligence in medicine. *Minimally Invasive Therapy & Allied Technologies.* 2019;28(2):73–81.
71. Nabiyev V V. *Yapay Zekâ: İnsan-Bilgisayar Etkileşimi.* Ankara: Seçkin Yayıncılık; 2012.
72. Andrew AM. *Artificial Intelligence.* Boston: Addison-Wesley; 1991.
73. Popov E V. *Yapay Zekâ: Uzman Sistemler ve Doğal Dil İşleme.* Radio i Svyaz; 1990. 461 p.
74. Charniak E, McDermott D. *Introduction to Artificial Intelligence.* Boston: Addison-Wesley Company; 1985.
75. Oren O, Gersh BJ, Bhatt DL. Artificial intelligence in medical imaging: switching from radiographic pathological data to clinically meaningful endpoints. *Lancet Digit Health.* 2020;2(9):486–8.
76. Samuel AL. Some Studies in Machine Learning Using the Game of Checkers. *IBM J Res Dev.* 1959;3(3):210–29.
77. Litjens G; et al. A survey on deep learning in medical image analysis. *Med Image Anal.* 42:60–88.
78. Bishop MB. *Pattern Recognition and Machine Learning.* Last Edition. : New York: Springer; 2006.
79. Zhu X, Goldberg AB. *Introduction to Semi-Supervised Learning.* Springer; 2009.
80. L. Kaelbling, M. Littman, A. Moore. Reinforcement learning: A survey. *Journal of Artificial Intelligence Research.* 1996;4:237–85.
81. Sutton RS, Barto AG. *Introduction to reinforcement learning.* mit press. Cambridge, MA. 1998;
82. Mousavi Seyed Sajad and Schukat M and HE. Deep Reinforcement Learning: An Overview. In: Bi Yaxin and Kapoor S and BR, editor. *Proceedings of SAI Intelligent Systems Conference (IntelliSys) 2016.* Cham: Springer International Publishing; 2018. p. 426–40.
83. Pouyanfar S, Sadiq S, Yan Y, Tian H, Tao Y, Reyes MP; et al. A Survey on Deep Learning: Algorithms, Techniques, and Applications. *ACM Comput Surv.* 2018 Sep 16;51(5):92:1-92:36.
84. Al-Rabadi A, Al-Rabadi AN. Intelligent Control of Singularly-Perturbed Reduced Order Eigenvalue-Preserved Quantum Computing Systems via Artificial Neural Identification and Linear Matrix Inequality Transform Intelligent Control of Singularly-Perturbed Reduced Order Eigenvalue-Preserved Quantum Computing Systems via Artificial Neural Identification and Linear Matrix Inequality Transformation [Internet]. 2010.
85. Cheng PM, Montagnon E, Yamashita R, Pan I, Cadrin-Chênevert A, Perdigón Romero F, et al. Deep learning: An update for radiologists. *Radiographics.* 2021;41(5):1427–45.

86. Soffer S, Ben-Cohen A, Shimon O, Amitai MM, Greenspan H, Klang E. Convolutional Neural Networks for Radiologic Images: A Radiologist's Guide. *Radiology*. 2019;290(3):590–606.
87. Cengil E, Çınar A. A New Approach For Image Classification: Convolutional Neural Network. Vol. 6, *European Journal Of Technic Ejt*. 2016.
88. Liawrungrueang W, Cho ST, Kotheeranurak V, Jitpakdee K, Kim P, Sarasombath P. Osteoporotic vertebral compression fracture (OVCF) detection using artificial neural networks model based on the AO spine-DGOU osteoporotic fracture classification system. *North American Spine Society Journal*. 2024 Sep 1;19.
89. Redmon J, Divvala S, Girshick R, Farhadi A. You Only Look Once: Unified, Real-Time Object Detection. In 2016. p. 779–88.
90. Ragab MG, Abdulkadir SJ, Muneer A, Alqushaibi A, Sumiea EH, Qureshi R, et al. A Comprehensive Systematic Review of YOLO for Medical Object Detection (2018 to 2023). *IEEE Access*. 2024;12:57815–36.
91. Redmon J. You only look once: Unified, real-time object detection. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE;
92. Kamilaris A, Prenafeta-Boldú FX. Deep learning in agriculture: A survey. *Comput Electron Agric*. 2018;147:70–90.
93. Nguyen HH, Ta TN, Nguyen NC, Bui VT, Pham HM, Nguyen DM. YOLO Based Real-Time Human Detection for Smart Video Surveillance at the Edge. In: *2020 IEEE Eighth International Conference on Communications and Electronics (ICCE)*. 2021. p. 439–44.
94. Pawar N, Waghmare A, Pratap A, Thorat A, Ghogale K, Karamtoth S, et al. Miniscule Object Detection in Aerial Images Using YOLOR: A Review. In 2022. p. 697–708.
95. Hussain M. YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection. *Machines and Tooling*. 2023 May;11:677.
96. Schechter MT. Sensitivity, Specificity, and Predictive Value. In: Troidl H. and McKneally MF and MDS and WAS and MB and SWO, editor. *Surgical Research: Basic Principles and Clinical Practice* [Internet]. New York, NY: Springer New York; 1998. p. 257–69.
97. Landis JR, Koch GG. The Measurement of Observer Agreement for Categorical Data. *Biometrics* [Internet]. 1977;33(1):159–74.
98. Xiong W, Droppo J, Huang X, Seide F, Seltzer ML, Stolcke A, et al. Toward Human Parity in Conversational Speech Recognition. *IEEE/ACM Trans Audio Speech Lang Process*. 2017;25(12):2410–23.
99. Pendleton SD, Andersen H, Du X, Shen X, Meghjani M, Eng YH, et al. Perception, Planning, Control, and Coordination for Autonomous Vehicles. *Machines* [Internet]. 2017;5(1).
100. Deo RC. Machine Learning in Medicine. *Circulation* [Internet]. 2015 Nov 17;132(20):1920–30.

101. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal* [Internet]. 2017;42:60–88.
102. Kooi T, Litjens G, van Ginneken B, Gubern-Mérida A, Sánchez CI, Mann R, et al. Large scale deep learning for computer aided detection of mammographic lesions. *Med Image Anal* [Internet]. 2017;35:303–12.
103. Rajkomar A, Lingam S, Taylor AG, Blum M, Mongan J. High-Throughput Classification of Radiographs Using Deep Convolutional Neural Networks. *J Digit Imaging* [Internet]. 2017;30(1):95–101.
104. Hallas P, Ellingsen T. Errors in fracture diagnoses in the emergency department – characteristics of patients and diurnal variation. *BMC Emerg Med* [Internet]. 2006;6(1):4.
105. Wei CJ, Tsai WC, Tiu CM, Wu HT, Chiou HJ, Chang CY. Systematic Analysis of Missed Extremity Fractures in Emergency Radiology. *Acta radiol* [Internet]. 2006 Jan 1;47(7):710–7.
106. Guly HR. Diagnostic errors in an accident and emergency department. *Emergency Medicine Journal* [Internet]. 2001 Jul 1;18(4):263.
107. Leeper WR, Leeper TJ, Vogt KN, Charyk-Stewart T, Gray DK, Parry NG. The role of trauma team leaders in missed injuries: Does specialty matter? *Journal of Trauma and Acute Care Surgery* [Internet]. 2013;75(3).
108. Hallas P, Ellingsen T. Errors in fracture diagnoses in the emergency department – characteristics of patients and diurnal variation. *BMC Emerg Med* [Internet]. 2006;6(1):4.
109. Lindsey R, Daluiski A, Chopra S, Lachapelle A, Mozer M, Sicular S, et al. Deep neural network improves fracture detection by clinicians. *Proceedings of the National Academy of Sciences* [Internet]. 2018;115(45):11591–6.
110. Cheng CT, Ho TY, Lee TY, Chang CC, Chou CC, Chen CC, et al. Application of a deep learning algorithm for detection and visualization of hip fractures on plain pelvic radiographs. *Eur Radiol* [Internet]. 2019;29(10):5469–77.
111. Urakawa T, Tanaka Y, Goto S, Matsuzawa H, Watanabe K, Endo N. Detecting intertrochanteric hip fractures with orthopedist-level accuracy using a deep convolutional neural network. *Skeletal Radiol* [Internet]. 2019;48(2):239–44.
112. Olczak J, Fahlberg N, Maki A, Razavian AS, Jilert A, Stark A, et al. Artificial intelligence for analyzing orthopedic trauma radiographs. *Acta Orthop* [Internet]. 2017 Nov 2;88(6):581–6.
113. Mutasa S, Varada S, Goel A, Wong TT, Rasiej MJ. Advanced Deep Learning Techniques Applied to Automated Femoral Neck Fracture Detection and Classification. *J Digit Imaging* [Internet]. 2020;33(5):1209–17.
114. Bae J, Yu S, Oh J, Kim TH, Chung JH, Byun H, et al. External Validation of Deep Learning Algorithm for Detecting and Visualizing Femoral Neck Fracture Including Displaced and Non-displaced Fracture on Plain X-ray. *J Digit Imaging* [Internet]. 2021;34(5):1099–109.
115. Yu JS, Yu SM, Erdal BS, Demirer M, Gupta V, Bigelow M, et al. Detection and localisation of hip fractures on anteroposterior radiographs with artificial

- intelligence: proof of concept. Clin Radiol [Internet]. 2020;75(3):237.e1-237.e9.
116. Wei W, Huang Y, Zheng J, Rao Y, Wei Y, Tan X, et al. YOLOv11-based multi-task learning for enhanced bone fracture detection and classification in X-ray images. J Radiat Res Appl Sci [Internet]. 2025;18(1):101309.
 117. Guy S, Jacquet C, Tsenkoff D, Argenson JN, Ollivier M. Deep learning for the radiographic diagnosis of proximal femur fractures: Limitations and programming issues. Orthopaedics & Traumatology: Surgery & Research [Internet]. 2021;107(2):102837.
 118. Beyaz S, Yaylı ŞB, Doktor U. Derin öğrenme ile otomatik kalça kırığı tanısı.
 119. Twinprai N, Boonrod A, Boonrod A, Chindaprasirt J, Sirithanaphol W, Chindaprasirt P, et al. Artificial intelligence (AI) vs. human in hip fracture detection. Heliyon [Internet]. 2022 Nov 1;8(11).
 120. Krogue JD, Cheng K V, Hwang KM, Toogood P, Meinberg EG, Geiger EJ, et al. Automatic Hip Fracture Identification and Functional Subclassification with Deep Learning. Radiol Artif Intell [Internet]. 2020;2(2):e190023.
 121. Beyaz S, Açıcı K, Sumer E. Femoral neck fracture detection in X-ray images using deep learning and genetic algorithm approaches. Eklem Hastalik Cerrahisi. 2020 Mar 27;31.
 122. Cha Y, Kim JT, Park CH, Kim JW, Lee SY, Yoo JI. Artificial intelligence and machine learning on diagnosis and classification of hip fracture: systematic review. J Orthop Surg Res [Internet]. 2022;17(1):520.
 123. Yıldız Potter İ, Yeritsyan D, Mahar S, Kheir N, Vaziri A, Putman M, et al. Proximal femur fracture detection on plain radiography via feature pyramid networks. Sci Rep [Internet]. 2024;14(1):12046.
 124. Yilmaz A, Gem K, Kalebasi M, Varol R, Gencoglan ZO, Samoylenko Y, et al. An automated hip fracture detection, classification system on pelvic radiographs and comparison with 35 clinicians. Sci Rep [Internet]. 2025;15(1):16001.

8. EKLER

EK 1: ETİK KURUL İZNİ

	T.C. AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ MÜDAHALE OLMAYAN BİLİMSEL ARAŞTIRMALAR ETİK KURULU
Birimi : Etik Kurul Başkanlığı Sayı : 2024/262 Konu : Etik Kurul Kararı	02.08.2024
Sayın; Doç. Dr. Ayşe ERTEKİN Afyonkarahisar Sağlık Bilimleri Üniversitesi Tıp Fakültesi Acil Tıp AD AFYONKARAHİSAR	
İlgi: Etik Kurul'un 02.08.2024 tarih ve 2024/262 sayılı kararı. Sorumluluğunuzda yürütülecek olan “Acil Serviste Proksimal Femur Fraktürlerinin Tespitinde Yapay Zekanın Kullanımı” başlıklı çalışmanıza ilişkin alınan ilgi sayılı Etik Kurul Kararı ekte gönderilmiştir. Bilgilerinizi ve gereğini rica ederim.	
EK: 1-İlgi sayılı karar (1 sayfa)	

T.C.
AFYONKARAHİSAR SAĞLIK BİLİMLERİ ÜNİVERSİTESİ
MÜDAHALE OLMAYAN BİLİMSEL ARAŞTIRMALAR ETİK KURULU

Toplantı Tarihi	02.08.2024	Toplantı Numarası	2024/6	Toplantı Saati	09:30
-----------------	------------	-------------------	--------	----------------	-------

262-Doç. Dr. Ayşe ERTEKİN'in sorumluluğunda yürütülecek olan "Acil Serviste Proksimal Femur Fraktürlerinin Tespitinde Yapay Zekanın Kullanımı" konulu Müdahale Olmayan Bilimsel Araştırmalar için başvuru dosyası incelendi. Araştırma protokolüne uyularak, Afyonkarahisar Sağlık Bilimleri Üniversitesi Müdahale Olmayan Bilimsel Araştırmalar Etik Kurulu Yönergesinde belirtilen hususlar yerine getirilmek ve sorumluluk araştırmacılara ait olmak üzere araştırmanın yapılmasında etik sakınca olmadığına toplantıya katılan üyelerin **oy birliği** ile karar verildi.



EK 2: VERİ TOPLAMA FORMU

Acil Serviste Proksimal Femur Fraktürlerinin Tespitinde Kullanılacak Veri Toplama Formu

Hasta İsim-Soyisim:				
Tarih:				
Dosya No:				
YAŞ				
CİNSİYET				
	ACİL TIP ASİSTANI		YAPAY ZEKA	
X-RAY Görüntü Analizi ile Proksimal Femur Fraktür Varlığı:	VAR	YOK	VAR	YOK
X-RAY Görüntü Analizi ile Proksimal Femur Fraktür Gruplaması:	VAR	YOK	VAR	YOK
Femur başı fraktürü				
Femur boyun fraktürü				
Femur intertrokanterik fraktürü				
Subtrokanterik femur fraktürü				