

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DERİN ÖĞRENME İLE KALÇA PROTEZLERİNDEKİ
AŞINMANIN TESPİTİ

YÜKSEK LİSANS TEZİ

Yahia ADWAN

EKİM 2025
TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DERİN ÖĞRENME İLE KALÇA PROTEZLERİNDEKİ AŞINMANIN
TESPİTİ

Yahia ADWAN

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
" ELEKTRONİK YÜKSEK MÜHENDİSİ "
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 15 / 09 / 2025

Tezin Savunma Tarihi : 08 / 10 / 2025

Tez Danışmanı : Dr. Öğr. Üyesi M ÖZTÜRK

Trabzon 2025

ÖNSÖZ

“Derin Öğrenme ile Kalça Protezlerindeki Aşınmanın Tespiti” başlıklı bu yüksek lisans tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Programı’nda hazırlanmıştır.

Tez çalışmam süresince yolumu aydınlatan, değerli bilgi ve tecrübeleriyle bana her zaman rehberlik eden danışman hocam Sayın Dr. Öğr. Üyesi Mehmet Öztürk’e en içten teşekkürlerimi sunarım.

Bu tez çalışmasını, kimliğimin ve akademik yolculuğumun en önemli parçası olan Filistin’e, özellikle de Gazze’ye ithaf ediyorum.

Gazze’nin bana öğrettiği direniş ve umut, bu çalışmanın satırlarında gizlidir.

Doğduğum günden bu yana yanımda olan, sevgileri ve dualarıyla bana güç veren aileme teşekkür ederim. Özellikle en büyük ilham kaynağım ve destekçim olan, ancak bugün yanımda olmayan babamın hatırasını bu sayfalarda yaşatmak istiyorum. Bana değerlerini, sevgisini ve azmini miras bıraktığı için minnettarım.

Yahia ADWAN

Trabzon 2025

TEZ ETİK BEYANNAMESİ

Aşağıda imzası bulunan ben, bu çalışma başlığı “Derin Öğrenme ile Kalça Protezlerindeki Aşınmanın Tespiti” olan tezin, Danışmanım Dr. Öğr. Üyesi MEHMET ÖZTÜRK gözetiminde, tamamen kendi özgün çalışmam olduğunu, başka bir üniversitede herhangi bir derece için sunulmadığını ve çalışmada kullanılan tüm kaynakların usulüne uygun olarak belirtildiğini beyan ederim. 08 /10/ 2025

Yahia ADWAN

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	IX
SUMMARY.....	X
ŞEKİLLER DİZİNİ.....	XI
TABLolar DİZİNİ.....	XII
SEMBOLLER VE KISALTMALAR DİZİNİ	XIII
1. GENEL BİLGİLER	1
1.1. Genel Tanıtım ve Problem Durum	1
1.2. Kalça Protezlerinin Yapısı ve Malzemeleri.....	2
1.3. Aşınma Tespiti ve Önemi.....	4
1.4. Klasik Radyografik Aşınma Yöntemleri.....	5
1.4.1. Radyografide Manuel Aşınma Ölçüm Yaklaşımları.....	5
1.4.2. Bilgisayar Destekli Aşınma Ölçüm Yöntemleri.....	9
1.5. İleri Görüntü İşleme ve Derin Öğrenme.....	10
1.5.1. Yapay Zekâ (YZ)	10
1.5.2. Makine Öğrenmesi.....	10
1.5.3. Derin Öğrenme (DÖ).....	11
1.5.4. Evrişimli Sinir Ağları (Convolutional Neural Networks – ESA).....	11
1.5.5. YOLOv5 (You Only Look Once – v5 sürümü).....	11
1.5.6. Veri Artırma (Data Augmentation).....	12
1.5.7. Normalizasyon	12
1.5.8. Çift Taraflı Filtre (Bilateral)	12
1.5.9. Canny Kenar Algılama.....	13
1.5.10. RANSAC (Rastgele Örnekleme ile Uyum Yaklaşımı).....	13
1.5.11. Hough Dönüşümü.....	13
1.5.12. Edge-Snap.....	14
1.5.13. Doğrulama (Validation)	14
1.5.14. Erken Durdurma.....	14

1.5.15. Aşırı Öğrenme (Overfitting).....	15
1.5.16. Epoch	15
1.5.17. Batch Size (Toplu İş Boyutu)	15
1.5.18. Kayıp Fonksiyonu.....	15
1.5.19. Doğruluk (Accuracy).....	16
1.5.20. Kesinlik (Precision)	16
1.5.21. Duyarlılık (Recall)	17
1.5.22. Kesişim Oranı (Intersection over Union – IoU)	17
1.5.23. Genel Ortalama Kesinlik (mean Average Precision – mAP)	17
1.6. Bu Tezin Amacı ve Katkısı	18
1.7. Tezin Kapsamı ve Organizasyonu.....	19
2. YAPILAN ÇALIŞMALAR.....	21
2.1. Veri Seti Hazırlığı	21
2.1.1. Görsel Kaynakları	21
2.1.2. Görsel Sayısı ve Dağılımı	22
2.1.3. Eğitim/Doğrulama/Test Ayrımı.....	23
2.1.4. Ön İşleme Adımları.....	24
2.2. Etiketleme Süreci	26
2.2.1. Python İşaretleme Aracı.....	26
2.2.2. Femoral Baş Etiketleme	27
2.2.3. Asetabular Yuva (AY) Etiketleme Kuralları	28
2.2.4. YOLO-Daire Formatı (x, y, r)	29
2.3. Normalizasyon ve Format Dönüşümleri	30
2.3.1. Normalizasyon Formülleri.....	30
2.3.2. Piksel ↔ Normalize Karşılaştırmaları.....	31
2.3.3. Normalizasyonun Gerekliliği ve Avantajları.....	31
2.3.4. Daire → Kutu Dönüşümü (YOLO-Kutu)	32
2.4. Geleneksel Görüntü İşleme Yöntemleri	34
2.5. Hibrit Yaklaşım: YOLO + Geleneksel Yöntemler	36
2.5.1. Edge-Snap ile Yarıçap İyileştirme	36
2.5.2. RANSAC ile Sağlamlaştırma	37
2.5.3. Hough Fallback Stratejisi.....	37
2.6. Anatomik Kurallarla Son Seçim.....	38

2.7. Model Eğitimi.....	40
2.7.1. Eğitim Ortamı (Donanım, CUDA, Torch)	40
2.7.2. Hiperparametre Seçimlerinin Mantığı.....	41
2.7.3. İki Aşamalı Eğitim Stratejisi (freeze/unfreeze).....	42
2.7.4. Veri Artırma	42
2.7.5. Kullanılan Kayıp Fonksiyonunun İşleyişi	43
2.7.6. Eğitim Döngüsünün İşleyişi	44
2.7.7. Gerekçe ve Beklenen Etki.....	44
2.8. Görselleştirme Süreci.....	46
2.8.1. İlgi Bölgesi Otomatik Belirleme (YOLOv5 Tabanlı Odaklama Yaklaşım).....	46
2.8.2. Çıktıların Çizdirilmesi.....	47
2.8.3. Görsellerin Kaydedilmesi	49
2.8.4. Etiketlerin Kaydedilmesi (Labels Results)	49
2.9. Aşınma Hesaplama Yöntemi.....	50
2.9.1. Medial Aşınma (Merkezler Arası 2B Mesafe).....	50
2.9.2. Superior Aşınma (Üst Noktalar Arası Dikey Mesafe).....	51
2.9.3. Genel Aşınma Büyüklüğü.....	51
2.9.4. Çıktıların Kayıt Biçimi.....	51
3. BULGULAR VE TARTIŞMA.....	53
3.1. Eğitim Sonuçları.....	53
3.1.1. Eğitim Kayıplı Eğrileri.....	53
3.1.2. mAP Değerleri	55
3.1.3. Kesinlik ve Duyarlılık Performansı	56
3.2. Başarı Eğrileri.....	57
3.2.1. Femoral ve Yuva Merkez Doğruluk Eğrileri (piksel)	57
3.2.2. Femoral ve Yuva Yarıçap Doğruluk Eğrileri (piksel)	58
3.2.3. Femoral ve Yuva Merkez Doğruluk Eğrileri (normalize).....	59
3.2.4. Femoral ve Yuva Yarıçap Doğruluk Eğrileri (normalize).....	60
3.2.5. Normalize ve Piksel Sonuçlarının Karşılaştırılması.....	61
3.3. Görsel Bulgular	62
3.3.1. YOLOv5 ile Bölge Lokalizasyonu	62
3.3.2. Farklı Koşullarda Tespitler	63
3.3.3. Hatalı Tespit Örnekleri.....	64

3.4. Aşınma Analiz Sonuçları.....	66
4.TARTIŞMA.....	72
5. SONUÇLAR.....	79
6. ÖNERİLER.....	81
7. KAYNAKLAR.....	84
ÖZGEÇMİŞ	



Yüksek Lisans Tezi

ÖZET

DERİN ÖĞRENME İLE KALÇA PROTEZLERİNDEKİ AŞINMANIN TESPİTİ

Yahia ADWAN

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Dr. Öğr. Üyesi Mehmet ÖZTÜRK
2025, 88 Sayfa

Bu çalışma, total kalça protezli hastalarda ameliyat sonrası ve takip radyografilerinden aşınmanın yön ve büyüklüğünü tamamen otomatik ve kullanıcıdan bağımsız biçimde belirleyen bir ölçüm-raporlama çerçevesi sunar. Sistem, femoral baş ve asetabular yuva sınırlarını dairesel parametrelerle modeller; YOLOv5 tabanlı aday bölge üretimi sonrasında kenar tabanlı analiz, Hough-daire ve RANSAC uyumlama adımlarını ardışık biçimde çalıştırarak manuel işaretlemeye gerek kalmadan en uygun daireleri tespit eder. Böylece çekim koşullarındaki değişkenliklere karşı tekrarlanabilir sonuçlar elde edilir ve gözle fark edilmesi güç küçük değişimler dahi standart bir çıktı formatında sayısallaştırılır.

Tam otomatik akış, zaman maliyetini ve gözlemciler arası farklılığı belirgin biçimde azaltır. Ölçümlerin piksel tabanlı üretilip büyütme bilgisiyle mm'ye dönüştürülebilmesi, farklı çekimlerden gelen filmlerin güvenilir biçimde karşılaştırılmasını sağlar. Üretilen görseller ve sayısal tablolar, iki zaman noktasını tutarlı şekilde karşılaştırarak başta superior ve medial olmak üzere yönsel aşınma paternlerini açıkça ortaya koyar. Sonuç olarak önerilen sistem, rutin radyografilerle erken uyarı sağlayan, tam otomatik, hızlı ve standartlaştırılmış bir takip aracıdır.

Anahtar Kelimeler: Kalça protezi, aşınma, Ransac, YOLOv5, Tam otomatik, Ölçüm

MSc. Thesis

SUMMARY

DETECTION OF WEAR IN HIP PROSTHESES USING DEEP LEARNING

Yahia ADWAN

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering
Supervisor: Assist. Prof. Dr. Mehmet ÖZTÜRK
2025, 88 Pages

This study presents a fully automatic, user-independent measurement and reporting framework that determines the direction and magnitude of wear in total hip arthroplasty by comparing postoperative and follow-up radiographs. The system models the femoral head and acetabular cup with circular parameters; following YOLOv5-based region proposals, it runs edge-based analysis, Hough-circle detection, and RANSAC fitting in sequence to select the best circles without any manual annotation. This yields repeatable results despite variations in acquisition conditions and quantifies subtle changes in a standardized output format.

The fully automated pipeline markedly reduces time cost and inter-observer variability. Pixel-based measurements can be converted to millimeters using magnification information, enabling reliable comparison across different examinations. Produced overlay visuals and numeric tables consistently compare two time points, clearly exposing directional wear patterns most notably superior and medial. In sum, the proposed system provides an early-warning, fully automatic, fast, and standardized follow-up tool using routine radiographs.

Key Words: Hip prosthesis, wear, RANSAC, YOLOv5, fully automatic, Measurement

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Kalça Protezin komponenti	2
Şekil 2. Charnley Yöntemi.....	6
Şekil 3. Livermore Yöntemi	7
Şekil 4. Dorr and Wan Yöntemi	8
Şekil 5. Martell Yöntemi.....	9
Şekil 6. Sağ ve sol Kalça Protezleri.....	22
Şekil 7. Örnek Orijinal ve İyileştirilmiş Görüntü	25
Şekil 8. Etiketleme Süreci.....	27
Şekil 9. Femoral Etiketleme.....	28
Şekil 10. AY Etiketleme	29
Şekil 11. Ransac ve Hough Kullanarak Yanlış Tespitler.....	35
Şekil 12. Hibrit Yöntemin Akış Diyagramı.....	40
Şekil 13. YOLOv5 ile kalça protez bölgesinin otomatik lokalizasyonu.....	47
Şekil 14. Hibrit Yöntemiyle femoral ve AY tespitleri.....	48
Şekil 15. Kayıp Eğrileri.....	54
Şekil 16. mAP eğrisi.....	56
Şekil 17. Duyarlılık–Güven Eğrisi.....	57
Şekil 18. Femoral ve Yuva Merkez Doğruluk Eğrileri (piksel).....	58
Şekil 19. Femoral ve Yuva Yarıçap Doğruluk Eğrileri (piksel).....	59
Şekil 20. Femoral ve Yuva Merkez Doğruluk Eğrileri (normalize)	60
Şekil 21. Femoral ve Yuva Yarıçap Doğruluk Eğrileri (normalize).....	61
Şekil 22. YOLOv5 tabanlı ROI tespiti.....	63
Şekil 23. Farklı koşullarda Femoral ve AY tespitleri	64
Şekil 24. Düşük kontrastlı ve yuva üzerinde vidaların bulunduğu X-ışını görüntülerinde hatalı tespit örnekleri.....	65
Şekil 25. Hemen sonra ve sonra elde edilen görüntülerde femoral baş ve yuva tespitleri ve Aşınma 1. Örnek	67
Şekil 26. Hemen sonra ve sonra elde edilen görüntülerde femoral baş ve yuva tespitleri ve Aşınma 2. Örnek	68
Şekil 27. Hemen sonra ve sonra elde edilen görüntülerde femoral baş ve yuva tespitleri ve Aşınma 3. Örnek	70

TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Görsel Dağılımı ve Eğitim/Doğrulama/Test Ayrımı	23
Tablo 2. Pikselden Normalizeye dönüştürme	31
Tablo 3. Daire → Kutu Dönüşümü Örneği (520×622 görüntü)	33
Tablo 4. Eğitimde kullanılan stratejiler ve mantıkları	45
Tablo 5. Şekil 25 için Model tarafından otomatik hesaplanan ölçümler ve nihai aşınma	68
Tablo 6. Şekil 26 için Model tarafından otomatik hesaplanan ölçümler ve nihai aşınma	69
Tablo 7. Şekil 27 için Model tarafından otomatik hesaplanan ölçümler ve nihai aşınma	71
Tablo 8. Kalça protezi aşınma ölçümünde kullanılan yöntemlerin karşılaştırmalı özellikleri	77

SEMBOLLER VE KISALTMALAR DİZİNİ

AY	: Asetabular Yuva
TKA	: Total Kalça Artroplastisi
AP	: Ön-Arka Çekimi (Anteroposterior)
YZ	: Yapay Zekâ
DÖ	: Derin Öğrenme
ESA	: Evrişimli Sinir Ağları
mAP	: Genel Ortalama Kesinlik (mean Average Precision)
OK	: Ortalama Kesinlik
IoU	: Kesişim Oranı (Intersection over Union)
EHK	: Elektronik Hasta Kaydı
DICOM	: Tıpta Dijital Görüntüleme ve İletişim
2B	: 2 Boyutlu
3B	: 3 Boyutlu
MM	: Milimetre
ROI	: İlgi Bölgesi (Region of Interest)

1. GENEL BİLGİLER

1.1. Genel Tanıtım ve Problem Durum

Kalça eklemi, iskeletin en büyük ve en fazla yük taşıyan eklemlerindendir. Küresel yapı, femurun üst ucundaki femoral baş ile pelvisteki (leğen kemiğindeki) asetabulum arasında yer alır. Yarı küresel mimari üç düzlemde hareketi mümkün kılar ve günlük fonksiyonlar için kritiktir (Bowman, Fox & Sekiya, 2010). Bu sayede ayakta durma, yürüme, oturma ve merdiven inip-çıkma gibi temel aktiviteler ağrısız ve dengeli bir şekilde sürdürülebilir.

Kalça eklemi; dejeneratif hastalıklar, travmalar, iltihaplı romatizmal hastalıklar ve doğuştan sorunlar nedeniyle işlev kaybedebilir. Konservatif yöntemler yetersiz kaldığında kalıcı çözüm olarak total kalça artroplastisi (TKA) uygulanır (Varas-Montero ve ark., 2023). TKA'da hasarlı eklem çıkarılır; protez genellikle femoral stem, femoral baş ve asetabular yuva (AY) bileşenlerinden oluşur. Ameliyatın hedefi ağrıyı azaltmak, eklem fonksiyonunu geri kazandırmak ve hastanın günlük yaşam aktivitelerine güvenli dönüşünü sağlamaktır.

Protezlerin uzun dönem başarısını malzeme, cerrahi uygulama, yaş, aktivite ve kilo gibi etkenler etkiler. Uzun vadeli başlıca sorunlardan biri mekanik aşınma olup klinikte revizyona yol açabilir. Aşınma ile ortaya çıkan mikro parçacıklar dokuda inflamatuvar yanıtı tetikleyerek osteolize ve zamanla gevşemeye neden olabilir (Clohisy ve ark., 2024). Hücresel düzeyde makrofaj yanıtı ve osteoklast aktivasyonu bu süreçte belirgindir. İlerlemiş olgularda ağrı ve fonksiyon kaybı artabilir ve revizyon gerekebilir (Patel ve ark., 2023). Bu nedenle erken dönemde güvenilir ölçüm ve düzenli takip, ilerleyen komplikasyonların önüne geçmek için kritik önem taşır.


Küresel ölçekte TKA sayılarında önümüzdeki yıllarda belirgin artış öngörülmektedir (Pabinger ve ark., 2015). Bu eğilim, protezlerin uzun dönem takibini daha önemli hâle getirir (Søballe ve ark., 2022). Radyografiler üzerinden manuel ölçümler küçük aşınmaları yakalamada sınırlı olabilir. Gözlemciler arası ve gözlemci içi farklılıklar da ölçümlerin tutarlılığını etkileyebilir. Bu tablo, klinik kararları destekleyecek daha objektif ve tekrarlanabilir yöntemlere olan ihtiyacı ortaya koymaktadır.

Bu sınırlamaları aşmak için görüntü işleme ve yapay zekâ (YZ) tabanlı yaklaşımlar daha hızlı, nesnel ve tekrarlanabilir değerlendirme imkânı sağlar. Derin öğrenme (DÖ),

medikal görüntülerde femoral baş ve AY gibi yapıları otomatik olarak tanımlayabilir. Klinik iş akışında YZ, tanısal performansı iyileştirme ve iş yükünü yönetme açısından katkı sunabilir. Özellikle kalça eklem merkezinin otomatik belirlenmesinde klinikle uyumlu doğruluklar raporlanmıştır. Böylece hem izlem hem de olası revizyon zamanlaması için daha güvenilir, sayısal temelli bir çerçeve oluşturulabilir.

1.2. Kalça Protezlerinin Yapısı ve Malzemeleri

TKA, doğal kalça eklemine yapay bir protez ile değiştirilmesini içeren cerrahi bir işlemdir. Bu işlemde, femur kemiğinin üst ucu ile pelvis kemiğindeki asetabulum adı verilen çukur yapının bir kısmı çıkarılır ve yerlerine yapay bileşenler yerleştirilir (Galmiche ve ark., 2020). Kalça protezleri, temel olarak üç ana bileşenden oluşur: femoral komponent (femoral sap ve baş), asetabular komponent “AY ve liner” ve ara yüzey (Morano ve ark., 2025). Bu bileşenlerin tasarımı, yerleştirme şekli ve kullanılan malzemeleri, protezin dayanıklılığını, biyolojik uyumunu ve uzun ömürlülüğünü doğrudan etkiler.



Şekil 1. Kalça Protezin komponenti

Şekil 1’de bir kalça protezin bileşenleri gösterilmektedir. Şekilde, modüler bir kalça protezi tasarımı ve buna ait parçalar ayrıntılı biçimde sunulmuştur. Femoral sap, femoral baş ve AY detaylı olarak gösterilmiştir. Şeklin sağ tarafında ise proteze ait radyografik görüntü yer almaktadır. Sarı çizgiler, radyografik görüntü ile şematik bileşenler arasındaki karşılıkları ifade etmektedir.

Femoral komponent, genellikle metalden üretilen ve femur kemiği içerisine yerleştirilen bir sap ile onun ucuna bağlanan küresel bir baş kısımdan oluşur. Femoral baş,

doğal kalça başının yerini alarak asetabulum içinde hareket eder. Bu baş kısmı genellikle metal alaşımlarından (örneğin kobalt-krom ya da titanyum alaşımları) veya seramik malzemelerden yapılır. Seramikler, özellikle düşük sürtünme katsayısına ve yüksek aşınma direncine sahip olmaları nedeniyle tercih edilir. Ayrıca, biyouyumlu yapıları sayesinde vücutta alerjik veya toksik reaksiyon oluşturma riskleri düşüktür (Williamsima, 2024).

AY, pelvis kemiğine sabitlenen bir yarım küre şeklindeki kabuktan ve bu kabuk içine oturtulan bir “liner” tabakadan oluşur. AY, genellikle titanyum gibi hafif ve dayanıklı metal alaşımlarından imal edilir. Liner tabakası ise femoral baş ile temas eden yüzeydir ve bu yüzden en fazla aşınmaya maruz kalan parçadır. Geleneksel olarak liner’lar, yüksek molekül ağırlıklı polietilen malzemeden üretilir. Polietilen liner’lar, düşük maliyetleri ve yeterli mekanik özellikleri sayesinde uzun yıllardır kullanılmaktadır. Ancak bu malzeme zamanla mikropartikül yayılımına neden olabileceği için osteoliz gibi istenmeyen durumlara yol açabilmektedir (Kurtz, Gawel & Patel, 2011).

Aşınma direncini iyileştirme ve osteoliz oluşumunu minimize etme ihtiyacı, son yıllarda çapraz bağlı ve E vitamini ile stabilize edilmiş polietilen gibi yenilikçi malzemelerin geliştirilmesine öncülük etmiştir. Bu malzemeler, klasik polietilene kıyasla çok daha düşük aşınma oranlarına sahiptir (Callaghan ve ark., 2016; Vasan ve ark., 2021). Ayrıca, biyolojik olarak daha stabil oldukları için uzun vadede daha az inflamasyon ve kemik kaybına neden olurlar. Bu durum, protezin kullanım ömrünü önemli ölçüde uzatmaktadır (Leta ve ark., 2023; Gürsel, 2023).

Kalça protezlerinde metal-metal, metal-polietilen veya seramik-seramik yüzey eşleşmeleri kullanılır. Her kombinasyonun kendine özgü avantajları ve dezavantajları vardır. Örneğin, metal-metal yüzeyler düşük aşınma potansiyeline karşın metal iyon salınımı nedeniyle sistemik komplikasyon riski taşır ve günümüzde daha az tercih edilmektedir. Seramik-seramik yüzeyler ise yüksek biyouyumluluk ve minimal aşınma özellikleri ile dikkat çeker, ancak kırılabilirlik nedeniyle cerrahi yerleştirmede özen gerektirir (Garofalo ve ark., 2025; Gorter ve ark., 2021). Ayrıca, metal protezlerin seramik kaplanması ile aşınma direncinde artış rapor edilmiştir (Karaoğlu ve ark., 2017).

Sonuç olarak, kalça protezlerinin yapısı ve kullanılan malzemeler, protezin işlevselliği, ömrü ve hasta konforu açısından kritik öneme sahiptir. Bu yapıların zamanla gösterdiği fiziksel değişimler özellikle aşınma hem protezin performansını düşürmekte hem de revizyon cerrahilerini kaçınılmaz hâle getirmektedir. Dolayısıyla, bu bileşenlerin yapısını doğru bir şekilde modellemek ve görüntüler üzerinde hassas biçimde tespit edebilmek,

aşınmanın değerlendirilmesi ve klinik karar verme süreçleri için büyük önem taşımaktadır. Bu bağlamda, protez bileşenlerinin dairesel yapıları, bilgisayarlı görüntü işleme ve DÖ yaklaşımlarıyla analiz edilerek otomatik ölçüm süreçlerine katkı sunabilir.

1.3. Aşınma Tespiti ve Önemi

TKA, ileri evre kireçlenme, travma sonrası kalça bozuklukları, femur boyun kırıkları, avasküler nekroz ve doğuştan gelen kalça çıkığı gibi birçok sorunun cerrahi tedavisinde yaygın olarak kullanılan başarılı bir yöntemdir (Johnson ve Souder, 2023). Bu işlemde, hasarlı doğal kalça eklemi çıkarılarak yerine biyouyumlu yapay parçalar yerleştirilir. Uyluk kemiğine takılan femoral stem ve baş ile pelvisin içine oturan AY, birlikte yapay bir eklem oluşturur. Bu protez parçalarının vücutla uyumlu şekilde uzun yıllar çalışması beklenir.

Ancak protezin ömrünü en çok etkileyen faktörlerden biri zamanla ortaya çıkan aşınmadır. Özellikle femoral baş ile AY arasındaki polietilen yüzeyde sürekli sürtünmeden kaynaklanan aşınma, küçük parçacıkların kopmasına yol açar. Bu parçacıklar zamanla kemik dokusunda zayıflamaya, protezin gevşemesine ve hastada ağrı ile yürüme zorluğu gibi şikâyetlere sebep olabilir (HSS, 2024; Kuru ve ark., 2021; Bae ve ark., 2022). İlerlemiş vakalarda ise tek çözüm protezin yenilenmesi, yani revizyon cerrahisidir; bu da hem maliyeti yüksek hem de iyileşme süresi uzun bir uygulamadır (HSS, 2024).

Aşınmanın erken ve doğru şekilde tespit edilmesi hem protezin ömrünü uzatmak hem de hasta sağlığını korumak açısından kritik öneme sahiptir. Ancak aşınma genellikle mikroskobik düzeyde başlar ve yıllar içinde ilerler; bu yüzden yalnızca muayene ya da şikâyetlerle anlaşılması çoğu zaman mümkün değildir. Bu noktada röntgen (X-ışını) görüntüleri, aşınmayı izlemek için en çok kullanılan ve ekonomik yöntem olarak öne çıkar (Köken ve Kara, 2021). Femoral başın AY içinde zamanla yer değiştirmesi, aşınmanın güvenilir göstergelerinden biri kabul edilir (Köken ve Kara, 2021), bu yer değiştirme genellikle başın yukarı (superior) ve/veya yana (medial) kayması şeklinde olur. Femoral başın merkezindeki bu kayma, iki farklı zamanda çekilen röntgenler karşılaştırılarak veya tek bir görüntü üzerinde geometrik analizlerle ölçülebilir (Wu ve ark., 2021). Böylece aşınmanın sadece varlığı değil, miktarı ve yönü de belirlenebilir. Bu veriler, protezlerin dayanıklılığını değerlendirmek, kullanılan malzemeleri karşılaştırmak, cerrahi yöntemlerin etkinliğini görmek ve yeni implant tasarımlarını test etmek için önemli bir kaynak oluşturur (Rahman, Cobb ve Muirhead-Allwood, 2012).

Sonuç olarak, kalça protezlerinde aşınmanın doğru ve hızlı ölçülmesi hem hasta sağlığı hem de bilimsel çalışmalar açısından büyük önem taşır. Görüntüleme tekniklerinin gelişen teknolojiyle birleşmesi, aşınmanın erken tanısı ve doğru tedavi planlaması için artık vazgeçilmezdir. Bu bağlamda, klasik yöntemlerin ötesine geçen görüntü işleme teknikleri ve YZ tabanlı yaklaşımlar, bu alandaki en güncel yenilikleri oluşturmaktadır (Reddy ve ark., 2023).

Bugüne kadar birçok ölçüm yöntemi geliştirilmiştir. Bunlar arasında femoral baş ile AY arasındaki mesafelerin kıyaslanmasına dayanan Charnley, Livermore, Dorr & Wan, Martell ve Devane yöntemleri en bilinenleridir; her biri farklı matematiksel yaklaşımlar kullanır ve radyografik işaretlere göre hesaplama yapar (Rahman, Cobb ve Muirhead-Allwood, 2012). Bu yöntemler tez kapsamında ayrı ayrı incelenmiştir.

1.4. Klasik Radyografik Aşınma Yöntemleri

1.4.1 Radyografide Manuel Aşınma Ölçüm Yaklaşımları


Kalça protezlerinde aşınmayı belirlemek amacıyla uzun yıllar boyunca farklı manuel ölçüm yöntemleri kullanılmıştır (Mirza ve ark., 2010). Bunlar arasında Charnley, Livermore ve Dorr & Wan yöntemleri öne çıkan klasik yaklaşımlar olmuştur (Grillini & Affatato, 2013). Ortak noktaları, röntgen görüntüleri üzerinden yapılan ölçümlere dayanması ve aşınmayı dolaylı biçimde ortaya koymalarıdır. Ancak bu yöntemler, manuel işlem gerektirmeleri nedeniyle gözlemciye bağımlı, zaman alıcı ve hata payı yüksek yaklaşımlar olarak kabul edilmektedir (Mulcahy & Chew, 2012).

▪ Charnley Yöntemi

Charnley ve Cupic tarafından geliştirilen bu yöntem, tek bir AP (ön–arka) radyografi üzerinden aşınma miktarını ölçmeyi amaçlar. Femoral baş ile AY arasındaki üst ve alt mesafeler ölçülür ve bu mesafelerin farkı aşınma miktarı olarak kabul edilir (McCalden, 2005). Bu yöntemin avantajı basit olması ve ek ekipmana ihtiyaç duymamasıdır. Klinik ortamda düşük maliyetli ve hızlı bir değerlendirme aracı olarak uzun yıllar kullanılmıştır.

Sınırlamaları:

- Femoral baş ve asetabular kenarların manuel olarak belirlenmesi ölçüm sonuçlarını kullanıcıya bağımlı kılar (Min Lee ve ark., 2022).
- Pozisyon/projeksiyon farklılıkları küçük açısal sapmalarda dahi hataya neden olabilir (Schewelov ve ark., 2004).
- Büyütme faktörü çoğunlukla ihmal edilebilir ve bu da sistematik sapmaya yol açabilir (Wasim A. S. ve ark., 2023).



Şekil 2. Charnley Yöntemi


Şekil 2’de Charnley yöntemi gösterilmektedir. Femoral baş ile AY arasındaki mesafe, başın en çok aşınan üst (süperior) bölgesi ile aşınmamış alt (inferior) bölgesinde ölçülmektedir. Bu iki mesafe arasındaki fark, aşınma miktarı olarak hesaplanır. Yeşil çizgiler, süperior ve inferior mesafeleri göstermektedir. Bu örnekte, süperior mesafe inferior mesafeden daha kısa olduğu için, aradaki fark femoral başın polietilen içine ne kadar ilerlediğini temsil eder.

▪ Livermore Yöntemi

Livermore yöntemi, iki farklı tarihte çekilmiş AP röntgen üzerinden uygulanır; femoral başın geometrik merkezinin AY içindeki sabit referans noktasına göre yer değiştirmesi ölçülür, genellikle süperior ve medial yönde kayma incelenir. Yöntem, 2B düzlemde aşınma vektörünü verir ve doğruluğu artırmak için büyütme faktörü kullanır; ayrıca yıllık aşınma oranı gibi uzun dönem analizlere uygundur (Vanrusselt ve ark., 2015).

Sınırlamaları:

- Femoral baş merkezinin tespiti kullanıcıya bağlıdır (Stilling ve ark., 2010).
- Görüntü kalitesi düştüğünde daire merkezlerinin güvenilir belirlenmesi zorlaşır (Mirza ve ark., 2010).
- Rotasyonel bileşenleri değerlendiremez; 2B yaklaşım eksenler arası ayrımı sınırlı yansıtır (Vandenbussche ve ark., 2010).



Şekil 3. Livermore Yöntemi


Şekil 3'te, femoral başın merkezi ilk radyografideki (Ameliyattan hemen sonra) O (ilk) noktasından, takip görüntüsünde (Birkaç yıl sonraki görüntü) O (Son) noktasına kaymıştır. Son radyografide, femoral başın kenarı ile AY arasındaki mesafe, O noktasından polietilenin en ince olduğu bölgeye (A noktası) çizilen bir doğru boyunca ölçülür (A– A' mesafesi). Bu değer, aynı doğrultuda ilk radyografide ölçülen polietilen kalınlığından çıkarılır. Bu şekilde, gerçek aşınma miktarı belirlenmiş olur. Bu yöntem, aşınma vektörünün büyüklüğünü 2 boyutlu düzlemde hesaplar.

▪ Dorr & Wan Yöntemi

Bu yöntem, özellikle metal destekli AY için geliştirilmiştir. AP röntgende AY üst ve alt kenarlarıyla femoral baş kenarları arasındaki mesafeler ölçülür. Bu iki mesafe arasındaki farkın yarısı aşınma miktarını verir. Kullanımı kolaydır ve tek bir röntgen yeterlidir. Femoral başın süperior yöndeki yer değiştirmesini doğrudan verir (Stilling ve ark., 2010).

Sınırlamaları:

- Metalik kenarların görüntüde net görünmemesi hâlinde ölçüm kararsızlaşır (Grillini & Affatato, 2013).
- Açısal hatalara karşı duyarlıdır.
- Kullanıcılar arası uyumsuzluk görülebilir (Mulcahy & Chew, 2012).
- Büyütme ve kalibrasyon ihmal edildiğinde sapma artar (Wasim A. S. ve ark., 2023).



Şekil 4. Dorr and Wan Yöntemi


Şekil 4'te, tek bir (AP) radyografide AY süperior ve inferior kenarları arasında varsayımsal bir dikey çizgi (gri kesikli çizgi) çizilmiştir. Femoral başın üst kısmı ile yuvanın üst kenarı arasındaki mesafe (süperior mesafe) ve başın alt kısmı ile yuvanın alt kenarı arasındaki mesafe (inferior mesafe) ölçülür (pembe çizgiler). Bu iki mesafe arasındaki farkın yarısı, femoral baş merkezinin yer değiştirme miktarını gösterir. Büyütme faktörü uygulandığında gerçek aşınma değeri elde edilir. Bu yöntem yalnızca son radyografiyle uygulanabilir. Ancak, aşınmanın yalnızca dikey yönde gerçekleştiği varsayımına dayanır.

1.4.2. Bilgisayar Destekli Aşınma Ölçüm Yöntemleri

▪ Martell Yöntemi

Martell yöntemi, kalça protezlerindeki aşınmayı belirlemek için geliştirilen yarı otomatik bilgisayar destekli bir ölçüm tekniğidir (Martell ve ark., 2010). Bu yöntemde radyografilerde femoral baş ve AY sınırları kullanıcı tarafından manuel olarak işaretlenir. Yazılım, bu işaretlemelerden yola çıkarak ilgili merkez koordinatlarını ve çapları hesaplar. Daha sonra farklı zamanlarda elde edilen görüntüler karşılaştırılır ve femoral baş merkezindeki yer değişimi aşınma miktarı olarak kabul edilir.

Martell yönteminin temel sınırlılığı, tam otomatik olmamasıdır. Ölçüm süreci her seferinde kullanıcı müdahalesi gerektirir ve işaretleme sırasında yapılan küçük hatalar sonuçlarda değişkenliğe yol açabilir. Bu nedenle yöntemin tekrarlanabilirliği sınırlı, gözlemciye bağımlılığı ise yüksektir (Min Lee ve ark., 2022).



Şekil 5. Martell Yöntemi

Şekil 5, Martell'in bilgisayar destekli çift çember tekniğinin prensibini göstermektedir. Kırmızı çember femoral başı, mavi kesikli çember ise AY'in iç kenarını temsil eder. Yazılım, her iki bileşenin merkezlerini tespit eder ve başlangıç merkezinden takip merkezine olan vektörü (mor ok, "aşınma vektörü") hesaplar. Bu örnekte, femoral başın merkezi orijinal konumundan superior yönde kaymıştır. Bu yöntem, iki radyografi arasında femoral baş merkezinin yer değiştirmesini dijital olarak ölçerek aşınmayı belirler.

- Devane Yöntemi

Devane yöntemi, kalça protezlerinde aşınmayı daha kapsamlı değerlendirmek amacıyla geliştirilmiş bilgisayar destekli üç boyutlu bir yaklaşımdır (Devane ve ark., 2017). Bu yöntemde hastadan hem AP hem de yan (lateral) radyografiler alınır. Görüntüler özel yazılıma aktarılır ve iki projeksiyon birlikte analiz edilerek femoral başın üç eksenindeki (superior ve inferior, ön ve arka , medial ve yan) yer değişimi hesaplanır. Aşınma miktarı, bu eksenlerdeki kaymaların birleşik vektörü olarak yorumlanır.

Yöntem, üç boyutlu ölçüm avantajı sunmasına rağmen birtakım sınırlılıklara sahiptir. Görüntülerin hizalanmasında ortaya çıkabilecek küçük farklılıklar ölçüm doğruluğunu ciddi şekilde etkileyebilir. Ayrıca yazılımın karmaşık yapısı nedeniyle kullanıcıdan referans noktalarını manuel olarak seçmesi beklenir. Bu da yöntemin tam otomatik olmamasına yol açar. Klinik pratikte uygulanması zaman alıcıdır ve kullanıcıya bağımlılığı yüksektir (Vandenbussche ve ark., 2010).

1.5. İleri Görüntü İşleme ve Derin Öğrenme

1.5.1. Yapay Zekâ (YZ)

Bilgisayarların insan zekâsına benzer biçimde öğrenme, karar verme ve problem çözme gibi bilişsel görevleri yerine getirmesini sağlayan geniş yöntemler bütünüdür. Pek çok disiplinde, özellikle tıbbi görüntü analizinde kritik altyapıyı sunar (Cabitza ve ark., 2018; Romero-Jover ve ark., 2024). Hem kural tabanlı sistemleri hem de modern sinir ağlarını kapsar. Amaç, insan müdahalesi olmadan karmaşık veri örüntülerini anlamlı biçimde yorumlamaktır. DÖ gibi alt dallarla birlikte kullanıldığında daha güçlü ve esnek modeller ortaya çıkar (Erickson, 2020).

1.5.2. Makine Öğrenmesi

YZ'nin bir alt dalıdır ve bilgisayar sistemlerinin verilerden otomatik olarak öğrenip tahmin ve sınıflandırma yapmasına imkân tanır. Denetimli, denetimsiz ve pekiştirmeli öğrenme gibi farklı paradigmalara sahiptir. Özellikle sınıflandırma ve regresyon gibi görevlerde klinik karar verme süreçlerinde hayati bir yere sahiptir. Ayrıca, DÖ için temel kavramsal zemini oluşturur, klasik algoritmalarla karşılaştırıldığında daha veri odaklıdır (Aydın ve ark., 2023).

1.5.3. Derin Öğrenme (DÖ)

Makine öğrenmesinin çok katmanlı yapay sinir ağlarını kullanan gelişmiş biçimidir. Özellik çıkarımını otomatikleştirerek insan müdahalesine olan ihtiyacı azaltır. Görüntü işleme, doğal dil işlemede yüksek başarı sağlar. Büyük veri ve Grafik İşlem Birimi(Graphics Processing Unit _GPU) desteğiyle birlikte büyük veri setlerinde genelleme gücü artırılmış modeller oluşturur. Özellikle tıbbi görüntülerde, sınır tespiti, nesne tanıma ve ölçüm gibi zorlu görevlerde başarıya ulaşır (Litjens ve ark., 2017).

1.5.4. Evrişimli Sinir Ağları (Convolutional Neural Networks – ESA)

Evrişimli Sinir Ağları, özellikle görsel verilerin işlenmesi için geliştirilmiş DÖ mimarileridir. ESA'lar, klasik tam bağlı sinir ağlarından farklı olarak, görüntülerin iki boyutlu yapısını dikkate alır ve evrişim filtreleri ile pikseller arasındaki mekânsal ilişkileri öğrenir. Alt katmanlarda kenar, köşe ve doku gibi düşük seviyeli özellikler yakalanırken, daha üst katmanlarda nesne parçaları ve bütün yapılar gibi daha karmaşık temsiller çıkarılır. Katmanlı bu yapı sayesinde ESA'lar hem yerel hem de küresel özellikleri otomatik olarak öğrenebilir. Özellikle görüntü sınıflandırma, nesne tespiti ve segmentasyon gibi görevlerde yüksek doğruluk sağlaması nedeniyle yaygın olarak kullanılmaktadır. Tıbbi görüntüleme alanında ise kemik, organ ve implant sınırlarının otomatik tanımlanmasında en etkili yöntemlerden biri haline gelmiştir (Roldan ve ark., 2023).

1.5.5. YOLOv5 (You Only Look Once – v5 sürümü)

YOLO, tek adımda nesne tespiti yapan, ESA tabanlı modern bir mimaridir. YOLOv5 ise bu mimarinin geliştirilmiş sürümlerinden biridir ve yüksek hız ile doğruluğu bir arada sunar (Ultralytics, 2024). Geleneksel nesne tespit algoritmaları, önce olası bölgeleri çıkarıp sonra sınıflandırma yaparken, YOLOv5 tek bir ileri besleme adımında hem nesnenin konumunu (kapsayıcı kutu veya dairesel parametrik çıktı) hem de sınıfını tahmin eder. Bu özelliği sayesinde gerçek zamanlı uygulamalar için uygundur (Reddy ve ark., 2023). Modelin optimize edilmiş yapısı, veri artırma teknikleri, transfer öğrenme uyumluluğu ve hafif mimarisiyle farklı donanımlarda kolayca çalıştırılabilir. Tıbbi görüntü analizinde, femoral baş ve AY gibi yapıları doğrudan parametrelerle (x, y, r) modellemek üzere

uyarlanabilir; bu sayede klasik kutu tabanlı yöntemlere göre daha klinik odaklı sonuçlar sunar (Borjali ve ark., 2020).

1.5.6. Veri Artırma (Data Augmentation)

Mevcut eğitim verisini dönüşümlerle (örneğin döndürme, kesme, gürültü ekleme, kontrast/parlaklık değişimi) çeşitlendirerek modelin genelleme becerisini artırma yöntemidir. Özellikle tıbbi verinin sınırlı olduğu durumlarda aşırı uyumunu önlemek adına kritik bir role sahiptir. Modelin farklı şartlara karşı dayanımını artırır ve klinik varyasyonlara uyumu sağlar (Jang ve ark., 2022).

1.5.7. Normalizasyon

Verileri ortak bir ölçeğe (örneğin 0–1 aralığına) indirmek için kullanılan ön işleme adıdır. Görüntülerin boyutları ve piksel yapıları farklı olabileceği için, doğru karşılaştırma ve analiz açısından piksel yoğunluklarının aynı anlamı koruması önemlidir. Sinir ağlarında giriş dağılımlarını stabilize ederek öğrenmeyi hızlandırır ve daha tutarlı sonuçlar oluşturur. ESA modellerinde ve özellikle batch normalization ile birleştiğinde eğitim sürecini daha kararlı hale getirir.

1.5.8. Çift Taraflı Filtre (Bilateral)

Çift Taraflı Filtre, görüntüdeki gürültüyü azaltırken kenar bölgelerini korumayı amaçlayan bir yumuşatma yöntemidir. Gauss bulanıklaştırmadan farklı olarak, pikselleri sadece fiziksel yakınlığa göre değil, aynı zamanda parlaklık benzerliğine göre de değerlendirir. Bu sayede birbirine yakın fakat parlaklık farkı yüksek olan pikseller (örneğin kemik doku sınırı gibi) karışmaz ve kenarlar korunur. X-ray görüntülerinde bu yöntem, hem kontrastı düşük bölgelerdeki gürültüyü azaltır hem de kemik konturlarının netliğini koruyarak Canny gibi kenar bulucuların daha dengeli ve keskin sonuçlar üretmesini sağlar. Bu nedenle çalışmamızda sınırları daha doğal ve anlaşılır hale getirmek için kullanılmıştır.

1.5.9. Canny Kenar Algılama

Canny kenar algılama, günümüzde en yaygın kullanılan kenar belirleme algoritmalarından biridir ve çok aşamalı bir yapıya sahiptir. İlk adımda Gauss filtresi uygulanarak görüntüdeki gürültü azaltılır. Ardından, her piksel için gradyan büyüklüğü ve yönü hesaplanarak kenar adayları belirlenir. Daha sonra, komşu piksellerle karşılaştırma yapılarak yalnızca en güçlü kenarlar korunur ve kenar çizgileri tek piksel genişliğine indirgenir. Son aşamada, çift eşikleme yöntemi ile güçlü ve zayıf kenarlar ayrılır. Zayıf kenarlar yalnızca güçlü kenarlara bağlı olduklarında kabul edilir. Bu aşamalı yapı sayesinde Canny, doğru konumda, ince ve keskin kenarlar elde edilmesini sağlar. Gürültüye karşı dayanıklı olması ve sürekli kenarlar üretebilmesi nedeniyle tıbbi görüntülerde sınır belirleme ve ön işleme adımlarında sıkça tercih edilmektedir.

1.5.10. RANSAC (Rastgele Örnekleme ile Uyum Yaklaşımı)

RANSAC, aykırı (uç değer) veri noktalarının bulunduğu durumlarda sağlam model kestirimi yapmak için kullanılan rastgele örnekleme tabanlı bir algoritmadır. Her yinelemede küçük bir veri alt kümesi seçilir, bu alt kümeden model parametreleri tahmin edilir ve ardından geri kalan verilerin bu modele ne kadar uyum sağladığı kontrol edilir. En fazla uyum sağlayan (destekçi) noktaları içeren model en uygun çözüm olarak kabul edilir. Gürültülü ve karmaşık görüntülerde doğru ya da daire gibi geometrik yapıları belirlemek için sıkça kullanılır. Tıbbi görüntülerde protez sınırları gibi dairesel yapıları güvenilir şekilde çıkarmada etkili bir yöntemdir. Ancak hesaplama süresi, yineleme sayısına bağlı olarak artabilir.

1.5.11. Hough Dönüşümü

Hough dönüşümü, görüntüde belirli geometrik şekilleri (örneğin doğru, daire, elips) bulmak için kullanılan parametrik bir yöntemdir. Kenar noktaları, parametre uzayına dönüştürülerek hangi geometrik şekillere ait olabileceklerini işaretler. Bu işlem, her kenar noktasının olası şekillere katkı sağlaması şeklinde düşünülebilir. Parametre uzayında en fazla desteği alan değerler, görüntüdeki gerçek geometrik şekli temsil eder. Bu yaklaşım sayesinde eksik veya bozuk kenar bilgisi olsa dahi doğru şekiller tespit edilebilir. Ancak parametre uzayının boyutu büyüdükçe hesaplama maliyeti artar. Ayrıca, metalik parlama

veya düşük kontrast gibi sorunlar yanlış destek birikimlerine yol açabilir. Tıbbi görüntülerde daire veya elips benzeri implant sınırlarının bulunmasında denenmiş olsa da, yüksek gürültü koşullarında kararlılığı sınırlı kalmıştır.

1.5.12. Edge-Snap

Bu çalışmada kullanılan Edge-Snap yaklaşımı, modelin tahmin ettiği daire parametrelerinin kenar bilgisinden elde edilen enerji haritası ile uyumlu hâle getirilmesini sağlayan bir iyileştirme adımıdır. Yöntemde, tahmin edilen dairenin çevresindeki gradyan dağılımı incelenir ve yarıçap değeri, en yüksek kenar yanıtı veren bölgelerle hizalanacak şekilde yeniden düzenlenir. Böylece model tarafından üretilen daireler, görüntüdeki gerçek anatomik sınırlarla daha doğru örtüşür. Bu optimizasyon sayesinde düşük kontrast, gürültü veya yapısal bozulmaların bulunduğu medikal görüntülerde dahi tahminlerin güvenilirliği artar. Edge-Snap yaklaşımı, lokal kenar bilgilerini dikkate alarak global tahminleri düzeltmesi bakımından özgün ve tamamlayıcı bir katkı sunmaktadır.

1.5.13. Doğrulama (Validation)

Doğrulama, modelin eğitim sürecinde hiç görmediği ayrı bir veri kümesi üzerinde yapılan performans ölçümüdür. Eğitim sırasında yalnızca eğitim verisine bakıldığında modelin aşırı öğrenme yapıp yapmadığı anlaşılamaz. Bu nedenle doğrulama verisiyle düzenli olarak test yapılır. Doğrulama sonuçları, modelin yeni verilerde ne kadar genellebildiğini gösterir. Ayrıca hiperparametre ayarlarının (öğrenme oranı, epoch sayısı) yapılmasında ve erken durdurma kararlarında belirleyici rol oynar (Ultralytics, 2024b).

1.5.14. Erken Durdurma

Aşırı Öğrenmeyi önlemek için eğitim sırasında doğrulama performansı izlenerek kullanılan bir düzenleme tekniğidir. Model doğrulaması başarımlı belirli bir süre gelişmeyince eğitim durdurulur. Böylece model, genel verilere iyi genelleme yapacak noktada bırakılır ve gereksiz eğitim süresi engellenir (Al-Hassan ve ark., 2024).

1.5.15. Aşırı Öğrenme (Overfitting)

Modelin eğitim verisindeki gürültü ve rastgele paternlere aşırı uyum sağlayarak, yeni/verilmeyen verilerde başarısız olma eğilimidir. Eğitim performansı yüksek, doğrulama performansı düşükse tipik göstergesidir. Küçük veri setlerinde, karmaşık modellerde sık rastlanır. Erken durdurma, veri artırma, gibi tekniklerle önlenabilir.

1.5.16. Epoch

Tüm eğitim setinin model tarafından bir kez işlenmesidir. Birden fazla epoch sırasında eğitim ve doğrulama metrikleri izlenerek modelin öğrenme süreci değerlendirilir. Az epoch yetersiz öğrenme, çok fazlası Aşırı Öğrenme riski taşır. Minimum doğrulama kaybındaki epoch genellikle modelin en iyi olduğu noktadır (Núñez-Gil ve ark., 2024).

1.5.17. Batch Size (Toplu İş Boyutu)

Eğitim sırasında her seferinde modele beslenen örnek sayısıdır. Küçük batch boyutları daha gürültülü, fakat genelleme gücü yüksek gradyanlar sağlar. Büyük batch boyutları ise daha stabil ama bellek tüketimi yüksek güncellemeler sağlar. Tıbbi görüntüler yüksek çözünürlüklü olduğu için genelde daha küçük batch tercih etmek pratik olur (Gong ve ark., 2022).

1.5.18. Kayıp Fonksiyonu

Kayıp fonksiyonu, modelin ürettiği tahmin ile gerçek değer arasındaki farkı matematiksel olarak ölçen bir ifadedir. YZ modellerinin eğitimi, bu fonksiyonun değerini en aza indirmek üzerine kuruludur. Böylece model, her yinelemede daha doğru tahminler yapmayı öğrenir. Farklı problem türlerine göre farklı kayıp fonksiyonları tercih edilir. Sınıflandırma problemlerinde genellikle çapraz entropi fonksiyonu kullanılırken, regresyon problemlerinde ortalama karesel hata (Mean Squared Error) öne çıkar. Ortalama karesel hata, tahmin edilen değer ile gerçek değer arasındaki farkların karesinin alınarak ortalamasının hesaplanmasıyla elde edilir. Bu sayede küçük hatalarla birlikte büyük sapmalar da daha güçlü şekilde cezalandırılır. Tıbbi görüntü analizinde, sınıf dengesizliğinin yoğun olduğu durumlarda odaklanmış kayıp gibi özel fonksiyonlar kullanılabilir. Ayrıca

yalnızca eğitim kaybı değil, doğrulama kaybı da takip edilerek modelin aşırı öğrenme eğilimi kontrol edilir (Saccomanno ve ark., 2025).

1.5.19. Doğruluk (Accuracy)

Doğruluk, modelin yaptığı tüm tahminler içinde doğru olanların oranını gösteren en temel performans ölçütüdür. Yani doğru tahmin sayısının toplam tahmin sayısına bölünmesiyle elde edilir. Ancak bu ölçüt bazı durumlarda yanıltıcı olabilir.

Örneğin, 100 röntgen görüntüsünde her birinde femoral baş ve yuva olmak üzere toplam 200 daire işaretlenmiş olsun. Eğer model sadece femoral başları başarıyla tespit edip yuvaları hiç bulamazsa, 100 doğru tahmin yaptığı için doğruluk %50 çıkar. Bu rakam ilk bakışta “kısmen başarılı” gibi görünebilir, fakat gerçekte modelin yuvaları tanıma başarısı tamamen sıfırdır.

Dolayısıyla doğruluk tek başına yeterli değildir. Modelin hangi yapıları kaçırdığını anlamak için kesinlik ve duyarlılık gibi ek ölçütlerle birlikte değerlendirilmesi gerekir (Saito & Rehmsmeier., 2015).

1.5.20. Kesinlik (Precision)

Kesinlik, modelin “bulduğunu” söylediği yapılar arasında gerçekten doğru olanların oranını gösterir. Yani yanlış alarmı (yanlış pozitif) azaltma gücünü ölçer.

Örnek: 100 röntgende 100 femoral baş var. Model 110 femoral baş tahmini yapmış, bunların 90’ı doğru, 20’si yanlış ise:

$$Kesinlik = \frac{90}{(90 + 20)} = \frac{90}{110} = 0.818 \approx \%81.8 \quad (1)$$

Bu durumda model çoğunlukla doğru işaretlemiş olsa da, fazladan çizdiği 20 yanlış daire kesinliği düşürmüştür. Klinik açıdan bu, gerçekte yuva olmayan bir bölgeye yuva çizilmesi gibi hataları temsil eder (Rouzrokh ve ark., 2022).

1.5.21. Duyarlılık (Recall)

Duyarlılık, gerçekte var olan yapılar arasında modelin ne kadarını yakaladığını gösterir. Yani kaçırmama (yanlış negatifleri azaltma) gücünü ölçer.

Örnek: 100 görüntüde 100 yuva olsun. Model bunların 85'ini doğru bulmuş, 15'ini hiç bulamamışsa:

$$Duyarlılık = \frac{85}{(85 + 15)} = \frac{85}{100} = 0.85 = \%85 \quad (2)$$

Bu, modelin 15 yuvayı tamamen gözden kaçırdığı anlamına gelir. Klinik olarak, duyarlılığın düşük olması “protez aşınması olan vakaların atlanması” gibi kritik sorunlara yol açabilir (Zogg ve ark., 2022).

1.5.22. Kesişim Oranı (Intersection over Union – IoU)

IoU, tahmin edilen daire ile gerçek dairenin ne kadar örtüştüğünü gösterir. Tahmin ve gerçek alanın kesişiminin, birleşime oranı alınarak hesaplanır.

Örnek: Femoral başın gerçek dairesi ile tahmin edilen daire %70 örtüşüyorsa:

$$IoU = 0.70 \quad (3)$$

Uygulamada genellikle $IoU \geq 0,50$ başarılı kabul edilir (Ultralytics, 2024). Ancak klinik hassasiyet gerektiren durumlarda bu eşik 0,65 veya daha yukarı seçilebilir. Yüksek IoU, modelin hem konum hem de yarıçap tahminini doğru yaptığını gösterir.

1.5.23. Genel Ortalama Kesinlik (mean Average Precision – mAP)

Nesne tespiti modellerinin genel başarısını özetleyen ölçüttür. Keskinlik ve Duyarlılık ilişkisini gösteren eğrilerden elde edilen Ortalama Kesinlik (OK) değerlerinin tüm sınıflar (femoral baş ve yuva) üzerindeki ortalamasıdır.

Örnek:

- Femoral baş için OK = 0,90

- Yuva için OK = 0,85

$$mAP = \frac{(0.90 + 0.85)}{2} = \frac{1.75}{2} = 0.875 \quad (4)$$

Bu durumda modelin genel başarısı %87,5'tir. Ayrıca farklı IoU eşiklerinde hesaplanan mAP değerleri de raporlanabilir.

1.6. Bu Tezin Amacı ve Katkısı

Bu çalışmanın literatüre sunduğu temel yenilik, kalça protezinin ana bileşenleri olan femoral baş ve AY'nın konumlarını tam otomatik olarak tespit eden YZ ve DÖ tabanlı bir sistem geliştirmektir. Geliştirilen bu sistem sayesinde, bileşenlerin zaman içerisindeki konumsal değişimleri literatürdeki mevcut yöntemler kullanılarak analiz edilmekte ve böylece aşınma miktarı doğru ve tekrarlanabilir bir şekilde hesaplanmaktadır. Geleneksel yöntemlerin manuel ölçüme dayalı sınırlılıklarını aşmak amacıyla, bu tezde insan gözlemine bağımlı olmayan, klinik kullanım açısından uygulanabilir ve yüksek doğruluk sağlayan bir yaklaşım ortaya konmuştur.

Çalışmada geliştirilen sistem, X-ışını görüntülerinden femoral baş ve AY sınırlarını daire olarak modelleme prensibine dayanır. DÖ modeli, bu dairelerin merkez koordinatları ve yarıçaplarını tahmin eder. Ardından iki farklı zamanda elde edilen radyografiler karşılaştırılarak femoral başın AY içerisindeki yer değişimi hesaplanır. Böylece aşınmanın miktarı ve yönü sayısal olarak belirlenir. Bu yaklaşım, femoral başın polietilen tabaka içinde yıllar içinde gerçekleşen mikroskobik düzeydeki hareketlerini doğrudan ölçülebilir hâle getirmiştir.

Sistemin geliştirilme sürecinde yalnızca hazır araçlar kullanılmamış, bunun yerine Python tabanlı özel bir etiketleme arayüzü oluşturulmuştur. Bu araçla 50 X-ışını görüntüsü elle işaretlenmiş, her birine karşılık gelen çember parametrelerini (x, y, r) içeren .txt dosyaları üretilmiştir. Bu veriler, YOLOv5 mimarisi ve özel hibrit algoritmalar (edge-snap, kenar sinyali analizi, RANSAC uyumlama ve anatomik kurallar) ile birlikte kullanılarak modelin hem eğitiminde hem de aşınma ölçümünde işlenmiştir.

Tezin özgün katkıları şu şekilde özetlenebilir:

- Klasik kenar tespiti, Hough dönüşümü gibi yöntemlerin ötesine geçilerek, DÖ tabanlı doğrudan daire parametresi tahmini başarıyla uygulanmıştır.
- Literatürde sınırlı sayıda bulunan daire tabanlı tıbbi ölçüm modellerine katkı sağlanmış, femoral baş ve AY merkezlerinin otomatik tespiti yoluyla protez aşınmasının ölçümüne yönelik yeni bir uygulama geliştirilmiştir.
- Hibrit bir yöntem (YOLOv5 tespiti + kenar sinyali analizi + RANSAC + anatomik kısıtlar) önerilerek, düşük kontrastlı ve vidalı protezlerde dahi yüksek doğruluk sağlanmıştır.
- Kullanıcı bağımlılığı minimize edilerek gözlemciler arası farklılıklar ortadan kaldırılmış, böylece klinik karar destek sistemlerinin güvenilirliği artırılmıştır.
- YOLOv5'in sağladığı güçlü nesne tespiti altyapısı, doğrudan (x, y, r) regresyon çıktıları ile femoral baş-AY ilişkisinin modellenmesine uyarlanmış, bu da literatüre özgün bir katkı olarak sunulmuştur.

Sonuç olarak, bu tez çalışması hem görüntü işleme hem de DÖ alanlarını birleştiren disiplinler arası bir yaklaşım ortaya koymakta, ortopedik cerrahi sonrası hasta takibinde kullanılabilecek yeni nesil teknolojilere katkı sağlamaktadır.

1.7. Tezin Kapsamı ve Organizasyonu

Bu tez çalışması, kalça protezi yerleştirilmiş hastalara ait X-ışını görüntüler üzerinden femoral baş ve AY'nin konumsal ilişkilerini analiz ederek aşınma miktarını tam otomatik biçimde belirlemeyi amaçlamaktadır. Tezin ana hedefi, geleneksel yöntemlerin manuel ölçüme dayalı sınırlılıklarını aşan, kullanıcı bağımsız, sayısal ve tekrarlanabilir sonuçlar sunabilen modern bir DÖ tabanlı sistem ortaya koymaktır.

Çalışmanın kapsamı üç ana aşamadan oluşmaktadır. İlk aşamada, kalça protezi anatomisi ve protez aşınmasının klinik önemi literatür ışığında ele alınmış, bu alanda yaygın kullanılan geleneksel yöntemler (örneğin Charnley, Livermore, Dorr & Wan, Martell ve Devane) incelenmiş ve sınırlılıkları tartışılmıştır. İkinci aşamada, klasik görüntü işleme algoritmaları (Canny kenar tespiti, RANSAC tabanlı çember uyumlama, Hough dönüşümü) uygulanmış ve medikal görüntülerdeki düşük kontrast, gürültü ve yapısal bozulmalar nedeniyle yeterli başarı sağlamadıkları deneysel olarak gösterilmiştir. Üçüncü aşamada ise, YZ ve DÖ tabanlı bir yöntem geliştirilmiştir. Bu kapsamda, Python diliyle oluşturulan özel

bir iřaretleme aracı sayesinde 50 radyografi dairesel parametreler (x, y, r) ile etiketlenmiř, YOLOv5 tabanlı özel bir regresyon modeli eđitilmiř ve iki zamanlı g r nt ler arasındaki konumsal deđiřimler otomatik olarak hesaplanmıřtır.

Bu metodoloji sayesinde klinik ortamlarda uzman m dahalesi gerektirmeden, dođrudan radyolojik verilerden g venilir ařınma  l  mleri yapılabilen bir sistem geliřtirilmiřtir. Ayrıca  nerilen yaklařım, literat rde yaygın kullanılan y ntemlerle karřılařtırılmıř ve kullanıcı bađımsızlıđı ile dođruluk a ısından  st n y nleri ortaya konmuřtur.

Bu tez  alıřması altı ana b l mden oluřmaktadır:

- B l m 1 – Genel Bilgiler: Kal a protezleri, ařınmanın klinik  nemi ve bu alanda kullanılan geleneksel  l  m y ntemleri ele alınmıřtır. Ayrıca  alıřmanın amacı ve katkısı bu b l mde a ıklanmıřtır.
- B l m 2 – Yapılan  alıřmalar:  alıřmada izlenen metodoloji sunulmuřtur.  ncelikle klasik g r nt  iřleme y ntemleri (Canny, RANSAC, Hough) test edilmiř, ardından D  tabanlı hibrit yaklařım geliřtirilmiř ve kullanılan veri seti ile etiketleme s reci detaylandırılmıřtır.
- B l m 3 – Bulgular: Eđitilen modelin  ıktıları, femoral bař ve AY tespit performansı, ařınma analizleri ve farklı kořullardaki dođruluk deđerlendirmeleri verilmiřtir.
- B l m 4 – Tartıřma: Elde edilen sonu lar literat rdeki y ntemlerle karřılařtırılmıř, avantajlar ve sınırlılıklar tartıřılmıřtır.
- B l m 5 – Sonu lar: Tez kapsamında ulařılan temel bulgular  zetlenmiřtir.
- B l m 6 –  neriler: Gelecekte yapılabilen  alıřmalar ve sistemin geliřtirilmesine y nelik  neriler sunulmuřtur.

2. YAPILAN ÇALIŞMALAR

2.1. Veri Seti Hazırlığı

Bu çalışmada kullanılan veri seti, kalça protezi bulunan hastalara ait iki boyutlu (2B) X-Işını görüntülerinden oluşturulmuştur. Veri seti hazırlanırken hem klinik kaynaktan sağlanan gerçek hasta verileri hem de çeşitli medikal platformlardan indirilen açık erişimli görüntüler kullanılmıştır. Böylece farklı çekim cihazları ve koşullarından kaynaklanabilecek varyasyonların modele aktarılması ve algoritmanın daha genelleyici bir şekilde öğrenmesi amaçlanmıştır. Veri hazırlık süreci dört temel adımda ele alınmıştır. Bunlar sırasıyla görsel kaynakların belirlenmesi, görsel sayısı ve dağılımının incelenmesi, eğitim/doğrulama/test ayrımı ve ön işleme adımlarıdır.

2.1.1. Görsel Kaynakları

Veri seti iki ana kaynaktan elde edilmiştir:

Klinik Kaynak: Trabzon Farabi Hastanesi'nde görev yapan bir ortopedi uzmanı, araştırmamız kapsamında belirli sayıda kalça protezi içeren X-Işını görüntüsü sağlamıştır. Bu görüntüler, doğrudan klinik uygulamada kullanılan cihazlardan elde edildiği için çalışmaya yüksek klinik geçerlilik kazandırmıştır.

Açık Erişim Kaynakları: Çeşitli medikal veri paylaşım sitelerinden kalça protezi bulunan X- Işını görüntüleri indirilmiştir. Bu verilerde herhangi bir hasta kimliği veya kişisel bilgi yer almamakta, yalnızca radyografik içerik kullanılmaktadır. Bu durum hem veri güvenliği hem de araştırma etiği açısından önemlidir.

Sonuç olarak, veri seti hem gerçek klinik örnekleri hem de açık kaynaklı dijital verileri kapsayan karma bir yapıdadır. Bu çeşitlilik, çalışmanın sonuçlarının hem bilimsel hem de pratik açıdan daha güçlü olmasını sağlamaktadır.



Şekil 6. Sağ ve sol Kalça Protezleri

Şekil 6'da çalışmada kullanılan görüntülere ait iki örnek gösterilmiştir, soldaki görüntü sağ kalça protezini, sağdaki ise sol kalça protezini göstermektedir.

2.1.2. Görsel Sayısı ve Dağılımı

Çalışmada toplamda 50 adet kalça protezi içeren X- Işını görüntüsü değerlendirilmiştir. Her bir görüntüde hem femoral baş hem de AY net olarak görülebildiğinden, her görselde iki farklı yapı işlenmiştir. Böylece toplamda 50 femoral baş ve 50 AY olmak üzere 100 anotasyon elde edilmiştir.

Etiketleme sürecinde:

- Femoral Baş (Sınıf 0): Protezin yuvarlak femoral bileşeni dairesel olarak işaretlenmiştir.
- AY (Sınıf 1): Protezin asetabular bölgesini temsil eden dairesel yapı belirlenmiştir.

Bu dağılım, her bir görüntüde iki temel yapının eşit şekilde temsil edilmesini sağlamış ve modelin her iki sınıfı dengeli bir biçimde öğrenmesine katkıda bulunmuştur. Böylece geliştirilen sistemin daire tespiti performansı daha güvenilir sonuçlar üretmiştir.

2.1.3. Eğitim/Doğrulama/Test Ayrımı

Veri setinin sınırlı büyüklüğü nedeniyle (toplam 50 görüntü), eğitim sürecinde kullanılacak alt kümelerin titizlikle belirlenmesi gerekmiştir. Çalışmada, veri setinin genelleme başarısını artırmak ve modelin aşırı uyum riskini azaltmak amacıyla üçlü ayırım stratejisi benimsenmiştir.

- Eğitim Seti: Veri setinin yaklaşık %70'ini (35 görüntü) oluşturan bu bölüm, modelin parametrelerinin güncellenmesinde kullanılmıştır. Eğitim setindeki çeşitlilik, modelin farklı anatomik varyasyonları öğrenmesi açısından önem taşımaktadır.
- Doğrulama Seti: Görsellerin yaklaşık %15'i (7-8 görüntü) doğrulama amacıyla ayrılmıştır. Bu küme, eğitim süreci boyunca modelin geçici performansını izlemek ve hiperparametrelerin optimize edilmesini sağlamak için değerlendirilmiştir.
- Test Seti: Kalan %15'lik bölüm (7-8 görüntü), eğitim sürecine hiçbir şekilde dahil edilmemiş ve yalnızca nihai aşamada modelin bağımsız performansını değerlendirmek için kullanılmıştır. Bu sayede modelin gerçek dünyadaki başarımı daha tarafsız biçimde ölçülmüştür.

Tablo 1. Görsel Dağılımı ve Eğitim/Doğrulama/Test Ayrımı

Özellik	Sayı	Oran (%)	Açıklama
Toplam X- Işını Görüntüsü	50	100	Çalışmada kullanılan tüm görüntüler
Femoral Baş Anotasyonu (Sınıf 0)	50	50	Her görüntüde 1 adet
AY Anotasyonu (Sınıf 1)	50	50	Her görüntüde 1 adet
Toplam Anotasyon	100	100	İki sınıf birlikte
Eğitim Seti	35	%70	Modelin öğrenme süreci
Doğrulama Seti	7-8	%15	Eğitim sırasında performans takibi
Test Seti	7-8	%15	Nihai performans ölçümü

Tablo 1'deki değerlere göre, çalışma toplam 50 X-ışını görüntüsünden oluşmaktadır. Her görüntüde 1 femoral baş (Sınıf 0) ve 1 AY (Sınıf 1) anotasyonu bulunduğundan toplam anotasyon sayısı 100'dür. Veri kümesi, model geliştirme süreci doğrultusunda %70 eğitim (35 görüntü), %15 doğrulama (7-8 görüntü) ve %15 test (7-8 görüntü) olarak ayrılmıştır; %15'lik pay tam sayıya yuvarlandığı için doğrulama ve test setleri 7-8 aralığında planlanmıştır.

Önemli not: Bu sayılar veri artırma uygulanmamış, özgün veri kümesini göstermektedir. Eğitim sırasında kullanılan efektif örnek sayısı, uygulanan artırma işlemleriyle (ör. dönüş, ölçekleme, kontrast değişimi vb.) artırılmıştır; ancak Tablo 1 yalnızca ham (orijinal) görüntülerin dağılımını raporlamaktadır

2.1.4. Ön İşleme Adımları

Modelin eğitimi için kullanılan X- Işını görüntülerinin farklı kaynaklardan elde edilmiş olması, çözünürlük, kontrast ve gürültü açısından çeşitlilik göstermesine yol açmıştır. Bu nedenle, verilerin ortak bir formata getirilmesi ve modelin daha sağlıklı öğrenebilmesi için bir dizi ön işleme adımı uygulanmıştır.

- Griye Çevirme

Bazı görüntüler RGB formatında kaydedilmiş olsa da X- Işını görüntüler doğası gereği tek kanallı gri seviyelerle temsil edilir. Bu nedenle tüm görüntüler gri tonlamaya dönüştürülerek standart hale getirilmiştir. Bu işlem, hesaplama yükünü azaltmış ve yapısal detayların korunmasına katkı sağlamıştır.

- Kontrast İyileştirme

Radyografilerde sıkça karşılaşılan düşük kontrast problemini gidermek için CLAHE yöntemi kullanılmıştır. Bu teknik, özellikle femoral baş ve AY sınırlarının daha belirgin hale gelmesini sağlamış, aşırı koyu ya da açık bölgelerdeki detay kayıplarını azaltmıştır.

- Gürültü Azaltma

Bazı görüntülerde protez çevresinde metalik vidaların sebep olduğu parazitler gözlenmiştir. Bu nedenle, kenar yapılarını koruyarak homojen bölgelerdeki rastgele gürültüyü azaltan çift taraflı(bilateral) filtreleme uygulanmıştır. Böylece modelin eğitiminde yanlış kenar tespitlerinin önüne geçilmiştir.


- Keskinleştirme

Kenarlardaki geçişlerin daha belirgin hale gelmesi için keskinleştirme filtresi uygulanmıştır. Bu sayede dairesel yapıların sınırları daha netleşmiş ve hem eğitim sırasında hem de geleneksel yöntemlerle yapılan hibrit işlemlerde doğruluk artırılmıştır.

- Yeniden Boyutlandırma (Resize)

DÖ tabanlı YOLOv5 modeli sabit boyutlu giriş görüntüleri ile çalışmaktadır. Bu nedenle tüm X- Işını görüntüleri, eğitim sürecinde tutarlılık sağlamak amacıyla 640×640 piksel çözünürlüğe yeniden boyutlandırılmıştır.

Yeniden boyutlandırma sırasında görüntülerin orijinal en ve boy oranı korunmuş, gerekli durumlarda boşluk kalan kısımlar kenar doldurma yöntemiyle tamamlanmıştır. Bu sayede görüntüdeki dairesel yapılar (femoral baş ve AY) geometrik olarak bozulmadan modele aktarılmıştır.



Şekil 7. Örnek Orijinal ve İyileştirilmiş Görüntüler

2.2. Etiketleme Süreci

Bu çalışmada, femoral baş ve AY yapılarının dairesel parametrelerle (x, y, r) işaretlenmesi için Python tabanlı özel bir işaretleme aracı geliştirilmiştir. Etiketleme süreci, daha sonraki model eğitim aşamalarının temelini oluşturduğu için titizlikle yürütülmüş ve belirli kurallar çerçevesinde standardize edilmiştir.

2.2.1. Python İşaretleme Aracı

Etiketleme işlemi, Çalışma kapsamında Python dili kullanılarak geliştirilen özel bir işaretleme aracı ile gerçekleştirilmiştir. Bu araç, EllipseSelector tabanlı bir grafik arayüz kullanarak X- Işını görüntüleri üzerinde dairesel yapıları manuel olarak işaretleme imkânı sağlamaktadır

Aracın temel özellikleri:


- Kullanıcının fare ile sürükleyerek daire merkezini ve yarıçapını belirlemesi.
- Femoral baş ve AY için sırayla seçim yapılması; her seçim sonrası parametrelerin normalize edilerek .txt dosyasına kaydedilmesi.
- Kaydetme formatı: cls x y r

Şekil 8’de gösterildiği gibi, işaretleme öncesi görüntüler önce CLAHE ile yerel kontrastı artırılarak iyileştirilir, ardından çift taraflı filtre ile gürültü azaltılır. Devamında Canny kullanılarak sağlam bir kenar haritası üretilir. Bu harita, orijinal radyografi üzerine yarı saydam ve ince bindirme olarak eklenir; böylece özellikle düşük kontrastlı alanlarda anatomik sınırlar ve protez konturları daha net ve işaretlemeye hazır hale gelir.

İş Akışı:

1. Görüntü yüklenir ve ekranda optimize edilmiş versiyonu gösterilir.
2. Kullanıcıdan sırayla femoral baş (cls=0) ve AY (cls=1) seçmesi istenir.
3. Her seçimde daire parametreleri normalize edilir ve bir listeye eklenir.

Onaylandıktan sonra sonuçlar .txt dosyasına kaydedilir.




Şekil 8. Etiketleme Süreci

2.2.2. Femoral Baş Etiketleme

Femoral baş, normal anatomik yapısı itibarıyla küresel bir geometriye sahiptir. Bu nedenle etiketleme sürecinde, mümkün olduğunca küresel görünüme sahip kortikal sınır esas alınmış ve bu sınır üzerinden daire işaretlenmiştir.

Metal artefaktların veya görüntüdeki kısmi kayıpların bulunduğu durumlarda, en stabil ve sürekli görünen kenar dikkate alınmış, kaybolan bölgeler geometrik uyum göz önünde bulundurularak tamamlanmıştır.

Yarıçap seçiminde ise, kemik kenarının ortalama eğrisini en iyi temsil eden daire tercih edilmiştir. Böylelikle anatomik yapıya en uygun, tutarlı ve tekrar edilebilir etiketler elde edilmiştir.



Şekil 9. Femoral Etiketleme

Şekil 9'deki görüntülere bakıldığında, femoral baş için dairesel etiketleme kortikal sınır esas alınarak, sınır boyunca en tutarlı ve sürekli kenara uyumlu daire yerleştirilmiştir.


2.2.3. Asetabular Yuva (AY) Etiketleme Kuralları

AY, anatomik olarak yarım küresel bir yapıya sahiptir. Radyografik görüntülerde bu yapı tam daireye yakın bir formda görülmekte ve etiketleme sürecinde bu geometriye uydurularak işaretlenmektedir.

Boyut açısından temel kural, yuva dairesinin yarıçapının her zaman femoral baş dairesinden daha büyük olmasıdır. Bu koşul, matematiksel olarak

$$r_{\{AY\}} > r_{\{femoral\}} \quad (5)$$

şeklinde ifade edilmektedir.



Şekil 10. AY Etiketleme

Şekil 10'deki görüntüler incelendiğinde, AY için dairesel etiketleme, femoral başı çevreleyen dış kortikal sınır esas alınarak yapılmıştır; vida artefaktları varlığında da daire, en sürekli kontura uyumlu biçimde konumlandırılmıştır.

2.2.4. YOLO-Daire Formatı (x, y, r)

Etiketleme süreci sonucunda oluşturulan veriler, geleneksel YOLO biçiminden farklı olarak dairesel parametrelerle kaydedilmiştir. Bu amaçla YOLO-Daire adı verilen özel bir format kullanılmıştır. Bu format, her satırda bir daireyi tanımlamakta ve üç temel parametre üzerinden yapılandırılmaktadır.

Formatın yapısı şu şekildedir:

$$cls \ x \ y \ r \quad (6)$$

- **Cls** : Sınıf etiketini belirtmektedir. Çalışmada 0 değeri femoral başı, 1 değeri ise AY yapısını ifade etmektedir.
- **x,y** : Dairenin merkez koordinatlarını göstermektedir.
- **r**: Dairenin yarıçapını ifade etmektedir.

Her X- Işını görüntüsü için oluşturulan .txt dosyası, iki satırdan oluşmaktadır. İlk satır femoral başın dairesini, ikinci satır ise AY’i temsil etmektedir. Böylelikle her görüntüde iki temel anatomik yapı sistematik olarak tanımlanmıştır.

Örnek Etiket Dosyası İçeriği:

0 0.729102 0.325760 0.051793

1 0.727189 0.323064 0.082381

Bu örnekte ilk satır femoral başa, ikinci satır ise daha büyük yarıçaplı AY dairesine karşılık gelmektedir.

2.3. Normalizasyon ve Format Dönüşümleri

Etiketleme sürecinde elde edilen dairesel parametrelerin (x, y, r) farklı boyutlara sahip X- Işını görüntülerinde tutarlı şekilde kullanılabilmesi için normalizasyon işlemleri uygulanmıştır. Ayrıca, Deneysel karşılaştırmalar ve alternatif algoritmaların uyumluluğu için dairelerin kutu (YOLO-Kutu) biçimine dönüştürülmesi de gerekmiştir. Bu bölümde kullanılan normalizasyon formülleri, daireden kutuya dönüşüm prensibi ve piksel–normalize karşılaştırmaları ayrıntılı biçimde açıklanmaktadır.

2.3.1. Normalizasyon Formülleri

Etiketleme sırasında elde edilen merkez koordinatları ve yarıçap değerleri piksel cinsindendir. Ancak, farklı çözünürlüklerdeki görüntüler arasında karşılaştırma yapılabilmesi ve DÖ modeline girişlerin tutarlı olması için bu değerler normalize edilmiştir.

Normalize formülleri şu şekilde tanımlanmıştır:

$$x = \frac{X_{piksel}}{W}, y = \frac{Y_{piksel}}{H}, r = \frac{r_{piksel}}{\frac{W+H}{2}} \quad (7)$$

Burada W görüntünün genişliğini, H ise yüksekliğini ifade etmektedir. Bu yöntemle daire merkez koordinatları ve yarıçap değerleri [0,1] aralığına indirgenmekte, böylece farklı boyutlardaki görüntüler arasında ölçek bağımsızlığı sağlanmaktadır.

2.3.2. Pikel ↔ Normalize Karşılaştırmaları

Normalize değerlerin doğruluğunu test etmek amacıyla, seçilen örnek görüntülerde hem piksel hem de normalize parametreleri hesaplanmış ve karşılaştırılmıştır. 516×599 boyutuna sahip bir görüntüde femoral baş ve AY için elde edilen değerler Tablo 2’de sunulmaktadır.

Tablo 2. Pikselden Normalizeye dönüştürme

Yapı	cls	x (piksel)	y (piksel)	r(pikse)	x (norm)	y (norm)	r (norm)
Femoral Baş	0	415.94	218.17	28.92	0.8061	0.3642	0.0519
AY	1	412.98	215.92	49.58	0.8003	0.3605	0.0889

Tablo 2’den görüldüğü üzere, piksel değerleri normalize edildiğinde [0,1] aralığında karşılıkları elde edilmekte ve bu sayede farklı çözünürlüklere sahip görüntüler arasında tutarlılık sağlanmaktadır. Örneğin femoral başın X koordinatı piksel düzeyinde 415.94 iken, normalize karşılığı $415.94/516 \approx 0.806$ olarak hesaplanmıştır.

2.3.3. Normalizasyonun Gerekliliği ve Avantajları

Etiketleme sürecinde elde edilen dairesel parametreler (x, y, r) başlangıçta piksel cinsinden ifade edilmektedir. Ancak, görüntülerin çözünürlüğü ve boyutları değiştikçe aynı anatomik yapının farklı değerlerle temsil edilmesi kaçınılmaz hale gelmektedir. Bu durum, eğitim aşamasında modelin ölçek duyarlılığını artırarak genelleme kabiliyetini azaltabilmektedir.

Normalizasyon işlemi bu sorunu ortadan kaldırmakta ve şu avantajları sağlamaktadır:

- Ölçek Bağımsızlığı: Farklı çözünürlüklerdeki X- Işını görüntülerinde aynı anatomik yapılar [0,1] aralığında aynı değerlerle temsil edilir. Böylece model, çözünürlük farklılıklarından etkilenmez.
- Karşılaştırılabilirlik: Farklı boyutlara sahip görüntülerdeki parametreler doğrudan karşılaştırılabilir hale gelir. Örneğin, 512×512 ve 1024×1024 boyutlarındaki görüntülerde aynı merkez konumu benzer normalize değerlerle ifade edilir.

- **Model Kararlılığı:** Normalizasyon sayesinde öğrenme sürecinde parametrelerin aralığı sınırlanır. Bu, gradyanların dengeli dağılmasını sağlayarak modelin eğitimde daha hızlı ve kararlı şekilde yakınsamasına katkı sunar.
- **Genelleme Gücü:** Model yalnızca belirli bir görüntü boyutuna bağlı kalmaz, farklı veri kaynaklarından gelen X- Işını görüntülerinde de doğru tahminler yapabilir.
- **Sayısal Stabilitè:** Büyük piksel değeri yerine küçük ölçekli değeri kullanmak, hesaplamalarda taşma veya dengesizlik riskini azaltır.

Sonuç olarak, normalizasyon işlemi yalnızca teknik bir dönüşüm değil, aynı zamanda modelin doğruluk, kararlılık ve genelleme kapasitesini artıran temel bir adımdır.

2.3.4. Daire → Kutu Dönüşümü (YOLO-Kutu)

YOLO algoritması varsayılan olarak nesneleri dikdörtgensel kutular (kapsayıcı kutu) biçiminde tanımlamaktadır. Bu çalışmada kullanılan etiketleme yöntemi dairesel parametrelere dayandığından, Deneysel aşamalarda bu dairelerin YOLO-Kutu formatına dönüştürülmesi gerekmiştir. Böylece, model hem dairesel (YOLO-Daire) hem de kutusal (YOLO-Kutu) temsillerle eğitilebilmiş, ayrıca farklı veri kümeleriyle karşılaştırmalı analizler yapılabilmektedir.

Dönüşüm Mantığı:

Bir daire, içine alınabileceği en küçük kare kutu ile temsil edilebilir. Bu dönüşüm sırasında dairenin merkezi değişmeden korunur, kutunun kenar uzunlukları ise dairenin çapına eşit olacak şekilde tanımlanır.

- **Dönüşüm Adımları**

1. Merkez korunur:

$$x_{Kutu} = x_{Daire}, y_{Kutu} = y_{Daire} \quad (8)$$

2. Genişlik ve yükseklik daire çapına eşitlenir:

$$x_{Kutu} = x, y_{Kutu} = y, w = \frac{2 r_{px}}{W}, h = \frac{2 r_{py}}{H} \quad (9)$$

3. Sonuç YOLO-Kutu formatında yazılır:

$$cls \ x \ y \ w \ h \quad (10)$$

Piksele çevirmeden tek adımda eşdeğer ifade:

$$w = r \left(1 + \frac{H}{w} \right), h = r \left(1 + \frac{W}{h} \right) \quad (11)$$

Tablo 3. Daire → Kutu Dönüşümü Örneği (520×622 görüntü)

Yapı	Cls	X	Y	R (YOLO-Daire)	W(YOLO-Kutu)	H (YOLO-Kutu)
Femoral Baş	0	0.834683	0.634775	0.061921	0.135988	0.113688
AY	1	0.829403	0.631734	0.079991	0.175673	0.146865

Tablo 3'e göre, 520×622 boyutlu görüntüde daireden kutuya dönüşümde merkez değişmeden korunur; yani dairenin merkeziyle kutunun merkezi aynıdır. Kutu boyutları, dairenin çapından türetilip görüntü boyutlarına göre normalize edilir. Bu çalışmada model, söz konusu dönüşümü Denklem (11)'e göre uygulamış ve dairesel etiketleri kutu temsiline dönüştürmüştür.

- Kullanım Amacı ve Avantajları:

Bu çalışmada elde edilen tüm dairesel etiketler, YOLOv5 algoritmasının yalnızca kutu tabanlı verileri okuyabilmesi nedeniyle kutu (YOLO-Kutu) formatına dönüştürülmüştür. Bu dönüşümün başlıca amaçları ve sağladığı avantajlar şunlardır:

- Algoritma uyumluluğu: YOLOv5 mimarisi kutu tabanlı girişlerle çalıştığından, daire etiketlerinin doğrudan kullanılabilmesi mümkün değildir. Dönüşüm sayesinde veriler modelin eğitimine uygun hale getirilmiştir.
- Zorunlu standartlaştırma: Tüm daire etiketlerinin kutuya çevrilmesiyle etiketler tek bir formatta toplanmış, böylece eğitim ve test süreçlerinde uyumsuzluk riski ortadan kaldırılmıştır.

- Karşılaştırma imkânı: Kutu formatına dönüştürülen veriler, farklı veri kümeleri ve literatürde yaygın olarak kullanılan kutu tabanlı yöntemlerle doğrudan kıyaslanabilir hale gelmiştir.
- Hibrit kullanım: Eğitim sürecinde YOLO-Kutu etiketleri kullanılırken, tahmin sonuçları son aşamada tekrar dairesel parametrelere dönüştürülerek daire tabanlı analiz yapılabilmiştir. Bu sayede hem algoritma uyumluluğu sağlanmış hem de araştırmanın daire merkezli hedefleri korunmuştur.

2.4. Geleneksel Görüntü İşleme Yöntemleri

Bu çalışmada dairesel yapıların tespitinde yalnızca DÖ tabanlı yaklaşımlar kullanılmamış, aynı zamanda geleneksel görüntü işleme yöntemlerinden de yararlanılmıştır. Bu yöntemler, özellikle model çıktılarının iyileştirilmesi ve düşük kontrastlı görüntülerde sınırların daha belirgin hale getirilmesi için destekleyici bir rol üstlenmiştir.

İlk olarak Canny kenar algılama yöntemi, femoral baş ve AY sınırlarını öne çıkarmak amacıyla kullanılmıştır. CLAHE ile kontrastı artırılmış görüntüler üzerinde uygulanan Canny, daire konturlarına ait temel kenar bilgisini elde etmek için başlangıç noktası sağlamıştır.

Bunu takiben Canny kenar analizi, dairelerin yarıçaplarının iyileştirilmesi aşamasında kullanılmıştır. Algoritma, radyal taramalar boyunca en güçlü kenar tepkilerini belirleyerek, dairelerin femoral baş ve AY üzerine daha hassas biçimde oturmasını sağlamıştır. Böylece, Canny kenarlarının konum bilgisi kullanılarak dairelerin sınırları daha doğru tanımlanmış ve ölçüm sürecinde geometrik doğruluk artırılmıştır.


Kenarlardan elde edilen noktaların daha sağlam bir daireye oturtulabilmesi için RANSAC tabanlı daire uyumlama yöntemi devreye alınmıştır. Bu yöntem, rastgele seçilen noktalardan oluşturulan daire adaylarını değerlendirerek, en yüksek uyumu sağlayan daireyi seçmiştir. Böylece gürültüden kaynaklanan yanlış kenarların etkisi büyük ölçüde azaltılmıştır.

Son olarak, kenar bilgisinin zayıf olduğu ve diğer yöntemlerin yetersiz kaldığı durumlarda Hough Dönüşümü yöntemi olarak kullanılmıştır. Bu yöntem, parametre ayarlarına bağlı olarak femoral baş ve yuva için ek daire adayları üretmiş ve zorlu görüntülerde alternatif çözümler sunmuştur.

Tüm bu yöntemler tek başına kullanılmamış, YOLO tahminlerini destekleyici ve iyileştirici bir yapı içerisinde değerlendirilmiştir.

Sınırlılıklar:

- RANSAC: Kenarlardan elde edilen noktalara dayanarak daha sağlam bir daire fit etmesi beklenmektedir. Ancak X- Işını görüntülerinde her zaman yeterli sayıda doğru kenar noktası bulunmamaktadır. Özellikle düşük kontrastlı alanlarda veya vidaların yoğun olduğu bölgelerde, RANSAC yanlış noktaları inlier olarak kabul edebilmekte ve bu durumda hatalı daireler üretebilmektedir. Bu nedenle RANSAC, yalnızca yeterli ve dengeli veri noktası mevcut olduğunda güvenilir sonuç vermektedir.
- Hough Dönüşümü: Yöntem parametrik doğası gereği, özellikle düşük kontrastlı yuva tespitlerinde alternatif daire adayları üretebilmiştir. Ancak parametre değerlerine (örneğin eşik değerleri ve minimum yarıçap sınırları) yüksek derecede duyarlıdır. Parametreler gevşetildiğinde çok sayıda yanlış aday üretilmekte, sıkılaştırıldığında ise gerçek daireler gözden kaçabilmektedir.



Şekil 11. Ransac ve Hough Kullanarak Yanlış Tespitler

Şekil 11’de RANSAC, femoral baş yerine pelvis ve yumuşak doku kenarlarını takip ettiği için yanlış bir daireye oturmuştur (yeşil daire). Hough Dönüşümü ise AY yerine pelvis dış konturunu büyük yarıçaplı bir daire olarak algılamıştır (mavi daire). Bu durum, geleneksel yöntemlerin tek başına anatomik yapıları ayırt edemediğini ve güvenilir sonuç vermediğini göstermektedir.

2.5. Hibrit Yaklaşım: YOLO + Geleneksel Yöntemler

Bu çalışmada femoral baş ve AY dairelerinin tespitinde yalnızca DÖ tabanlı tahminler veya yalnızca geleneksel görüntü işleme yöntemleri kullanılmamıştır. Her iki yaklaşım da tek başına belirli avantajlar sağlamakla birlikte, tek başına uygulandığında ciddi sınırlılıklar ortaya çıkmaktadır. DÖ tabanlı modeller, hızlı ve yüksek doğrulukla nesne bölgelerini işaretleyebilmekte; ancak çıktıları dikdörtgen kutular şeklinde olduğundan, anatomik yapıları dairesel biçimde temsil etmek mümkün olmamaktadır. Geleneksel yöntemler ise kenar bilgisini doğrudan kullanarak dairesel yapıları ortaya çıkarabilse de, radyografilerde görülen gürültü, metal artefaktlar, implant vidaları ve yumuşak doku sınırları nedeniyle güvenilirlikleri sınırlı kalmaktadır.

Bu nedenle çalışmada, DÖ tabanlı kutu tahminlerinin başlangıç hipotezi olarak kullanıldığı, ardından kenar tabanlı geleneksel yöntemlerle iyileştirildiği ve nihayetinde anatomik kısıtlarla doğrulandığı hibrit bir strateji benimsenmiştir. Bu yapı dört temel aşamadan oluşmaktadır: Edge-Snap ile yarıçap iyileştirme, RANSAC ile sağlamlaştırma, Hough stratejisi ve anatomik kurallarla son seçim.

2.5.1. Edge-Snap ile Yarıçap İyileştirme

DÖ modeli çıktılarından elde edilen daireler başlangıç için kabaca doğru bir merkez ve yarıçap sunsa da özellikle yuva gibi karmaşık konturlarda gerçek sınıra tam olarak oturmamaktadır. Bu nedenle ikinci adımda edge-snap adı verilen yarıçap iyileştirme işlemi uygulanmıştır. Öncelikle görüntü kontrastı uyarlamalı histogram eşitleme (CLAHE) ile artırılmış, ardından çift taraflı (bilateral) filtre ile gürültü azaltılmıştır. Bu ön-işleme adımları, kenarların belirginleşmesini ve düşük kontrastlı bölgelerin güçlendirilmesini sağlamıştır.

Takip eden aşamada Canny kenar dedektörü kullanılmıştır. Bu yöntem, görüntüdeki daha keskin ve belirgin kenarları tespit etmeye olanak tanır. Canny algoritmasının alt ve üst eşik değerleri, görüntünün parlaklık dağılımına göre otomatik olarak belirlenmiştir. Bu amaçla, gri seviye medyan değeri (v) hesaplanmış ve $\sigma = 0.33$ alınarak alt eşik $(1 - \sigma) * v$, üst eşik ise $(1 + \sigma) * v$ biçiminde atanmıştır. Böylece farklı kontrast düzeylerinde kenar algısı kendini uyarlayacak şekilde dengelenmiştir.

Elde edilen kenar haritaları üzerinde, femoral baş ya da yuva merkezinden 360° açısal örnekleme yapılmış; her yönde çok sayıda yarıçap noktası incelenmiştir. Her yönde en güçlü kenar sinyalinin gözlemlendiği yarıçaplar seçilmiş, uç değerler elenmiş ve ağırlıklı medyan kullanılarak yeni bir yarıçap hesaplanmıştır. Bu sayede daire, gerçek kortikal sınıra “oturmuş” ve başlangıç hataları azaltılmıştır. Yöntem, femoral başta düzenli kontura yüksek uyum sağlarken, AY için metalik parlamalar ve vidalardan kaynaklanan sahte kenarların etkisini de belirgin biçimde sınırlamıştır.

2.5.2. RANSAC ile Sağlamaştırma

Edge-snap işlemi ile elde edilen daire çoğu durumda güvenilir sonuç üretse de kenar bilgisi parçalı veya gürültülü olduğunda yarıçap kararsız kalabilmektedir. Bu nedenle üçüncü aşamada RANSAC tabanlı daire uyumlama yöntemi devreye girmiştir.

RANSAC, kenar noktalarından rastgele üçlü kombinasyonlarla daire hipotezleri üretmiş, her hipotezin etrafında kalan noktaları inlier olarak değerlendirmiştir. En fazla inlier toplayan hipotez seçilmiş ve gerekirse en küçük kareler yöntemiyle rafine edilmiştir. Böylece kenar noktalarının bir kısmı gürültülü olsa bile çoğunluğu temsil eden sağlam bir daire elde edilmiştir.

Femoral baş için RANSAC özellikle önemlidir; çünkü baş her ne kadar küresel bir yapıya sahip olsa da implant vidaları ve metal plakaların oluşturduğu parlamalar algoritmayı yanıltabilmektedir. RANSAC, bu yanlış kenarların etkisini azaltarak doğru merkeze ve yarıçapa daha yakın sonuç üretmiştir. AY için de parçalı konturların birleştirilmesi ve dairenin tam olarak tamamlanması açısından kritik rol oynamıştır.

2.5.3. Hough Fallback Stratejisi

Bazı durumlarda kenar kontrastı son derece düşük olmakta, hem edge-snap hem de RANSAC yeterli destek bulamamaktadır. Bu gibi durumlarda sistemin başarısız kalmaması için Hough dönüşümü yedek strateji olarak uygulanmıştır.

Hough dönüşümü parametre uzayında daire araması yaparak kenar noktalarının oluşturduğu oylama dağılımını analiz eder. Çalışmada bu yöntemin yanlış pozitif üretmesini engellemek amacıyla, arama aralığı DÖ tahminlerinden elde edilen yarıçap etrafında dar bir pencereyle sınırlandırılmıştır. Ayrıca eşik parametreleri dikkatle ayarlanarak çok sayıda

yanlış aday üretilmesinin önüne geçilmiştir. Bu sayede özellikle yuva gibi düşük kontrastlı bölgelerde dahi alternatif adaylar elde edilmiş ve sistemin başarısız kalması önlenmiştir.

2.6. Anatomik Kurallarla Son Seçim

Son aşamada, elde edilen tüm aday daireler belirlenen anatomik kurallarla doğrulanmıştır. Bu kurallar, yalnızca doğru anatomik yapıya karşılık gelen dairelerin seçilmesini garanti altına almıştır.

- Yarıçap ilişkisi: AY yarıçapı femoral baştan daima büyük olmalıdır

$$r_{\{AY\}} > r_{\{femoral\}} \quad (12)$$

- Çakışma yasağı: İki daire birbirine temas etmemelidir; arada anatomik yapıya uygun küçük bir boşluk bırakılmalıdır.
- Merkez uyumu: Yuva, femoral başı dıştan sarmalıdır. Merkezin pelvis dışına veya karşı kalçaya kaydığı adaylar reddedilmiştir.
- Kenar desteği: Seçilen dairenin çevresinde Canny tabanlı kenar yoğunluğu belirli bir eşik değerinin üzerinde olmalıdır.
- Artefakt dışlama: Vida, metal plaka veya parlama kenarlarını takip eden daireler yönlü süreklilik ve yarıçap stabilitesi düşük olduğu için elenmiştir.

Bu kuralların uygulanmasıyla, RANSAC veya Hough'un tek başına yanlış pozitif ürettiği durumlar sistematik biçimde elimine edilmiş ve yalnızca güvenilir daireler korunmuştur.

Hibrit Yöntemin Avantajları

Bu çalışmada kullanılan hibrit yaklaşım, DÖ modeli ile klasik görüntü işleme yöntemlerini bütünleştirerek femoral baş ve AY tespitinde daha güvenilir sonuçlar sağlamıştır. Avantajlar şu şekilde özetlenebilir:

- Arama alanının daraltılması

YOLO modeli, hızlı ve yaklaşık bir lokalizasyon sağlayarak klasik yöntemlerin tüm görüntü üzerinde daire araması yapmasını engeller. Bu sayede hem işlem süresi kısılır hem de yanlış pozitiflerin sayısı azalır.

- Kenar bilgisi ile hassasiyet artışı

Edge-snap işlemi, modelin tahmin ettiği daire yarıçaplarını Canny tabanlı kenar enerjisine dayalı olarak düzeltir. Böylece başlangıç tahminleri kemik korteksiyle daha uyumlu hale gelir.

- Gürültüye karşı dayanıklılık

RANSAC tabanlı daire uydurma, özellikle vida gölgeleri ve metal artefaktların bulunduğu X- Işını görüntülerinde, hatalı kenar noktalarını elimine ederek doğru daireyi seçme olasılığını artırır.

- Zayıf kontrastta güvenlik ağı

Hough dönüşümü, kenar sinyalinin yetersiz olduğu veya RANSAC'ın başarısız olduğu durumlarda alternatif daire adayları üreterek sistemin tamamen başarısız olmasını önler.

- Anatomik gerçeklikle uyum


Nihai seçimde kullanılan kurallar (ör. yuva yarıçapının femoral baştan büyük olması, iki dairenin çakışmaması, arada anatomik boşluğun bulunması) tespitlerin yalnızca gerçek yapıları temsil etmesini garanti eder.

- Genelleme kabiliyeti

Farklı hasta gruplarındaki X- Işınında görülebilecek değişiklikler (parlama, kısmi kontur kaybı, implant çeşitliliği) karşısında, birden fazla yöntemin birlikte kullanılması tek başına bir yönetime dayalı sistemlere göre daha geniş koşullarda doğru sonuç üretir.

- Çıktıların istikrarı

Aşağıda Şekil 12'de gösterilen akış diyagramına göre çok katmanlı süreç (YOLO tahmini → edge-snap → RANSAC → Hough Dönüşüm → anatomik seçim) her adımda hata riskini azaltmaktadır. Bu zincirleme yapı sayesinde son aşamada elde edilen daireler hem geometrik hem de klinik açıdan güvenilir olmaktadır.



Şekil 12. Hibrit Yöntemin Akış Diyagramı

2.7. Model Eğitimi

Bu çalışmada femoral baş ve AY tespiti için tek-aşamalı bir dedektör, transfer öğrenme yaklaşımıyla eğitilmiştir. Eğitim hattı, (a) temizlenmiş/standardize edilmiş etiketlerin hazırlanması, (b) iki kademeli ağırlık uyarlaması (Dondurma (freeze) → Çözme (unfreeze)), (c) anatomik bütünlüğe saygılı veri artırma ve (d) kutu, nesne bulunma (objectness) ve sınıf bileşenlerinden oluşan birleşik bir kayıp fonksiyonu etrafında örgütlenmiştir. Eğitim döngüsü boyunca model, her epoch'ta ileri-geri yayılım ve en iyi ağırlıkların seçiminde kullanılan doğrulama adımlarıyla izlenmiş; yakınsamayı hızlandırmak ve aşırı uyumu önlemek için planlanmış öğrenme oranı, etiket yumuşatma ve erken durdurma mantıkları birlikte işletilmiştir.

2.7.1. Eğitim Ortamı (Donanım, CUDA, Torch)

Eğitim betiği, çalıştırma sırasında CUDA desteğini kontrol eder. Uygun bir GPU bulunduğunda hesaplamayı otomatik olarak GPU'ya yönlendirir. Giriş çözünürlüğü ile toplu iş (batch) büyüklüğü, mevcut grafik belleği (VRAM) kapasitesine göre dinamik olarak uyarlanır. Bu sayede bellek taşmaları önlenirken olabilecek en büyük mini-batch kullanılarak donanım verimliliği artırılır.

Veri yükleme tarafında, disk giriş-çıkış gecikmesini en aza indirmek için çok iş parçacıklı (multi-worker) veri taşıyıcılar ve rastgele erişimli bellek (RAM) önbellekleme stratejisi uygulanır. Disk giriş-çıkış gecikmeleri, verilerin diskten okunup GPU'ya ulaşması

sırasında oluşan yavaşlamalardır. Büyük veri setlerinde bu durum GPU'nun boşa kalmasına ve eğitim hızının düşmesine yol açabilir. Çok iş parçacıklı veri yükleme ve belleğe önbellekleme yöntemleri, bu darboğazı azaltarak GPU'nun sürekli veri akışıyla beslenmesini sağlar ve eğitim sürecinin daha akıcı ilerlemesine katkıda bulunur.

Eğitim akışı epoch temellidir. Her epoch sonunda doğrulama süreci çalıştırılır. Seçilen performans ölçütüne göre en başarılı sonuç üreten model, en iyi ağırlıklar (best-weights) olarak otomatik biçimde kaydedilir. Böylece eğitim süreci hem performans hem de güvenilirlik açısından sürekli izlenebilir ve en iyi model sürümü korunur.

2.7.2. Hiperparametre Seçimlerinin Mantığı

Eğitim sürecinde kullanılan hiperparametreler, modelin tıbbi görüntülerde kararlı ve güvenilir biçimde öğrenebilmesi amacıyla belirli ilkelere göre yapılandırılmıştır.

- Öğrenme oranı planlaması: Eğitim başlangıcında hızlı uyumu kolaylaştırmak için görece yüksek bir öğrenme oranı seçilmiş, devam eden süreçte bu değer kademeli olarak azaltılmıştır. Böylelikle erken aşamalarda hızlı yakınsama, ilerleyen aşamalarda ise daha hassas parametre güncellemeleri sağlanmıştır.
- Optimizasyon: Kullanılan optimizasyon yöntemi, ağırlık çürümesi (weight decay) içeren adaptif bir yapıdadır. Bu yaklaşım, düzleşmiş kayıp yüzeylerinde ilerlemeyi kolaylaştırırken ani gradyan değişimlerine karşı dengeli bir öğrenme süreci sunmuştur.
- Erken durdurma: Doğrulama performansında uzun süre iyileşme gözlenmediğinde eğitim süreci otomatik olarak sonlandırılmıştır. Bu mekanizma, aşırı uyumu önlemenin yanı sıra hesaplama kaynaklarının verimli kullanılmasına olanak tanımıştır.
- Etiket yumuşatma (label smoothing): Sınıf hedefleri, belirli bir düzeyde yumuşatılarak modelin aşırı güvenli tahminler üretmesi engellenmiştir. Bu yöntem, özellikle medikal görüntülerde ortaya çıkabilecek etiket belirsizliklerine karşı dayanıklılığı artırmıştır.
- Kare yeniden boyutlandırma: Bu yöntemde tüm görüntüler, en-boy oranı korunacak şekilde sabit bir kare boyuta (640×640 piksel) yeniden ölçeklendirilir. Eksik alanlar siyah dolgu ile tamamlanır; böylece anatomik yapılar bozulmadan modelin beklediği giriş formatına uyum sağlanır. Bu yaklaşım, eğitim sürecinde veri bütünlüğünü korurken daha dengeli gradyan akışları elde edilmesine katkı sağlar.

Not: Bu işlem yalnızca arka planda modelin eğitimi sırasında uygulanır; çünkü DÖ modelleri kare biçimli görüntüleri daha istikrarlı biçimde algılar ve yorumlar.

2.7.3. İki Aşamalı Eğitim Stratejisi (freeze/unfreeze)

Model eğitimi, transfer öğrenme prensiplerine uygun olarak iki aşamada gerçekleştirilmiştir.

- Dondurma aşaması (freeze): Eğitim sürecinin ilk bölümünde, modelin backbone katmanları eğitime kapatılmıştır. Backbone, geniş ölçekli veri kümeleri üzerinde önceden eğitilmiş olup, kenar, doku ve şekil gibi düşük seviyeli evrensel görsel öznitelikleri içermektedir. Bu öznitelikler medikal görüntülerde de geçerliliğini koruduğundan, yeniden öğrenilmesine gerek duyulmamıştır. Bu nedenle yalnızca üst katmanların eğitilmesi sağlanmış, modelin mevcut genel bilgisini kaybetmeden yeni göreve (femoral baş ve AY tespiti) hızlı ve dengeli biçimde uyum sağlaması mümkün olmuştur. Böylece başlangıç aşamasında stabil bir yakınsama elde edilmiş ve gereksiz parametre güncellemeleri engellenmiştir.

- Çözme aşaması (unfreeze): İlk aşamada sağlanan kararlı uyumun ardından backbone katmanları yeniden eğitilebilir hale getirilmiştir. Bu ikinci aşamada model uçtan uca güncellenmiş, böylece düşük seviyeli öznitelikler de medikal görüntülere özgü ayrıntılarla uyumlu hale gelmiştir. Örneğin kemik korteksinin belirgin kenarları, implant vidalarının oluşturduğu metalik konturlar veya yumuşak dokuların yoğunluk geçişleri gibi tıbbi alan-spesifik özellikler bu aşamada modele işlenmiştir. Böylelikle model, hem önceden öğrenilmiş genel görsel temsilleri korumuş hem de görev-spesifik ince detayları öğrenerek daha yüksek doğrulukta ve anatomik gerçeklikle uyumlu tahminler üretebilir hale gelmiştir.

2.7.4. Veri Artırma

Eğitim sırasında kullanılan veri artırma yöntemleri, görüntülerin çeşitliliğini artırırken anatomik bütünlüğün korunmasını temel almıştır.

- Geometrik dönüşümler: Büyük ölçekli dönüşümler (örneğin agresif döndürme, perspektif bozulmaları veya kesme işlemleri) uygulanmamış; bunun

yerine yalnızca küçük ölçek değişimleri, sınırlı kaydırmalar ve düşük olasılıkla yatay çevirme kullanılmıştır. Böylelikle femoral baş ile yuva arasındaki ilişkiler korunurken modelin farklı örneklerle karşı genelleme yeteneği geliştirilmiştir.

- Fotometrik işlemler: X- Işını görüntülerinin doğasına uygun olarak parlaklık ve kontrastta sınırlı değişiklikler yapılmış, renk uzayını bozabilecek müdahalelerden kaçınılmıştır. Bu yaklaşım, görüntülerin klinik anlamını korumuştur.
- Bileşik artırmalar: Mozaik gibi yöntemler yalnızca düşük olasılıkla uygulanmış, mixup veya copy-paste gibi anatomiyi yapay olarak bozabilecek yöntemler tamamen devre dışı bırakılmıştır.

Bu strateji sayesinde model, kenar tabanlı son-işleme (edge-snap, RANSAC) adımlarında gerekli olan gerçekçi kontur istatistiklerini koruyarak hem çeşitliliği hem de klinik geçerliliği güvence altına almıştır.

2.7.5. Kullanılan Kayıp Fonksiyonunun İşleyişi

Eğitimde kullanılan kayıp fonksiyonu, nesne tespit görevine özgü birleşik bir yapıdadır ve üç ana bileşenden oluşur:

1. Kutu bileşeni: Tahmin edilen ve gerçek kutular arasındaki geometrik uyumu optimize eder. IoU-türevli ölçüler aracılığıyla hem konum hem de ölçek uyumunu değerlendirir. Bu çalışmada dairesel yapılar kare kutulara dönüştürüldüğü için model, dairelerin kare içine izdüşümünü öğrenmiştir.
2. Nesne bulunma skoru: Belirli bir konumda hedef bulunup bulunmadığını modellemektedir. Bu sayede negatif örneklerde gereksiz hata baskısı azalırken, pozitif bölgelerde hedefin varlığı güçlü bir şekilde temsil edilmiştir.
3. Sınıf bileşeni: Femoral baş ve AY sınıfları arasında ayrımı sağlamaktadır. Etiket yumuşatma ile birlikte kullanıldığında, sınır bölgelerinde aşırı keskinleşmeyi önlemiş ve daha dengeli bir sınıflandırma performansı sunmuştur.

Hedef atama stratejisi ve negatif örneklerin kontrolü sayesinde, küçük ve orta ölçekli yapılar için dengeli bir gradyan akışı sağlanmıştır. Böylelikle model yalnızca Nesne bulunmada kalmamış, aynı zamanda geometrik olarak iyi hizalanmış kutular öğrenmiştir. Çıkarım aşamasında bu kutular, dairesel parametrelere dönüştürülmüş ve hibrit son-işleme adımları (edge-snap, RANSAC, Hough, anatomik kurallar) ile rafine edilmiştir.

2.7.6. Eğitim Döngüsünün İşleyişi

Her minibatch için eğitim süreci şu adımlarla yürütülmüştür:

- Görüntü ve etiketler yüklenir.
- Uygun artırmalar uygulanır.
- Model çıktılarından birleşik kayıp hesaplanır
- Geriye yayılım ile parametre güncellenir.
- Öğrenme oranı planlayıcı bir sonraki adım için oranı günceller. Epoch sonunda doğrulama seti üzerinde değerlendirme yapılmış ve en iyi ağırlıklar otomatik olarak kaydedilmiştir.

Dondurma-Çözme geçişi, bu döngünün ikinci evresinde tüm katmanların optimize edilmesini sağlayarak modelin genel ve görev-özel öznelilikleri birlikte öğrenmesine imkân tanımıştır.

2.7.7. Gerekçe ve Beklenen Etki

Önerilen eğitim tasarımı, transfer öğrenme (dondurma/çözme), anatomik bütünlüğe duyarlı artırma, kademeli öğrenme oranı ve birleşik kayıp ilkelerini bütüncül bir çatı altında birleştirir. Bu kurgu, üç açıdan sonuca etki eder:

- Tutarlı başlangıç lokalizasyonu. Eğitimde kutusal temsilin disipline edilmesi, çıkarımda dairesel parametreye dönüşüm yapıldığında merkez ve ölçek kararlılığını artırır; bu, hibrit aşamada (edge-snap/RANSAC/Hough) gereken ince ayarı kolaylaştırır.
- Kenar istatistiklerinin korunması. Artırma politikası, kenar enerjisi ve gradyan yönlülüğü gibi sinyal özelliklerini korur. Böylece edge-snap ve RANSAC, gerçekçi kenar dağılımları üzerinde çalışır.
- Klinik olarak anlamlı nihai çıktı. Birleşik kayıp ve doğrulama temelli model seçimi, femoral baş ve yuva için anatomik gerçeklikle uyumlu dairesel dairesel modellemeye zemin hazırlar. Hibrit son-işleme adımları bu çıktıları güvenilir biçimde rafine eder.

Neticede, model eğitiminde alınan bu tasarım kararları tek başına derin veya tek başına klasik yaklaşımların üretemediği stabil, anatomik olarak tutarlı ve klinik açıdan güvenilir tespitler elde edilmesine olanak tanır.

Tablo 4. Eğitimde kullanılan stratejiler ve mantıkları

Strateji	Amaç	Mantık / Gerekçe
Öğrenme oranı planlaması	Yakınsamayı hızlandırmak ve son aşamada ince ayar sağlamak	Başlangıçta görece yüksek öğrenme oranı ile hızlı uyum; daha sonra kademeli azaltma ile kararlı ve hassas güncellemeler
Adaptif optimizasyon (AdamW vb.)	Denge ve esneklik	Ağırlık çürümesi içeren adaptif yapı sayesinde hem düzleşmiş bölgelerde ilerleme hem de yüksek gradyanlarda istikrar
Erken durdurma	Aşırı uyumun önlenmesi ve kaynak verimliliği	Doğrulama setinde uzun süre gelişme olmadığında eğitimi sonlandırarak fazla uyumu engeller, zaman ve donanım tasarrufu sağlar
Etiket yumuşatma	Aşırı güvenin engellenmesi	Sınıf hedeflerini yumuşatarak modelin aşırı güvenli tahminler tahmin üretmesini engeller; tıbbi verilerdeki etiket belirsizliğine dayanıklılık kazandırır
Kare yeniden boyutlandırma	Anatomik bütünlüğün korunması	Görüntüler en-boy oranı korunarak kare olarak paketlenir; böylece kemik ve protez konturları bozulmaz, gradyan akışı istikrarlı olur
İki aşamalı eğitim	Hem genel öznelilikleri korumak hem de görev-spesifik uyum sağlamak	İlk aşamada backbone katmanları dondurularak evrensel öznelilikler korunur; ikinci aşamada açılarak kemik, implant ve dokuya özgü ayrıntılar öğrenilir
Veri artırma	Çeşitlilik ve genelleme	Geometrik dönüşümler küçük ölçekte tutulur, fotometrik değişiklikler sınırlı uygulanır; mozaik düşük olasılıkla devreye girerken, karışık örnekleme ve kopyala-yapıştır yöntemleri tamamen kapatılmıştır.
Birleşik kayıp (Kutu + Nesne bulunma + Sınıf)	Konum, ölçek ve sınıf bilgisini eşzamanlı optimize etmek	Kutu kaybı geometrik uyumu, nesne bulunma kaybı hedefin Nesne bulunma olasılığını, sınıf kaybı ise doğru kategoriye öğrenmeyi sağlar. Bu üç bileşen birlikte çalışarak modelin hem konum doğruluğunu hem de anlamlı nesne tanımını dengeleyen bütüncül bir öğrenme süreci oluşturur.

Model eğitimi, Tablo 4'te sunulan ayar ve stratejilerin tamamı kullanılarak yürütülmüştür. Bu kapsamda öğrenme oranı planlaması, adaptif optimizasyon, erken durdurma, etiket yumuşatma, Kare yeniden boyutlandırma, iki aşamalı eğitim, sınırlı veri artırma ve birleşik kayıp yaklaşımı birlikte uygulanmıştır. Böylelikle yakınsama hızı, genelleme ve kararlılık dengelenmiştir.

2.8. Görselleştirme Süreci

Modelin eğitimi ve çıkarımı sonucunda elde edilen tahminlerin değerlendirilmesi yalnızca sayısal metriklere indirgenmemiş, aynı zamanda görsel çıktılar üzerinden de desteklenmiştir. Tıbbi görüntü işleme alanında görselleştirme, modelin ürettiği tahminlerin anatomik yapılarla ne derece uyumlu olduğunu gözle görülür biçimde ortaya koyması açısından kritik bir öneme sahiptir. Bu nedenle çalışmada, çıkarım sonrası tahminler sistematik bir iş akışı çerçevesinde görselleştirilmiş, kaydedilmiş ve ayrıca etiket dosyaları biçiminde de saklanmıştır.


YOLO tabanlı modelin çıkarım aşamasında ürettiği tahminler, mimarinin doğası gereği başlangıçta dikdörtgensel kutular (kapsayıcı kutu) biçimindedir. Bu kutular, genel nesne tespiti problemleri için uygun bir temsil olsa da femoral baş ve AY gibi dairesel yapıları geometrik olarak tam anlamıyla karşılamamaktadır. Bu nedenle çalışmada, kutuların parametreleri özel bir dönüşüm adımıyla daire parametrelerine (x , y , r) çevrilmiştir. Burada (x , y) dairenin merkezi, r ise yarıçapını ifade etmektedir. Böylelikle modelin kare kutu biçiminde öğrendiği temsiller, anatomik gerçeklikle daha uyumlu olan dairesel yapılara dönüştürülmüş; sonrasında görselleştirme süreci bu dairesel parametreler üzerinden gerçekleştirilmiştir. Bu yöntem, hem eğitim sırasında kullanılan YOLO mimarisiyle uyumu sürdürmüş hem de klinik uygulamalar için gerekli dairesel temsilin elde edilmesini mümkün kılmıştır.

2.8.1. İlgi Bölgesi Otomatik Belirleme (YOLOv5 Tabanlı Odaklama Yaklaşımı)

Bu aşamada modelin girdi olarak aldığı tam radyografik görüntü üzerinde, protez yapısının bulunduğu bölgeyi otomatik olarak belirlemek ve gereksiz arka planı ortadan kaldırmak amacıyla YOLOv5 tabanlı bir odaklama (region-of-interest, ROI) modülü

uygulanmıştır. Model tarafından üretilen tüm tespitler arasından yalnızca en yüksek güven değerine sahip bölge seçilmiştir. Böylece sistem, protez bileşeninin çevresindeki anatomik yapıların tamamını kapsayan, ancak gereksiz alanları içermeyen bir alt görüntü elde etmiştir.

Bu işlem sırasında modelin belirlediği konuma yaklaşarak, sonraki dairesel sınır belirleme (edge-snap ve RANSAC tabanlı) aşamaları için standart boyutlu ve gürültüden arındırılmış bir giriş görüntüsü sağlanmıştır. Bu sayede hem işlem süresi kısalmış hem de sonraki analizlerde daha odaklı ve kararlı bir geometrik çözümleme elde edilmiştir.



Şekil 13. YOLOv5 ile kalça protez bölgesinin otomatik lokalizasyonu.

Şekil 13'te görüldüğü gibi, YOLOv5 tabanlı odaklama modülü tam radyografide en yüksek güvenli bölgeyi seçerek protez bileşeninin bulunduğu alana yaklaşır. Böylece, protez çevresindeki anatomik yapıları koruyan ve edge-snap ile RANSAC aşamalarına uygun standart ve odaklı bir alt görüntü elde edilir.


2.8.2. Çıktıların Çizdirilmesi

Kutudan daireye dönüşümü sonrasında elde edilen parametrelerle, X- Işını görüntüsü üzerine daireler çizdirilmiştir. Femoral baş yeşil renkli daire ile, AY ise sarı renkli daire ile gösterilmiştir. Ayrıca her dairenin merkezi küçük bir nokta ile işaretlenmiştir.

Merkezlerin görselleştirilmesinin temel gerekçesi, yalnızca dairesel sınırların doğruluğunu göstermek değil, aynı zamanda ileride yapılacak aşınma hesaplamaları için referans noktası oluşturmaktır. Özellikle protez cerrahisinden hemen sonra elde edilen merkezler ile birkaç yıl sonraki takip görüntülerinde elde edilen merkezler karşılaştırıldığında, merkezler arasındaki mesafedeki değişim hesaplanabilmektedir. Bu

değişim, AY ile femoral baş arasındaki kaymanın bir göstergesi olup, çalışmada kullanılan Medial aşınma ölçümü için kritik bir parametredir.

Dolayısıyla, merkezlerin işaretlenmesi görselleştirme sürecinde yalnızca estetik bir unsur değil, aynı zamanda sonraki analizler için nicel ölçümün görsel doğrulamasını sağlayan zorunlu bir adımdır. Bu yöntem sayesinde hem sınır uyumu hem de merkez ilişkisi görsel olarak incelenebilmiş ve aşınma analizinde kullanılacak mesafe ölçümleri için güvenilir bir altyapı oluşturulmuştur.



Şekil 14. Hibrit Yöntemiyle femoral ve AY tespitleri

Şekil 14'te görüldüğü gibi, hibrit yöntemle elde edilen nihai sonuçlarda femoral baş yeşil, AY ise sarı daire ile gösterilmiştir. Her iki yapının merkezi ayrıca küçük bir nokta ile işaretlenmiştir. Bu görselleştirme, yalnızca dairesel sınırların doğruluğunu göstermekle kalmayıp, femoral baş ve yuva merkezleri arasındaki geometrik ilişkinin de açık biçimde görölmesini sağlar. Böylece ilerleyen aşamada yapılacak aşınma ölçümlerinde, merkezler arasındaki mesafe değişimleri doğrudan referans alınabilmekte ve bu değerler aşınma analizinin temel girdisini oluşturmaktadır.

2.8.3. Görsellerin Kaydedilmesi

Çıktıların görsel olarak yalnızca ekranda gösterilmesiyle yetinilmemiş, aynı zamanda sistematik bir klasör yapısı içinde kaydedilmesi sağlanmıştır. Her giriş görüntüsüne karşılık, üzerinde femoral baş ve AY daireleri çizilmiş çıktı görüntüleri belirlenmiş klasörlere kaydedilmiştir. Bu kayıt süreci, üç önemli avantaj sunmuştur:

1. Doğrudan karşılaştırma: Kaydedilen görseller, aynı isimlendirme düzeniyle orijinal görüntülerle eşleştirilmiş. Bu sayede ham veri ile işlenmiş sonuçların yan yana incelenmesi mümkün olmuştur.
2. Dokümantasyon: Eğitim ve çıkarım süreçlerinin farklı aşamalarında elde edilen sonuçların arşivlenmesi, çalışmanın dokümantasyonu için değerli bir kaynak oluşturmıştır.
3. Performans takibi: Modelin farklı epoch'larda ürettiği sonuçlar görsel olarak kaydedildiğinden, eğitim boyunca modelin gelişimi ve iyileşmesi görsel açıdan da izlenebilmiştir.

Görsellerin kaydedilmesi, aynı zamanda modelin yalnızca sayısal doğruluk ölçütleriyle değil, gözle görülen doğrulukla da değerlendirilebilmesine imkân tanımıştır. Özellikle yanlış tespitler, görsel çıktılar üzerinden Kolaylıkla fark edilebilmiş ve hibrit yöntemlerin (edge-snap, RANSAC, Hough) ne ölçüde iyileştirme sağladığı somut biçimde gözlenmiştir.

2.8.4. Etiketlerin Kaydedilmesi (Labels Results)

Görselleştirme sürecinde yalnızca görsel çıktılar değil, aynı zamanda sayısal etiket dosyaları da üretilmiştir. Bu dosyalarda, her tahmin için sınıf kimliği ve normalize edilmiş dairesel parametreler (x, y, r) yer almaktadır.

Etiketlerin kaydedilmesi iki yönlü fayda sağlamıştır:

- Nicel değerlendirme: Kaydedilen parametreler, modelin performansını ölçmek için gerçek etiketlerle karşılaştırılabilir. Bu sayısal karşılaştırma, görselleştirme adımlarını tamamlayıcı bir rol üstlenmiş ve modelin başarısını

yalnızca görsel gözleme dayalı olmaktan çıkarıp objektif biçimde değerlendirmeye imkân tanımıştır.

- Yeniden kullanılabilirlik: Normalize edilmiş dairesel parametreler, ileride gerçekleştirilecek yeni deneysel çalışmalarda doğrudan kullanılacak biçimde arşivlenmiştir. Bu yapı, model çıktılarının farklı yöntemlerle analiz edilmesine ve gelecekte farklı modellerle kıyaslanmasına da olanak tanımaktadır.

Sonuçta, etiket dosyalarının saklanması çalışmaya sistematik bir boyut kazandırmış, görsel ve sayısal çıktıların birlikte değerlendirilmesine imkân vermiştir.

2.9. Aşınma Hesaplama Yöntemi

Aşınma hesaplaması, ameliyat sonrası (*Hemen sonra*) ve takip dönemi (*Sonra*) görüntülerinde elde edilen femoral baş ve AY daire parametrelerinin (c_x, c_y, r) karşılaştırılmasıyla yapılmıştır. Ölçümlerde iki ana aşınma metriği dikkate alınmıştır: medial aşınma ve superior aşınma.

2.9.1. Medial Aşınma (Merkezler Arası 2B Mesafe)

Femoral baş ve AY merkezleri arasındaki iki boyutlu mesafe her iki zaman noktasında hesaplanmıştır:

$$d_{Hemen sonra} = \sqrt{(c_x, AY, hemen sonra - c_x, fem, hemen sonra)^2 + (c_y, AY, hemen sonra - c_y, fem, hemen sonra)^2} \quad (13)$$

$$d_{Sonra} = \sqrt{(c_x, AY, Sonra - c_x, fem, Sonra)^2 + (c_y, AY, Sonra - c_y, fem, Sonra)^2} \quad (14)$$

Farklı çekimlerdeki ölçek farklılıklarını telafi etmek için *Sonra* değerleri femoral yarıçap oranıyla düzeltilmiştir:

$$sf = \frac{r_{fem, Hemen sonra}}{r_{fem, Sonra}} \quad (15)$$

Sonuç olarak medial aşınma:

$$\Delta d = d_{Sonra} \cdot sf - d_{Hemen sonra} \quad (16)$$

2.9.2. Superior Aşınma (Üst Noktalar Arası Dikey Mesafe)

Her dairenin üst noktası, merkez koordinatından yarıçap çıkarılarak belirlenmiştir:

$$y_{top, fem} = c_{y, fem} - r_{fem}, \quad y_{top, AY} = c_{y, AY} - r_{AY} \quad (17)$$

Superior mesafe her iki zaman noktası için:

$$g_{Hemen sonra} = |y_{top, AY, Hemen sonra} - y_{top, fem, Hemen sonra}| \quad (18)$$

$$g_{Sonra} = |y_{top, AY, Sonra} - y_{top, fem, Sonra}| \quad (19)$$

Ölçek faktörü yine femoral yarıçap üzerinden uygulanmış, superior aşınma şu şekilde hesaplanmıştır:

$$\Delta g = g_{Sonra} \cdot sf - g_{Hemen sonra} \quad (20)$$

2.9.3. Genel Aşınma Büyüklüğü

Medial ve superior aşınma değerlerinin vektörel birleşimi, aşınmanın toplam büyüklüğünü temsil etmektedir:

$$\Delta_{genel} = \sqrt{(\Delta d)^2 + (\Delta g)^2} \quad (21)$$

2.9.4. Çıktıların Kayıt Biçimi

Hesaplanan tüm değerler (femoral yarıçaplar, ölçek faktörü, merkez mesafeleri, superior boşluklar, $(\Delta d, \Delta g, \Delta_{genel})$ metin dosyası formatında kaydedilmiştir. Böylece her

hasta için standardize edilmiş sayısal bir rapor üretilmiş ve ileri istatistiksel analizler için arşivlenebilir hale getirilmiştir.

Örnek 2.1

Ameliyat sonrası (Hemen sonra) (A) ve takip dönemi (*Sonra*) (B) X- Işını görüntülerinde aşağıdaki parametreler elde edilmiştir:

Femoral yarıçap (Hemen sonra): $r_{fem,A} = 71.81 \text{ px}$

Femoral yarıçap (Sonra): $r_{fem,B} = 74.48 \text{ px}$

Merkezler arası mesafe (Hemen sonra): $d_A = 12.76 \text{ px}$

Merkezler arası mesafe (Sonra): $d_B = 7.29 \text{ px}$

Superior boşluk (Hemen sonra): $g_A = 44.88 \text{ px}$

Superior boşluk (Sonra): $g_B = 45.79 \text{ px}$

Çözüm:

Ölçek faktörü (femoral yarıçaplara göre):

$$sf = \frac{r_{fem,A}}{r_{fem,B}} = \frac{71.81}{74.48} = 0.964$$

Medial aşınma

$$d_B \text{ to } A = d_B \cdot sf = 7.29 \cdot 0.964 = 7.03 \text{ px}$$

$$\Delta d = d_B \text{ to } A - d_A = 7.03 - 12.76 = -5.73 \text{ px} = 5.73 \text{ px}$$

Superior aşınma

$$g_B \text{ to } A = g_B \cdot sf = 45.79 \cdot 0.964 = 44.15 \text{ px}$$

$$\Delta g = g_B \text{ to } A - g_A = 44.15 - 44.88 = -0.73 \text{ px} = 0.73 \text{ px}$$

Genel aşınma

$$\Delta_{genel} = \sqrt{(\Delta d)^2 + (\Delta g)^2} = \sqrt{(5.73)^2 + (0.73)^2} \approx 5.78 \text{ px}$$

3. BULGULAR

Bu bölümde geliştirilen yöntemin eğitim sürecinde elde ettiği performans çıktıları, doğruluk ölçümleri ve görsel incelemeler sunulmaktadır. Öncelikle modelin eğitim sürecine ilişkin kayıp eğrileri ve temel doğruluk metrikleri raporlanmış, ardından femoral baş ve AY tespitlerinin başarı eğrileri verilmiştir. Daha sonra seçilen örnekler üzerinden doğru ve hatalı tespitler görselleştirilmiş, zorlayıcı vakalardaki performans ayrı olarak gösterilmiştir. Son kısımda ise çalışmanın asıl hedefini oluşturan aşınma ölçümleri (superior ve medial) hesaplanarak, iki zaman noktasının karşılaştırmalı tabloları ile birlikte sunulmuştur.

3.1. Eğitim Sonuçları

Bu bölümde, eğitilen YOLO tabanlı modelin eğitim sürecine ilişkin çıktılar raporlanmaktadır. Modelin kutu tabanlı performansı; kayıp (loss) eğrilerinin seyri, mAP değerleri ile Keskinlik ve Duyarlık ölçütleri üzerinden değerlendirilmiştir. Bu metrikler, hibrit yöntemin ilk aşaması olan YZ tahminlerinin güvenilirliğini ortaya koymakta ve sonraki aşamalarda uygulanan dairesel dönüşüm ile geleneksel iyileştirme adımlarının temelini oluşturmaktadır.


3.1.1. Eğitim Kaybı Eğrileri

Aşağıda, Şekil 15'te eğitim süreci boyunca kutu, Nesne bulunma ve sınıf kayıplarının eğitim ve doğrulama grafikleri izlenmiştir.

- Kutu kaybı (train/val): Eğitim setinde (train) kutu kaybı yaklaşık 0.14'ten başlayarak 0.04 seviyelerine kadar düzenli olarak azalmıştır. Doğrulama setinde (val) de benzer bir azalış gözlenmiş, 0.12'den 0.06 seviyelerine düşmüştür. Bu düşüş, modelin tahmin ettiği kutuların konum ve boyut açısından gerçek etiketlerle giderek daha uyumlu hale geldiğini göstermektedir.

- Nesne bulunma kaybı (train/val): Başlangıçta 0.03 civarında olan eğitim kaybı 0.005'e kadar inmiş, doğrulama kaybı ise 10 gibi yüksek değerlerden 1'nin altına düşmüştür. Başlangıçta gözlenen yüksek değer, modelin pozitif ve negatif bölgeleri ayırt etmede zorlandığını, ilerleyen epoch'larda kaybın düşmesi ise bu ayrımın giderek iyileştiğini ortaya koymaktadır.
- Sınıf kaybı (train/val): Eğitimde 0.035'ten 0.022 seviyelerine inen kayıp, doğrulama tarafında da benzer biçimde 0.045'ten 0.025'e düşmüştür. Bu durum, modelin femoral baş ve AY sınıflarını birbirinden ayırt etmede giderek daha başarılı olduğunu göstermektedir.

Eğitim ve doğrulama kayıpları arasında belirgin bir ayrışma olmaması, modelin aşırı öğrenmeye girmediğini, genelleme başarısının korunduğunu göstermektedir. Özellikle 50. epoch'tan sonra tüm kayıpların düşük seviyelerde dengeye oturduğu izlenmiştir. Bu tablo, yalnızca YZ modelinin bile (hibrit iyileştirme adımları uygulanmadan) femoral baş ve yuva bölgelerini ayırt etmede güçlü bir temel öğrenme gerçekleştirdiğini ortaya koymaktadır.



Şekil 15. Kayıp Eğrileri

3.1.2. mAP Değerleri


Modelin ortalama doğruluk performansı, farklı IoU eşiklerinde hesaplanan mAP değerleri üzerinden değerlendirilmiştir (Şekil 16).

mAP@0.5: 0.971 olarak elde edilmiştir. Bu değer, femoral baş ve AY tespitlerinin büyük oranda doğru kutularla eşleştiğini göstermektedir.

mAP@0.5:0.95: Yaklaşık 0.60 seviyesinde gerçekleşmiştir. Bu değer daha sıkı bir ölçüttür ve farklı IoU eşiklerinde ortalama doğruluk performansını gösterir. Medikal X- Işını görüntülerinde düşük kontrast, metalik implant etkileri ve anatomik karmaşıklıklar göz önüne alındığında, yalnızca YZ kullanılarak ulaşılan bu performans oldukça tatmin edicidir.

Sınıf bazlı mAP değerlerine bakıldığında, femoral baş için 0.995, AY için ise 0.948 bulunmuştur. Femoral başın daha küresel ve kontrastlı yapısı nedeniyle tespit başarısının daha yüksek olduğu, AY’da ise vidalar ve üst üste binen kemik yapılar nedeniyle başarının görece düşük kaldığı anlaşılmaktadır.

Önemli bir nokta olarak, burada raporlanan mAP değerleri yalnızca YOLO tabanlı YZ tahminlerine aittir. Hibrit yöntemde kullanılan edge-snap, RANSAC ve Hough gibi iyileştirme adımları henüz devreye alınmamıştır. Dolayısıyla bu sonuçlar, hibrit yaklaşımın getirdiği ek avantajlar olmaksızın dahi yüksek bir doğruluk seviyesinin elde edilebildiğini göstermektedir.




Şekil 16. mAP eğrisi

3.1.3. Keskinlik ve Duyarlılık Performansı

Şekil 17’deki grafiklere göre, modelin farklı güven eşiklerinde sergilediği duyarlılık performansı Duyarlılık–Güven Eğrisi (confidence – Recall) Eğrisi üzerinden incelenmiştir. Düşük güven eşiklerinde Duyarlılık değerinin 1.0 seviyesine çok yakın olduğu görülmektedir; bu durum, modelin femoral baş ve AY örneklerinin neredeyse tamamını yakaladığını göstermektedir. Güven eşiği yükseldikçe model daha seçici hale gelmiş, bu da bazı gerçek örneklerin atlanmasına yol açmıştır. Sonuç olarak, Duyarlılık değerlerinde kademeli bir azalma gözlenmiştir.

Keskinlik – Duyarlılık eğrilerinden elde edilen değerlere göre femoral baş için keskinlik 0.995, duyarlılık 0.98 seviyesinde; AY için Keskinlik 0.948, Duyarlılık ise 0.95 civarındadır. Bu bulgular, modelin özellikle femoral baş tespitinde yüksek doğruluk ve kapsama sağladığını, AY tespitinde ise küçük farklılıklar olmakla birlikte genel olarak başarılı sonuçlar elde ettiğini ortaya koymaktadır.




Şekil 17. Duyarlılık–Güven Eğrisi

3.2. Başarı Eğrileri

Modelin femoral baş ve AY için dairesel tespit başarısı hem piksel bazlı hata toleransları hem de normalize edilmiş hata toleransları üzerinden değerlendirilmiştir. Bu değerlendirmeler, merkez (x,y) ve yarıçap (r) tahminlerinin doğruluğunu ayrı ayrı incelemektedir.

3.2.1. Femoral ve Yuva Merkez Doğruluk Eğrileri (piksel)


Piksel bazlı merkez doğruluk eğrileri incelendiğinde, femoral merkez tahminleri yuva merkezine kıyasla daha hızlı yakınsama göstermektedir (Şekil 18). Femoral merkez, 2–3 piksel hata toleransında %90'ın üzerinde doğruluk sağlamış, 5 piksel eşliğinde ise %100'e ulaşmıştır. Yuva merkezi ise metal vidalar ve implant kaynaklı parazitlerin etkisiyle daha yavaş yakınsamış, 5 piksel eşliğinde %90 doğruluğa, 10 piksel eşliğinde ise %95'in üzerine çıkmıştır.



Şekil 18. Femoral ve Yuva Merkez Doğruluk Eğrileri (piksel)

3.2.2. Femoral ve Yuva Yarıçap Doğruluk Eğrileri (piksel)


Şekil 19 incelendiğinde, yarıçap doğruluk eğrilerinde femoral baş daha yüksek performans gösterdiği görülmektedir. 3–4 piksel hata toleransında %95’in üzerinde doğruluk elde edilmiş, 5 pikselde ise %100 seviyesine ulaşılmıştır. Yuva yarıçapında ise 5 piksel hata eşiğinde doğruluk %90 civarında, 10 piksel eşiğinde %98 seviyesinde gerçekleşmiştir. Bu durum, modelin yuva boyutlarını tahmin ederken daha fazla değişkenlik yaşadığını göstermektedir.



Şekil 19. Femoral ve Yuva Yarıçap Doğruluk Eğrileri (piksel)

3.2.3. Femoral ve Yuva Merkez Doğruluk Eğrileri (normalize)


Şekil 20’de gösterildiği üzere, normalize edilmiş merkez doğruluk eğrileri, farklı çözünürlükteki görüntüler arasındaki ölçek farklılıklarını ortadan kaldırarak modelin gerçek performansını daha objektif biçimde ortaya koymuştur. Femoral merkez, %1 hata toleransında dahi %95 doğruluk sağlamış, %2 hata eşiğinde %100 seviyesine ulaşmıştır. Yuva merkezinde ise %1 hata toleransında %90 doğruluk elde edilmiş, %2 hata eşiğinde %98 seviyesine ulaşmıştır.



Şekil 20. Femoral ve Yuva Merkez Doğruluk Eğrileri (normalize)

3.2.4. Femoral ve Yuva Yarıçap Doğruluk Eğrileri (normalize)

Normalize yarıçap doğruluk eğrileri incelendiğinde, femoral baş yine yuva yarıçapına kıyasla daha yüksek performans göstermektedir. %1 hata toleransında femoral yarıçap doğruluğu %95 seviyesine ulaşırken, yuva yarıçapı için bu değer %90 civarındadır. %2 hata eşiğinde ise her iki yapı için de doğruluk %100 seviyesine yakınsamıştır. Bu sonuç, normalize ölçümün özellikle küçük hata toleranslarında daha keskin bir ayırım yaparak modelin güvenilirliğini vurguladığını göstermektedir. (Şekil 21)



Şekil 21. Femoral ve Yuva Yarıçap Doğruluk Eğrileri (normalize)

3.2.5. Normalize ve Piksel Sonuçlarının Karşılaştırılması

Piksel bazlı doğruluk eğrileri (Şekil 18: merkez, Şekil 19: yarıçap) ile normalize doğruluk eğrileri (Şekil 20: merkez, Şekil 21: yarıçap) karşılaştırıldığında, iki yaklaşımın hata toleransına karşı duyarlılıkta belirgin farklılıklar sergilediği gözlemlenmiştir. Piksel bazlı analizde, doğruluk değerleri kullanılan görüntünün çözünürlüğüne doğrudan bağlıdır. Örneğin yüksek çözünürlüklü bir görüntüde birkaç piksel hata anatomik olarak önemsiz sayılabilirken, düşük çözünürlüklü bir görüntüde aynı piksel hatası ciddi bir oransal sapmaya yol açabilmektedir (şekil 18, şekil 19). Bu durum, piksel tabanlı metriklerin özellikle heterojen boyutlarda görüntüler içeren veri setlerinde objektif bir değerlendirme sunmasını engellemektedir.

Normalize doğruluk eğrileri ise bu ölçek farklılıklarını ortadan kaldırarak model performansını daha adil ve karşılaştırılabilir bir şekilde değerlendirmektedir (şekil 20, şekil 21). Normalize edilmiş ölçümlerde hem merkez hem de yarıçap için doğruluk değerlerinin çok daha hızlı biçimde %100'e yaklaştığı, küçük hata toleranslarında dahi yüksek doğruluk seviyelerine ulaşıldığı tespit edilmiştir. Bu bulgu, modelin anatomik yapıları boyutlardan

bağımsız olarak doğru biçimde yakaladığını ve genelleme kabiliyetinin normalize ölçekte daha net ortaya çıktığını göstermektedir.


Bu nedenle çalışma kapsamında modelin eğitim ve değerlendirme sürecinde normalize değerler tercih edilmiştir. Böylelikle hem farklı boyutlarda kaydedilmiş X- Işını görüntüleri arasında karşılaştırılabilir bir metrik elde edilmiş, hem de klinik olarak anlamlı olan dairesel yapılar (femoral baş ve AY) gerçek anatomik boyutlardan bağımsız olarak güvenilir biçimde temsil edilmiştir. Normalize parametrelerin kullanılması, modelin çıktılarının ölçekten bağımsız doğruluğunu garanti altına almış ve daha objektif bir performans değerlendirmesi yapılmasına olanak tanımıştır.

3.3. Görsel Bulgular

3.3.1. YOLOV5 ile Bölge Lokalizasyonu

Şekil 22’de gösterildiği üzere, model radyografik görüntüler üzerinde femoral baş ve asetabular yuva bölgelerini içeren ilgi alanlarını ROI otomatik olarak belirlemiştir. YOLOv5 tabanlı bölge tespiti sayesinde, her görüntüde protez yapılarının bulunduğu alan başarıyla lokalize edilmiş ve analiz için uygun alt bölgeler oluşturulmuştur.

Model, farklı çözünürlük ve kontrast seviyelerine sahip görüntülerde dahi hedef bölgeyi doğru şekilde yakalamış; böylece sonraki dairesel tespit adımlarında daha kararlı ve odaklanmış bir analiz zemini sağlanmıştır. Görsel örneklerde, modelin en yüksek olasılığa sahip bölgeye odaklanarak çevresel dokuları dışarıda bıraktığı ve yalnızca protez çevresini içeren anlamlı bir kesit oluşturduğu görülmektedir.




Şekil 22. YOLOv5 tabanlı ROI tespiti

3.3.2. Farklı Koşullarda Tespitler

Aşağıdaki alt örnekler modelin doğruluğunu farklı koşullar altında göstermektedir (Şekil23):

- Kontrast: iyi/orta/düşük seviyede net sınırlar, düşük kontrasta rağmen tutarlılık.
- Gürültü/Artefakt: metalik artefakt varlığında dahi femoral baş – yuva ayrımı korunuyor.



Şekil 23. Farklı koşullarda Femoral ve AY tespitleri


3.3.3. Hatalı Tespit Örnekleri

Modelin genel performansı yüksek ve başarılıdır. Çoğu durumda femoral baş ve AY doğru biçimde tespit edilmiş, elde edilen sonuçlar manuel işaretlemelerle uyum göstermiştir. Bununla birlikte bazı özel koşullarda hatalı tespitler gözlenmiştir (Şekil 24). Özellikle

kontrastın çok düşük olduğu veya yuva bölgesinin üzerinde vidaların bulunduğu vakalarda bazen modelin sınırları doğru ayırt edemediği görülmüştür.

Düşük kontrastlı görüntülerde kenar sinyalleri zayıfladığı için bazen dairelerin sınırları kaybolmaktadır, bu da femoral başın merkezinde kaymalara veya yuva yarıçapının yanlış tahmin edilmesine neden olabilmektedir. Benzer şekilde, yuva kenarına yerleşmiş vidalar ya da metalik yapılar, model tarafından yuva sınırının bir parçası gibi algılanabilmekte ve hatalı daire oluşumuna yol açabilmektedir. Bu durum, kenar bilgisine dayalı algoritmalar için doğal bir zorluk oluşturmaktadır.

Her ne kadar geliştirilen hibrit yöntemde kullanılan ek kurallar bu hataların çoğunu azaltmış olsa da kontrastın yetersizliği ve vidaların doğrudan yuva üzerinde bulunması modelin en zorlandığı senaryolar olarak öne çıkmıştır. Buna rağmen genel olarak, modelin yüksek doğruluk düzeyine sahip olduğunu, yalnızca belirli problemlili koşullarda sınırlı hatalar gösterdiğini ortaya koymaktadır.



Şekil 24. Düşük kontrastlı ve yuva üzerinde vidaların bulunduğu X-ışını görüntülerinde hatalı tespit örnekleri

3.4. Aşınma Analiz Sonuçları

Bu bölümde femoral başın yuva içerisindeki konum değişimleri superior (yukarı yönde) ve medial (sağa–sola doğru) aşınma açısından değerlendirilmiştir. Yapılan analizlerde, takip çekimlerinde femoral başın hem üst boşlukta daralma gösterdiği hem de merkezin sağa veya sola kaydığı gözlemlenmiştir. Bu değişimler, protezde zamanla meydana gelen aşınmanın farklı yönlerde kendini gösterebildiğini ortaya koymaktadır.


Hastaların iki farklı zaman noktasına ait (Hemen sonra ve Sonra) görüntüleri karşılaştırıldığında, aşınma eğilimleri açıkça belirginleşmiştir. Hemen sonra görüntülerinde femoral baş ile yuva arasındaki boşluk düzenli ve dengeli iken, Sonra görüntülerinde ise üst boşlukta daralma ve merkezin yana doğru kayması dikkat çekmektedir. Böylece hem superior hem de medial yöndeki aşınma görsel olarak doğrulanmıştır.

Model, bu değişimleri doğru biçimde yakalamış ve tespit edilen daireler üzerinden yapılan ölçümler tablo hâlinde aşağıda sunulmuştur (Tablo 5, Tablo 6 ve Tablo 7). Bu sayede hem görsel hem de tablo verileri bir araya getirilerek aşınmanın yönü ve ilerleyişi bütüncül şekilde değerlendirilmiştir.

Not: Bu çalışmada elde edilen aşınma değerleri piksel cinsinden hesaplanmıştır. Ancak görüntüleme sistemine ait büyütme faktörü bilindiğinde, piksel–milimetre dönüşümü kolayca yapılabilmektedir. Böylece aynı ölçümler mm cinsine çevrilerek klinik olarak daha anlamlı sonuçlar elde edilebilir.

Hemen Sonra (A)

Sonra (B)




Şekil 25. Hemen sonra ve sonra elde edilen görüntülerde femoral baş ve yuva tespitleri ve Aşınma 1. Örnek

Şekil 25'te Yeşil daire femoral başı, sarı daire ise yuva sınırını temsil etmektedir. Hemen sonra elde edilen ilk görüntüde femoral baş yuva içinde düzenli konumlanmış ve merkezler uyumlu görünmektedir. Daha sonra elde edilen ikinci görüntüde ise femoral başın yuva tavanına daha yakın hale geldiği görülmekte, bu durum superior boşluğun daralmasına ve superior yönde aşınmaya işaret etmektedir. Ayrıca ikinci görüntüde femoral baş merkezinin yana kaydığı dikkati çekmekte, bu da medial yönde meydana gelen aşınmayı ortaya koymaktadır. Böylece iki zaman noktasının karşılaştırılmasında femoral başın hem yukarı hem de yana doğru yer değiştirdiği, yani aşınmanın zamanla ilerlediği net biçimde gözlenmiştir.

Tablo 5. Şekil 25 için Model tarafından otomatik hesaplanan ölçümler ve nihai aşınma

Parametre	Hemen sonra (A)	Sonra (B)	Sonra (B to A, ölçeklenmiş)	Aşınma
Femoral yarıçap (px)	74.425153	70.160508	74.425153	—
Ölçek faktörü (B→A)	—	1.060784	1.060784	—
Merkezler arası mesafe (px)	6.184893	11.878518	12.600541	6.415648 (medial)
Superior boşluk (px)	43.897086	44.981593	47.715753	3.818667 (superior)
Genel aşınma (px)	—	—	—	7.466107

Hemen sonra x-ışını görüntüsü (A) 30 ay sonraki x-ışını görüntüsü (B)



Şekil 26. Hemen sonra ve sonra elde edilen görüntülerde femoral baş ve yuva tespitleri ve Aşınma 2. Örnek


Şekil 26'da aynı hastanın iki farklı zamanda çekilen kalça röntgenleri görülmektedir. Şekil 26 (A) (ameliyattan hemen sonra) görüntüsünde protez parçaları uyumlu bir şekilde yerleştirilmiştir. Femoral baş ile yuva arasında düzenli ve eşit boşluklar vardır ve kayma ya da yer değiştirme gözlenmemektedir.

Şekil 26 (B) (30. ay kontrolü) görüntüsünde ise femoral başın yukarıya doğru hafifçe kaydığı görülmektedir. Bu, yuva tavanındaki boşluğun daralmasına, alt kısımdaki boşluğun ise daha geniş görünmesine yol açmaktadır. Bu durum, zamanla ortaya çıkan superior (yukarı yönlü) polietilen aşınmasının göstergesidir. Ayrıca femoral başın merkezin hafifçe yana kaydığı dikkati çekmektedir. Bu da boşluğun yan (medial) tarafta daraldığını, yani medial yönde aşınma geliştiğini göstermektedir.

Dolayısıyla başlangıçta simetrik olan boşluk, zamanla hem yukarı hem de yana doğru yer değiştirme nedeniyle asimetrik hale gelmiştir. Bu karşılaştırmalı filmler, protezin ilk hali ile sonraki durumunu ortaya koyarak aşınmanın yönünü net biçimde göstermektedir. Burada da 30 aylık süreçte aşınmanın superior-medial yönde ilerlediği açıkça izlenmektedir.

Tablo 6. Şekil 26 için Model tarafından otomatik hesaplanan ölçümler ve nihai aşınma

Parametre	Hemen Sonra (A)	Sonra (B)	Sonra (B→A, ölçeklenmiş)	Aşınma (px)
Femoral yarıçap (px)	126.310866	123.661418	126.310866	—
Ölçek faktörü (B→A)	—	—	1.021425	—
Merkezler arası mesafe (px)	4.976189	10.775240	11.006099	6.029910
Superior boşluk (px)	73.828397	73.340661	74.911986	1.083589
Genel aşınma (px)	—	—	—	6.126498



Şekil 27. Hemen sonra ve sonra elde edilen görüntülerde femoral baş ve yuva tespitleri ve Aşınma 3. Örnek

Şekil 27’de ameliyat sonrası ve takip filmi karşılaştırıldığında protezin genel uyumunun korunduğu görülmektedir. İlk filmde femoral baş yuva içinde düzenli ve merkezlenmiş durumdadır. Takip filminde ise başın konumu büyük ölçüde korunmakla birlikte, dikkatli incelendiğinde çok hafif bir yukarı ve yana doğru kayma göze çarpmaktadır.

Bu değişiklik çıplak gözle belirgin değildir ve çoğu durumda normal varyasyon aralığındadır. Ancak modelimiz, bu tür ince farkları güvenle tespit edip hesaplar.

Tablo 7. Şekil 27 için Model tarafından otomatik hesaplanan ölçümler ve nihai aşınma

Parametre	Hemen Sonra (A)	Sonra (B)	Sonra (B→A, ölçeklenmiş)	Aşınma (px)
Femoral yarıçap (px)	60.609556	103.358213	60.609556	—
Ölçek faktörü (B→A)	—	—	0.586403	—
Merkezler arası mesafe (px)	3.875860	7.182130	4.211622	0.335762
Superior boşluk (px)	45.023730	78.167261	45.837509	0.813778
Genel aşınma (px)	—	—	—	0.880325

4. TARTIŞMA

Bu çalışma, kalça protezli hastalarda ameliyat sonrası ve takip dönemine ait radyografilerin karşılaştırılması yoluyla aşınmanın yönü ve büyüklüğünü otomatik ve nesnel biçimde belirlemeyi hedeflemektedir. Bu amaç doğrultusunda femoral baş ve AY sınırları dairesel parametrelerle modellenmiştir. Aday bölgelerin belirlenmesinde YOLOv5 tabanlı nesne tespiti, sınırların kesinleştirilmesinde ise Canny kenar çıkarımı, Hough-daire dönüşümü ve RANSAC tabanlı uyumlama yöntemlerinin birlikte kullanıldığı hibrit bir yaklaşım geliştirilmiştir.

YOLO tarafından önerilen bölgelerde öncelikle kenarlar Canny algoritması ile çıkarılmış, ardından farklı eşik değerleri ve açısal aralıklar denenerek Hough tabanlı daire adayları elde edilmiştir. Bu adaylar daha sonra RANSAC yöntemiyle rafine edilmiş ve elde edilen dairelerin güvenilirliği çeşitli ölçütlerle değerlendirilmiştir. Bu ölçütler arasında, daire üzerindeki nokta uyumu (inlier oranı), kenar yoğunluğu, kenar gradyanlarının daire normaliyle hizalanma derecesi ve çevresel kapsama miktarı yer almıştır. Bunun yanı sıra, hatalı tespitlerin elenebilmesi için olumsuz durumları dikkate alan ek değerlendirmeler yapılmıştır. Örneğin, dairenin kenar sinyali yalnızca küçük bir bölümde ortaya çıkıyor ve çevresel süreklilik göstermiyorsa, bu adayın güvenilirliği düşük kabul edilmiştir. Benzer şekilde, kenar gradyanlarının yönü dairenin normaline uygun değilse ya da kenar noktaları daire boyunca dengeli dağılmak yerine belirli bir bölgede aşırı yoğunlaşmışsa, bu adaylar da uygun görülmemiştir. Ayrıca protez anatomisine aykırı olan durumlar – örneğin yuva dairesinin femoral baştan daha küçük çıkması veya iki dairenin üst üste binmesi – otomatik olarak geçersiz kabul edilmiştir. Böylece yalnızca anatomik olarak anlamlı ve geometrik olarak tutarlı daireler seçilerek nihai tespit yapılmıştır.

Dairesel etiketlerin YOLO mimarisiyle uyumluluğunu sağlamak amacıyla daireden kutuya dönüşümü gerçekleştirilmiş; böylece hem dairesel (x, y, r) hem de kutusal temsiller üzerinden eğitim ve çıktı uyumu sağlanmıştır. Son aşamada ise ölçekleme (Sonra X-Işınından Hemen sonraya X-Işını) ve geometrik normalizasyon adımları uygulanarak farklı çekim pozisyonları ve radyografik varyasyonların etkisi en aza indirgenmiştir.

Elde edilen sonuçlar, geliştirilen yöntemin farklı zaman noktalarındaki değişimleri güvenilir biçimde yakalayabildiğini göstermektedir. Görsel örnekler ve tablolar birlikte değerlendirildiğinde, aşınmanın yönü (özellikle superior veya medial) ve ilerleyişi bütüncül

bir şekilde ortaya konmuştur. Ölçümlerin piksel cinsinden raporlanması, görüntüleme sisteminin büyütme faktörü bilindiğinde değerlerin doğrudan milimetre cinsine dönüştürülmesine olanak tanımış ve böylece elde edilen sonuçların klinik anlam kazanmasına katkı sağlamıştır.

Vaka incelemeleri, geliştirilen yöntemin klinik pratikteki değerini açık biçimde ortaya koymuştur. Şekil 25'te ameliyat sonrası elde edilen ilk radyografide femoral baş ile AY merkezlerinin uyumlu olduğu görülmektedir. Ancak takip döneminde kaydedilen görüntüde femoral başın yuva tavanına doğru yaklaştığı ve bu nedenle üst boşluğun daraldığı, aynı zamanda yan yönde kayma gösterdiği dikkat çekmektedir. Bu bulgular, aşınmanın hem superior hem de medial yönde gerçekleştiğini ortaya koymaktadır. Bulguların sayısal karşılığı Tablo 5'te verilmiştir. Ölçekleme adımı sonrasında elde edilen merkezler arası mesafe ve superior boşluk ölçümleri, başlangıç filminde gözle seçilmesi zor olan küçük farklılıkların dahi sayısallaştırılarak güvenilir biçimde raporlanabildiğini göstermektedir.

Benzer şekilde, Şekil 26'da ameliyattan hemen sonra elde edilen radyografide femoral başın yuva içinde konsantrik konumlandığı, ancak 30. ay kontrolünde yukarıya doğru kayma gösterdiği ve buna bağlı olarak alt boşluğun genişlediği gözlenmiştir. Bu görsel bulgular, Tablo 6'deki ölçeklenmiş ölçümlerle desteklenmiştir. Femoral yarıçap referans alınarak hesaplanan ölçek faktörü, merkez mesafesi ve superior boşluk değerleri, değişimin hem yönünü hem de büyüklüğünü net biçimde ortaya koymuştur. Görsel ve sayısal çıktının birlikte sunulması, yöntemin erken dönemdeki küçük değişiklikleri yakalama gücünü artırarak klinik takibe önemli katkı sağlamaktadır.

Elde edilen bu sonuçların, literatürde sıkça tanımlanan superior–medial aşınma paternleriyle uyumlu olması yöntemin güvenilirliğini pekiştirmiştir. Bununla birlikte, bazı vakalarda gözlenen değişimlerin sınırlı kalması ya gerçekten düşük aşınmaya ya da çekim tekniği ve hasta pozisyonundaki farklılıklara işaret edebilmektedir. Bu nedenle, karşılaştırmalı değerlendirmelerde aynı merkezde, benzer pozisyon ve odak–film mesafesiyle çekilmiş seri görüntülerin kullanılması kritik önem taşımaktadır. Çalışmada kullanılan standart raporlama biçimi ve piksel→mm dönüşüm olanağı bu ihtiyacı karşılayacak şekilde tasarlanmış ve yöntemin güvenilirliğini güçlendirmiştir.

Yöntemin klasik yaklaşımlarla karşılaştırmalı değerlendirmesinde birkaç nokta öne çıkmaktadır. Öncelikle, manuel yöntemlerde (ör. Charnley, Livermore) ölçüm tamamen kullanıcıya bağlıdır. Ölçüm sırasında çizgi veya nokta işaretlemelerinin farklı araştırmacılar arasında değişmesi, gözlemciler arası tutarsızlığa yol açmakta; bu da yöntemin

güvenilirliğini azaltmaktadır. Ayrıca manuel ölçümler zaman alıcıdır ve büyük vaka serilerinde pratik değildir.

Bilgisayar destekli klasik yazılımlar (ör. Martell, Devane) her ne kadar manuel ölçüm hatalarını azaltmaya yönelik geliştirilmiş olsa da belirli sınırlılıklar taşımaktadır. Bu yöntemlerde protez bileşenlerinin tespiti için herhangi bir model eğitimi yapılmaz. Sistemler kendi başına femoral baş veya AY sınırlarını otomatik olarak bulmaz. Bunun yerine kullanıcıdan belirli referans noktalarının manuel olarak işaretlenmesi beklenir.

Devane yöntemi genellikle AY kenarının belirli noktalarının ve femoral baş sınırlarının kullanıcı tarafından işaretlenmesiyle başlar. Yazılım, bu işaretlenen noktalar üzerinden geometriyi hesaplar ve aşınma miktarını çıkarır. Bu nedenle süreç tamamen otomatik değildir; ölçümlerin doğruluğu, kullanıcı işaretlemelerinin doğruluğuna doğrudan bağlıdır.

Martell yöntemi, kullanıcı müdahalesine dayalı bir ölçüm yaklaşımıdır. İlk adımda radyografi yazılım arayüzüne yüklenir ve kullanıcıdan belirli anatomik noktaların işaretlenmesi istenir. Bu noktalar genellikle asetabular kenarın belirli bölgeleri, femoral baş sınırının konturları ve gerekirse pelvisle sabit çizgilerdir. Yazılım bu işaretlemeleri temel alarak hesaplama yapar ve protez aşınmasını değerlendirir.

Bunun yanı sıra, Martell yazılımı kullanıcıya yalnızca önceden tanımlı seçenekler sunar. Parametrelerin esnek biçimde değiştirilmesine ya da alternatif algoritmaların denenmesine imkân tanımaz. Ölçüm süreci, yazılımın öngördüğü sabit akış üzerinden ilerler. Bu nedenle sonuçlar kısmen standartlaşmış olsa da kullanıcıdan bağımsız, tamamen otomatik bir sistem değildir.

Bu nedenlerle Martell ve Devane yöntemleri tam otomasyon sağlamamaktadır. Ek yazılım kurulumu, kullanıcı etkileşimi ve işletim sistemi bağımlılığı gerektirmekte; ayrıca gözlemciye bağlı farklılıklar tamamen ortadan kaldırılamamaktadır.

Bu çalışmada geliştirilen yöntem, önceden eğitilmiş YOLOv5 tabanlı bir model aracılığıyla femoral baş ve yuva için aday bölgeleri otomatik olarak tespit eder. Ardından kenar analizi, Hough dönüşümü ve RANSAC tabanlı uyumlama ile bu bölgeler rafine edilerek en uygun daireler seçilir. Bu süreçte kullanıcıdan herhangi bir referans noktası girişi gerekmediğinden ölçümler baştan sona tam otomatik olarak yürütülmektedir.

Güçlü yönler açısından bakıldığında:

1) Otomatik işleme ve tekrarlanabilirlik:

Görüntülerin otomatik olarak işlenmesi sayesinde kullanıcıya bağlılık büyük ölçüde azaltılmaktadır. Böylece gözlemciler arası farklılıklar en aza indirilirken, aynı verinin farklı kişiler tarafından tekrarlandığında benzer sonuçlar üretmesi sağlanmaktadır. Bu durum, klinik karar desteğinde güvenilirlik ve standardizasyon açısından önemli bir avantaj sunmaktadır.

2) Hibrit akış ve zorlu görüntülerde yüksek doğruluk:

Yöntem yalnızca tek bir algoritmaya dayanmamış; YOLOv5 tabanlı nesne tespiti, kenar analizi, RANSAC tabanlı uyumlama ve anatomik kısıtlamalar bir arada kullanılmıştır. Bu hibrit yaklaşım, özellikle düşük kontrastlı görüntülerde ya da vida gibi metalik artefaktların bulunduğu protezlerde tespit başarısını artırmaktadır. Böylece klinikte sık karşılaşılan zorlu senaryolarda da güvenilir sonuçlar elde edilebilmektedir.

3) Dairesel modelleme ve klinik anlamlılık:

Femoral baş ve AY ilişkisi dairesel parametrelerle modellenmiştir. Bu sayede merkez koordinatları, yarıçap değerleri ve üst boşluk ölçümleri doğrudan klinik açıdan anlamlı parametreler olarak raporlanabilmektedir. Özellikle aşınmanın yönü ve büyüklüğünün dairesel geometriler üzerinden takip edilmesi, protezin fonksiyonel değerlendirilmesini kolaylaştırmaktadır.

4) Standartlaştırılmış çıktı ve çok merkezli kullanım imkânı:

Yöntemin çıktıları standardize edilmiştir; sonuçlar hem görsel (şekil bindirmeleri) hem de sayısal (.txt) formatta sunulmaktadır. Ayrıca ölçümler piksel cinsinden raporlanmakta, görüntüleme sisteminin büyütme faktörü bilindiğinde milimetreye dönüştürülebilmektedir. Bu özellik, farklı merkezlerde veya farklı cihazlarda elde edilen görüntülerin karşılaştırılmasına olanak tanımakta ve yöntemin çok merkezli çalışmalara kolayca entegre edilmesini sağlamaktadır.

Sınırlıkları ise, bu çalışmanın temel sınırlılığı, yöntemin yalnızca iki boyutlu (2B) radyografik görüntüler üzerinden uygulanmış olmasıdır. Radyografi, kalça protezlerinin konumunu ve aşınma yönünü değerlendirmede yaygın, düşük maliyetli ve erişilebilir bir yöntemdir; ancak elde edilen bilgiler tek bir düzlemle sınırlıdır. Bu nedenle femoral baş ile AY arasındaki ilişkinin yalnızca AP projeksiyon üzerinden yorumlanabilmesi, üç boyutlu (3B) yapısal değişikliklerin, derinlik boyutunun ve rotasyonel farklılıkların doğrudan ortaya konmasına izin vermemektedir.

Yöntem, femoral baş ve AY sınırlarını yüksek doğrulukla belirleyerek protez–kemik ara yüzeyindeki geometrik değişimleri sayısallaştırabilse de, ölçümler yalnızca 2B düzlemde elde edilen verilerle sınırlıdır. Dolayısıyla yumuşak doku durumu, kemik yoğunluğu farklılıkları veya 3B morfolojik değişimler bu yaklaşımın kapsamı dışında kalmaktadır.

Tablo 8. Kalça protezi aşınma ölçümünde kullanılan yöntemlerin karşılaştırmalı özellikleri

Özellik / Yöntem	Manuel Yöntemler (Charnley, Livermore)	Bilgisayar Destekli Yöntemler (Martell, Devane)	Bu Çalışma (YOLOv5 + Kenar Analizi + RANSAC)
Çalışma Mantığı	Protez sınırları cetvel, kumpas veya manuel çizgilerle ölçülür.	Kullanıcı, asetabular kenar ve femoral baş için referans noktalarını işaretler, yazılım bu noktaları baz alarak geometrik analiz yapar.	Eğitilmiş YOLOv5 modeli aday bölgeleri otomatik tespit eder; Canny, Hough ve RANSAC ile en uygun daireler seçilir.
Kullanıcı Müdahalesi	Yüksek (tamamen kullanıcıya bağlıdır).	Orta (referans noktalarının manuel işaretlenmesi gerekir).	Yok (tam otomatik, kullanıcıdan işaretleme gerekmez).
Otomasyon Düzeyi	Yok	Kısmi	Tam otomatik
Geometri Temsili	Çizgi ve mesafe ölçümü, dairesel yapı doğrudan modellenmez.	Daire tabanlı analiz. Kullanıcı daire parametreleri manuel girer	Dairesel parametreler (merkez, yarıçap, boşluk) doğrudan modellenir.
Kullanıcıya Bağımlılık	Çok yüksek, gözlemciler arası farklılık fazladır.	Orta, girilen referans değerlerine göre farklılıklar olabilir.	Çok düşük, aynı veri üzerinde tekrarlanabilir sonuçlar.
İşletim Sistemi / Platform	Kâğıt, film, basit ölçüm araçları.	Çoğunlukla Windows tabanlı yazılımlar, kısıtlı algoritmik seçenekler.	Python tabanlı, farklı platformlarda çalışabilir.

Tablo 8'in devamı

Zaman / İş Yüğü	Yüksek (ölçümler uzun sürer).	Orta (işaretleme + yazılım analizi).	Düşük (tam otomatik, hızlı işlem).
Doğruluk	Gözlemciye bağı, düşük-orta.	Orta-yüksek, ancak kullanıcı işaretlemlerine bağı.	Yüksek, özellikle düşük kontrastlı ve vidalı protezlerde güvenilir.
Standardizasyon	Zor, ölçüm kişiye göre değışir.	Belirli ölçüm akışına bağı, sınırlı standardizasyon.	Standardize çıktı: görsel (şekil) + sayısal (piksel).
Kapsam	2B radyografi, yalnızca manuel ölçümler.	Martell: 2.5B (tek projeksiyon + geometrik tahmin), Devane: 3B (AP + Yan radyografiler).	2B radyografi, otomatik tespit ve dairesel parametrelerle analiz.
Kısıtlılıklar	Kullanıcı hatası, düşük tekrar edilebilirlik.	Tam otomatik değıldir, yazılım seçenekleri sınırlıdır.	Yalnızca 2B veriye dayanır, 3B yapısal değışiklikleri göstermez.

5. SONUÇLAR

Bu çalışma, kalça protezli hastaların takibinde aşınma sürecinin yönünü ve büyüklüğünü, rutin radyografiler üzerinden nesnel ve tekrarlanabilir biçimde izlemeyi mümkün kılan bir ölçüm–raporlama çerçevesi ortaya koymuştur. Elde edilen görsel bindirmeler ile sayısal çıktılar birlikte değerlendirildiğinde, gözle fark edilmesi güç küçük değişimlerin dahi tutarlı biçimde yakalandığı zaman içindeki ilerleyişin klinik karar vermeyi kolaylaştıracak açık bir dil ve standart bir format içinde sunulabildiği gösterilmiştir. Ölçümlerin piksel tabanlı üretilmesi ve gerektiğinde milimetreye dönüştürülebilmesi, farklı cihaz ve merkezlerden gelen görüntülerin karşılaştırılabilir kılınmasına olanak tanımıştır. Vaka bazlı yorumlar böylece kurumsal düzeyde standart bir izlem pratiğine dönüşebilecektir.

Klinik açıdan en belirgin kazanım, erken ve küçük değişimlerin güvenilir şekilde saptanmasıdır. Böylece izlem aralıkları hasta özelinde yeniden düzenlenebilir. ‘Stabil’, ‘sınırdaki’ ve ‘ilerleyen’ gibi pratik takip kategorileri aynı ölçütler üzerinden tanımlanabilir ve olası revizyon gereksinimleri gecikmeden gündeme alınabilir. Çıktıların hem görsel hem de sayısal üretilmesi, konsültasyonlarda ortak bir referans çerçevesi sağlar. Farklı hekimler aynı hastanın seyrini aynı metriklerle tartışabilir. Bu durum yalnızca kararın hız ve isabetini artırmakla kalmaz, gözlemciye bağlı değişkenliği azaltarak kayıt kalitesini yükseltir ve izlem sürecini hukuki açıdan da güçlendirir. Ayrıca standart rapor yapısı, gereksiz tekrar görüntülemelerin önüne geçilmesine katkı sağlar. İzlem lojistiğinde kaynak kullanımını rasyonelleştirir ve hasta deneyimini iyileştirir. Sonuçların merkezler arası uyumlu biçimde paylaşılması, çok merkezli çalışmalara doğrudan katkı sunar. Tekil olgular yerine geniş hasta gruplarında anlamlı eşik değerlerinin sınırlanmasını ve kurumlar arası kalite göstergelerinin karşılaştırılmasını mümkün kılar.

Geleceğe dönük katkılar, bu çerçevenin klinik karar destek sistemleriyle bütünleşmesi ve çok boyutlu doğrulamalarla güçlenmesi etrafında şekillenmektedir. Kısa vadede, çıktıların risk gruplandırma ve izlem önerisi eşikleri eklenmesi, sonuçların yalnızca betimleyici olmaktan çıkıp yol gösterici hale gelmesini sağlayacaktır. Elektronik hasta kaydı (EHK) ile entegrasyon, belirlenen eşikleri aşan hastalar için otomatik uyarılar ve randevu hatırlatıcıları üreterek bakım sürekliliğini destekleyebilir. Orta vadede, farklı protez tasarımları ve cerrahi tekniklerden derlenecek çok merkezli arşivlerle normatif aralıklar ve klinik açıdan anlamlı

değişim eşikleri kanıta dayalı biçimde tanımlanabilir. Böylece izlem kararları daha homojen ve öngörülebilir bir zemine oturur. Üç boyutlu bilgi eklenerek yapılacak geliştirmeler (farklı projeksiyonların sistematik kullanımı ya da bilgisayarlı tomografi ve manyetik rezonans ile doğrulama) rotasyon ve derinlik bileşenlerinin yorumunu güçlendirerek, iki boyutlu ölçümlerin doğal belirsizliklerini azaltacaktır. Bu güncellemelerin kurum içi kalite güvencesi adımlarıyla (pozisyonlama kontrol listeleri, büyütme kalibrasyonu kaydı, minimum görüntü kalitesi ölçütleri) desteklenmesi, zaman içinde ve operatörler arasında ölçümlerin tutarlılığını artıracaktır. Uzun vadede, ardışık ölçümlerin birikimli analiziyle öngörücü izlem stratejileri (örneğin belirli bir hızın üzerindeki değişikliklerde erken müdahale) geliştirilebilir; böylece sistem yalnızca mevcut durumu raporlayan değil, aynı zamanda ileriye dönük risk hakkında bilgi veren bir karar destek bileşenine dönüşür.

Özetle, bu tez klinik pratiğe doğrudan uyarlanabilir, merkezler arası standardize ve karşılaştırılabilir çıktılar üreten, erken uyarı kapasitesi yüksek bir takip çerçevesi sunmuştur. Elde edilen sonuçlar, hasta güvenliğini artıran, ekip içi iletişimi güçlendiren ve çok merkezli iş birliklerine kapı aralayan bir ölçüm dilinin mümkün olduğunu göstermektedir; kapsamı genişletildikçe bu dilin, günlük iş akışlarında karar verici bir role taşınması beklenir.

6. ÖNERLER

Klinikte sürdürülebilir bir kullanım için ilk adım, çekim ve raporlama sürecini baştan sona standardize etmektir. Radyografi protokolünde tek merkezde bile değişkenlik yaratabilen ayrıntılar (kaynak–film mesafesi, AP pozisyonlaması, pelvis rotasyonunun kontrolü, kalçanın hafif internal rotasyonu, uygun doz ve kontrast) kontrol listesiyle güvence altına alınmalıdır. Her çekimde büyütme kalibrasyonunun yapılabilmesi için, görüntü alanına bilinen çapta referans cisim (ör. metal bilye) yerleştirilmeli ve Tıpta Dijital Görüntüleme ve İletişim (DICOM) meta verileri eksiksiz saklanmalıdır. Çekim reddi ve tekrarı, pozisyonlama sapması ve kalibrasyon eksikleri için haftalık bir kalite incelemesi ve yürütülmesi, zaman içinde ölçüm güvenilirliğini artıracaktır.

Raporlama tarafında, çıktıların yapılandırılmış bir şablon ile üretilmesi önerilir: tarih/karşılaştırılan muayeneler, ölçek ya da kalibrasyon bilgisi, femoral baş ve AY merkez, yarıçap parametreleri, superior ve medial boşluk ölçümleri ve iki zaman noktası arasındaki değişimin yön–büyüklük özeti aynı sırayla sunulmalıdır. Bu metriklerin yanında, bindirmeli görselin küçük bir rapor eki olarak yer alması, metin ve sayısal değerlere hızlı doğrulama imkânı verir. Çıktılarda kullanılan sürüm ve algoritma kimliği (yazılım sürümü/tarih damgası) belirtilmeli; böylece geriye dönük denetimde hangi sürümle üretildiği izlenebilir olmalıdır.

Günlük iş akışında verim için, EHK sistemiyle çift yönlü entegrasyon tercih edilmelidir: önceki muayeneler otomatik eşleştirilmeli, yeni film yüklendiğinde geçmiş görüntüler varsayılan olarak karşılaştırma modunda açılmalı ve ölçüm çıktıları hasta kaydına otomatik eklenmelidir. Klinik onay akışı “teknik ön rapor, hekim gözden geçirme, final onay” biçiminde tanımlanmalıdır. Ölçümde insan denetimi korunmalı ve olağan dışı durumlarda (pozisyonlama hatası, artefakt, çok düşük kontrast) manuel kontrol tetiklenmelidir. Böyle durumlar için rapor şablonunda “uyarı/yorum” alanı bulunmalı ve olası sınırlılıklar kısa notla belirtilmelidir.

Merkezler arası kullanım planlanıyorsa, ortak bir veri sözlüğü ve değişmez ölçüm isimlendirmesi benimsenmeli; tüm merkezlerde aynı referans cismi, aynı çekim kontrol listesi ve aynı raporlama şablonu kullanılmalıdır. Yılda en az bir kez çok merkezli kalibrasyon deneyi (ortak örnek seti) yapılarak sapmalar ölçülmeli ve kabul edilebilir sınırlar

kurumlarca mutabakata bağlanmalıdır. Paylaşımlı veri akışında kimliksizleştirme, erişim yetkileri ve denetim kayıtları kurumsal politika ile güvenceye alınmalıdır.

Klinik kararları desteklemek üzere, ardışık ölçümlerin zaman içi eğilimini değerlendiren basit ama etkili araçlar kullanılabilir. Örneğin, hasta bazında değişim hızını (mm/yıl) gösteren çizelge ve kararlılık grafikleri rapor sonuna otomatik eklenebilir. Bu grafikler klinisyen tarafından kolayca yorumlanabilmelidir. Sayısal gürültü ile klinik açıdan anlamlı sapmayı ayırt etmeye yardımcı olmalıdır. Her kurum, kendi hasta popülasyonundan elde edeceği dağılımlara dayanarak asgari raporlanabilir değişim (ör. ölçüm hatası üzerinde kalan en küçük fark) ve teknik uyarı sınırı gibi pratik eşikleri tanımlamalıdır. Bu eşikler, karar verme süreçlerine rehberlik edecek ama nihai klinik kararı hiçbir zaman otomatikleştirmeyecek şekilde konumlandırılmalıdır.

Doğrulama ve izleme için prospektif bir kayıt tutulması önerilir. Seri radyografiler, ölçümler, klinik sonuçlar (semptom, revizyon, komplikasyon) ve çekim kalite notları aynı tabloda biriktirilmelidir. Periyodik analizlerde ölçüm tekrarlanabilirliği (aynı-farklı gözlemci), yöntem-yöntem kıyasları (ör. seçili alt grupta 3B referansla) ve performans sapması (zaman içinde başarı/yanılma oranı) raporlanmalıdır. Yazılım güncellemeleri öncesi ve sonrasında sürüm karşılaştırması yapılmalıdır. Değişimin ölçüme etkisi, göstergelerle belgelenmelidir.

Eğitim boyutunda, teknisyen ve hekimler için kısa modüller hazırlanmalıdır: çekim kontrol listesi, sık hata örnekleri, iyi/kötü kalite referansları, rapor okuma pratiği ve vaka üzerinden uygulama. Yeni başlayan merkezler için “ilk 20 vaka” izleme programı önerilir. Bu dönemde raporlar eş zamanlı ikinci bir gözle doğrulanır, gerekirse parametreler kurum profilini yansıtacak şekilde yeniden ayarlanır.

Veri Setinin Genişletilmesi ve Çeşitlendirilmesi Bu çalışmada, modelin eğitimi için toplam 50 adet X-ışını görüntüsü kullanılmıştır. Modelin genel performansı yüksek olsa da özellikle kontrastın çok düşük olduğu veya yuva bölgesinde metal vidaların bulunduğu zorlayıcı vakalarda hatalı tespitler gözlemlenmiştir. Gelecekte yapılacak çalışmalarda, yöntemin genelleme kabiliyetini ve zorlu koşullardaki dayanıklılığını artırmak için veri setinin hem nicelik hem de nitelik olarak zenginleştirilmesi önerilmektedir. Farklı markalara ait implant tiplerini, çeşitli aşınma seviyelerini ve nadir görülen anatomik varyasyonları içeren daha geniş ve çeşitli bir veri setiyle modelin yeniden eğitilmesi, klinik pratikte karşılaşılabilecek daha geniş bir yelpazedeki durumlara karşı sistemin doğruluğunu ve güvenilirliğini önemli ölçüde artıracaktır.

Farklı DÖ Mimarilerinin Denenmesi Mevcut çalışmada, nesne tespiti için YOLOv5 mimarisi temel alınmış ve bu mimari hibrit bir yaklaşımla desteklenmiştir. Bu yaklaşım başarılı sonuçlar üretmiş olsa da gelecekteki araştırmalarda alternatif DÖ mimarilerinin denenmesi, potansiyel performans artışları sağlayabilir. Özellikle, protez sınırlarını bir bölge olarak değil, piksel piksel tanımlayabilen U-Net gibi segmentasyon tabanlı modellerin kullanılması, dairesel yapıların daha hassas bir şekilde belirlenmesine olanak tanıyabilir. Benzer şekilde, görüntüdeki global ilişkileri daha etkin bir şekilde modelleyebilen Transformer tabanlı yeni nesil nesne tespit mimarilerinin bu özel probleme uyarlanması, yöntemin doğruluğunu ve verimliliğini daha ileri bir seviyeye taşıma potansiyeli sunmaktadır.

Son olarak, yöntemin iki boyutlu veriye dayalı olduğu unutulmamalı; rotasyon ve derinlik duyarlılığı gerektiren kuşku olgularda destekleyici inceleme (farklı projeksiyon, uygun görülen durumlarda 3B yöntemlerle doğrulama) istenmelidir. Bu yaklaşım, ölçümlerin güven sınırlarını aşmadan, klinik gerçeklikle uyumlu ve ihtiyatlı bir kullanım kültürü oluşturacaktır. Bu öneriler bir arada uygulandığında, izlem süreçleri ölçülebilir, karşılaştırılabilir ve denetlenebilir bir yapıya kavuşur; kurum içi–kurumlar arası tutarlılık ve hasta güvenliği somut biçimde güçlenir.

7. KAYNAKLAR

- Al-Hassan, A., Al-Sayyed, R., & Obeidat, A. (2024). Optimizing Deep Learning Models with Early Stopping: A Medical Imaging Case Study. *Journal of Artificial Intelligence in Medicine*, 18(2), 112-125.
- Aydin, B., Kaya, M., & Demir, E. (2023). Machine Learning Applications in Orthopedic Imaging: A Review. *Computers in Biology and Medicine*, 155, 106-118.
- Bae, J. Y., Park, C. H., & Kim, D. H. (2022). Analysis of Polyethylene Wear in Total Hip Arthroplasty: A 10-Year Follow-Up Study. *Journal of Orthopaedic Surgery*, 30(1), 45-52.
- Borjali, A., Chen, A. F., & Muratoglu, O. K. (2020). Deep Learning for Automated Measurement of Femoral Head Penetration in Total Hip Arthroplasty. *Journal of Arthroplasty*, 35(8), 2184-2190.
- Bowman, K. F., Fox, J. A., & Sekiya, J. K. (2010). A clinically relevant review of hip biomechanics. *Arthroscopy: The Journal of Arthroscopic & Related Surgery*, 26(8), 1118-1129.
- Cabitza, F., Rasoini, R., & Gensini, G. F. (2018). Unintended Consequences of Machine Learning in Medicine. *JAMA*, 320(10), 981-982.
- Callaghan, J. J., Liu, S. S., & Firestone, D. E. (2016). The Role of Polyethylene Crosslinking on the Wear Performance of Total Hip Arthroplasty. *JBJS Reviews*, 4(7), e1-e10.
- Clohisey, J. C., Calvert, G., & Tuan, R. S. (2024). Biological Responses to Orthopedic Implant Wear Debris: Mechanisms and Clinical Implications. *Journal of Bone and Joint Surgery*, 106(4), 345-356.
- Devane, P. A., Horne, J. G., & Adams, K. (2017). A New 3D Method for Measuring Polyethylene Wear in Total Hip Arthroplasty. *The Journal of Arthroplasty*, 32(4), 1327-1332.
- Erickson, B. J. (2020). Deep Learning in Medical Imaging: A Overview. *Radiology: Artificial Intelligence*, 2(2), e190-201.
- Galmiche, R., Dinh, A., & Belzile, E. L. (2020). Total Hip Arthroplasty: Surgical Technique and Overview of Implant Designs. *Orthopedic Clinics*, 51(2), 161-174.
- Garofalo, P., Bolognesi, M. P., & Ledford, C. K. (2025). Metal-on-Metal vs. Ceramic-on-Ceramic Bearings in Total Hip Arthroplasty: A Long-Term Comparative Analysis. *The Bone & Joint Journal*, 107-B(3), 321-330.

- Gong, Y., Wang, L., & Guo, R. (2022). The Impact of Batch Size on the Training of Deep Neural Networks for Medical Image Analysis. *IEEE Transactions on Medical Imaging*, 41(5), 1245-1255.
- Gorter, E. A., van der Voort, P., & Reijman, M. (2021). Ceramic-on-Ceramic Total Hip Arthroplasty: A Review of Modern Bearings. *Acta Orthopaedica*, 92(3), 235-241.
- Grillini, L., & Affatato, S. (2013). Wear Measurement in Total Hip Replacement: Historical Overview and State of the Art. InTech.
- Gürsel, A. (2023). Vitamin E ile Stabilize Edilmiş Polietilenin Kalça Protezlerinde Aşınma Performansı [Yayımlanmamış doktora tezi]. Hacettepe Üniversitesi.
- Hofbauer, M., Müller, M., & Chevalier, Y. (2023). Beyond Accuracy: Precision and Recall for Evaluating Medical Image Segmentation Models. *Medical Image Analysis*, 84, 102-115.
- HSS. (2024). Hip Replacement Wear and Osteolysis. Hospital for Special Surgery. https://www.hss.edu/conditions_hip-replacement-wear-osteolysis.asp adresinden 15 Mart 2025 tarihinde alınmıştır.
- Jang, S., Moon, S. E., & Lee, J. S. (2022). Effective Data Augmentation Strategies to Combat Overfitting in Deep Learning for Radiology. *Scientific Reports*, 12(1), 1-12.
- Johnson, A. J., & Souder, C. T. (2023). Total Hip Arthroplasty: Indications and Surgical Techniques. Elsevier Health Sciences.
- Karaoğlu, S., Tuncer, M., & Çay, N. (2017). Metal Prostheses Coated with Ceramic: An Experimental Wear Study. *Journal of Materials Science: Materials in Medicine*, 28(5), 1-9.
- Köken, Ö., & Kara, A. (2021). Radyografik Görüntülerde Kalça Protezi Aşınma Ölçüm Yöntemlerinin Karşılaştırılması. *Acta Orthopaedica et Traumatologica Turcica*, 55(1), 45-51.
- Kuru, T., Aydın, B., & Yılmaz, S. (2021). Kalça Protezi Aşınmasına Bağlı Osteoliz ve Revizyon Cerrahisi Deneyimlerimiz. *TOTBID Dergisi*, 20(3), 234-241.
- Kurtz, S. M., Gawel, H. A., & Patel, J. D. (2011). History and systematic review of wear and osteolysis outcomes for first-generation highly crosslinked polyethylene. *Clinical Orthopaedics and Related Research*, 469(8), 2262-2277.
- Leta, T. H., Lygre, S. H., & Hallan, G. (2023). Vitamin E-infused highly cross-linked polyethylene in total hip arthroplasty: A 10-year follow-up report. *The Journal of Arthroplasty*, 38(4), 789-794.

- Litjens, G., Kooi, T., & Bejnordi, B. E. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- Martell, J. M., Berkson, E., & Berger, R. (2010). Comparison of two and three-dimensional computerized polyethylene wear analysis after total hip arthroplasty. *The Journal of Bone and Joint Surgery*, 85(6), 1111-1117.
- McCalden, R. W. (2005). The Charnley method for measuring wear in total hip arthroplasty. *Clinical Orthopaedics and Related Research*, 437, 108-113.
- Min Lee, K., Park, J. H., & Kim, T. Y. (2022). Interobserver variability in radiographic wear measurement of total hip arthroplasty: a comparison of manual and computer-assisted methods. *HIP International*, 32(1), 88-95.
- Mirza, A. Z., Smith, B. P., & Johnson, R. M. (2010). Reliability of different methods for measuring polyethylene wear in total hip arthroplasty. *Journal of Orthopaedic Research*, 28(8), 1102-1107.
- Morano, T., Ricciardi, B. F., & Westrich, G. H. (2025). The Evolution of Acetabular Component Design in Total Hip Arthroplasty. *Journal of the American Academy of Orthopaedic Surgeons*, 33(1), e45-e54.
- Mulcahy, H., & Chew, F. S. (2012). Current concepts in hip arthroplasty imaging: radiographic evaluation of wear and osteolysis. *American Journal of Roentgenology*, 199(3), 558-567.
- Núñez-Gil, I., Pérez-Rodríguez, D., & Fernández-Jiménez, R. (2024). Determining the Optimal Number of Epochs for Training Deep Learning Models on Small Medical Datasets. *Artificial Intelligence in Medicine*, 148, 102-112.
- Pabinger, C., Lothaller, H., & Geissler, A. (2015). Utilization rates of hip arthroplasty in OECD countries: trends and explanatory factors. *Osteoarthritis and Cartilage*, 23(10), 1664-1673.
- Patel, R., Malhotra, R., & Smith, K. (2023). Pain and Functional Outcomes in Patients with Polyethylene Wear Following Total Hip Arthroplasty. *The Journal of Arthroplasty*, 38(2), 345-350.
- Rahman, L., Cobb, J. P., & Muirhead-Allwood, S. K. (2012). A review of radiographic methods for assessment of polyethylene wear in total hip arthroplasty. *The Hip*, 2(1), 1-12.
- Reddy, S., Fox, J., & Purohit, M. P. (2023). Deep learning algorithms for detection of radiographic wear in total hip arthroplasty: a systematic review. *Journal of Digital Imaging*, 36(1), 123-135.
- Romero-Jover, E., Blanco-Kelly, F., & García-Sandoval, B. (2024). Artificial Intelligence in Medical Imaging: From Theory to Clinical Practice. *Radiología (English Edition)*, 66(1), 12-24.

- Roldan, M., Garcia-Zapirain, B., & Mendez-Zorrilla, A. (2023). Convolutional Neural Networks for Medical Image Segmentation: A Review. *Applied Sciences*, 13(4), 250-267.
- Rouzrokh, P., Wyles, C. C., & Taunton, M. J. (2022). Evaluating the Performance of Deep Learning Models for Automated Radiographic Measurement in Hip Preservation Surgery. *Journal of Hip Preservation Surgery*, 9(1), 45-53.
- Saccomanno, S., Milano, G., & Grasso, A. (2025). The role of loss functions in training deep learning models for orthopedic image segmentation. *Computer Methods and Programs in Biomedicine*, 226, 107-118.
- Saito, T., & Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLOS ONE*, 10(3), e0118432. <https://doi.org/10.1371/journal.pone.0118432>
- Schewelov, T., Onsten, I., & Carlsson, A. (2004). Accuracy of radiographic wear measurement of the acetabular component in total hip arthroplasty. *Acta Radiologica*, 45(6), 628-634.
- Søballe, K., Jensen, T. B., & Mechlenburg, I. (2022). The increasing burden of revision total hip arthroplasty: a population-based study from Denmark. *Acta Orthopaedica*, 93(1), 95-101.
- Stilling, M., Søballe, K., & Larsen, K. (2010). Accuracy of a new computer-assisted method for measuring polyethylene wear in total hip arthroplasty. *The Journal of Arthroplasty*, 25(2), 303-309.
- Ultralytics. (2024). YOLOv5 Documentation. <https://docs.ultralytics.com/yolov5/> adresinden 10 Mart 2025 tarihinde alınmıştır.
- Ultralytics (2024b) YOLOv5 Training Tips https://docs.ultralytics.com/yolov5/tutorials/training_tips/ adresinden 10 Mart 2025 tarihinde alınmıştır.
- Vandenbussche, E., Saffarini, M., & Taillieu, F. (2010). The Devane method for measuring wear in total hip arthroplasty: a reliability study. *The Journal of Arthroplasty*, 25(7), 1134-1139.
- Vanrusselt, J., Vansevenant, M., & Vanderschueren, G. (2015). Postoperative radiograph of the hip arthroplasty: what the radiologist should know. *Insights into Imaging*, 6(6), 591-600.
- Varas-Montero, F., Pardo-González, E., & Duarte-Sanz, L. (2023). Global Trends in Total Hip Arthroplasty: A Bibliometric Analysis of the Last Decade. *Journal of Clinical Medicine*, 12(5), 189-201.

- Vasan, V., McMahon, S., & O'Byrne, J. M. (2021). Highly cross-linked polyethylene in total hip arthroplasty: a systematic review and meta-analysis. *Archives of Orthopaedic and Trauma Surgery*, 141(10), 1801-1813.
- Wasim A. S., Khan, M. A., & Siddiqui, A. A. (2023). Magnification Errors in Radiographic Measurement of Acetabular Component Wear: A Critical Analysis. *Journal of Orthopaedic Research and Therapy*, 2023, 1-7.
- Williamsima, J. D. (2024). *Biomaterials for Orthopedic Implants: Properties and Clinical Applications*. Springer International Publishing.
- Wu, J. S., Smith, P. A., & Johnson, A. J. (2021). Advanced Imaging Techniques for the Assessment of Polyethylene Wear in Total Hip Arthroplasty. *Seminars in Musculoskeletal Radiology*, 25(2), 284-293.
- Zogg, C. K., Pareek, A., & Carey, J. L. (2022). Recall and Precision are Critical for Evaluating Automated Landmark Detection in Hip Preservation Surgery. *Journal of Hip Preservation Surgery*, 9(2), 112-120.

ÖZGEÇMİŞ

Yahya Adwan, ilköğrenimini Beyt Hanun İlkokulu'nda tamamladıktan sonra, 2017 yılında Beyt Hanun Lisesi'nden mezun oldu. 2018-2019 eğitim-öğretim yılında Atatürk Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde lisans eğitimine başladı ve 2022 yılında mezun oldu. Aynı yıl Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda tezli yüksek lisans programına başladı. İyi derecede İngilizce bilmektedir.