



T.C.
VAN YÜZÜNCÜ YIL
ÜNİVERSİTESİ TIP FAKÜLTESİ

**DERİN ÖĞRENME MODELLERİNİN DESTEĞİ İLE DİSTAL
RADIUS KIRIKLARININ TANIMLANMASI VE KONSERVATİF
TEDAVİ KRİTERLERİNİN DEĞERLENDİRİLMESİ**

Dr. Mehmet SARACALIOĞLU
ORTOPEDİ VE TRAVMATOLOJİ ANABİLİM DALI
UZMANLIK TEZİ

TEZ DANIŞMANI
Dr. Öğr. Üyesi Şehmuz KAYA

VAN – 2025

ÖN SÖZ

Tez çalışmam süresince sağladığı sürekli destek, rehberlik ve katkılarından dolayı danışman hocam Dr. Öğr. Üyesi Şehmuz KAYA'ya en derin teşekkürlerimi sunarım. Kendisinin yönlendirmeleri, sabrı ve bilgi birikimi, tezimin başarılı bir şekilde tamamlanmasında büyük bir rol oynamıştır.

Ayrıca, Anabilim Dalı Başkanımız Prof. Dr. Mehmet Ata GÖKALP'e ve değerli hocalarım Doç. Dr. Cihan ADANAŞ, Doç. Dr. Sezai ÖZKAN, Doç. Dr. Tülin TÜRKÖZÜ ve Doç. Dr. Necip GÜVEN'e şükranlarımı sunarım. Sizlerin bilgi birikimleri ve deneyimleri eğitim sürecimde önemli bir rehber olmuştur. Asistanlarınıza gösterdiğiniz ilgi ve özverili çalışmalarınız, bana ilham kaynağı olmuş ve kendimi geliştirmem için gerekli ortamı sağlamıştır. Sizlerle çalışma fırsatı bulmuş olmaktan dolayı kendimi son derece şanslı hissediyorum. Asistanlık sürecim boyunca verdiğiniz destek ve öğrettikleriniz, mesleki ve kişisel gelişimimde temel olmuştur. Sizlerle çalışmak benim için büyük bir onur ve ayrıcalık olmuştur. Tüm katkılarınız için bir kez daha teşekkür ederim.

Asistanlık sürecinde her zaman bana yol gösteren, çalışmalarını örnek aldığım kıymetli büyüğüm, şefim Dr. Yunus Can ÜNAL'a desteklerinden dolayı içtenlikle teşekkürlerimi sunarım.

Bunun yanı sıra, birlikte çalışmaktan büyük mutluluk duyduğum ve çalışma sürecimiz boyunca birçok zorlu ve keyifli anı paylaştığım değerli asistan doktor arkadaşlarıma, görev yaptığım kliniklerin, polikliniklerin ve ameliyathanelerin kıymetli hemşirelerine ve personeline teşekkürlerimi sunarım.

Son olarak, her zaman yanımda olan, zor zamanlarımda desteğini esirgemeyen ve bu süreçte bana güç veren sevgili kız arkadaşım Ecz. Buse KARADAYI' ya en içten teşekkürlerimi iletmek isterim.

Dr. Mehmet SARACALIOĞLU
Van – 2025

ÖZET

SARACALIOGLU, M. (2025). Derin Öğrenme Modellerinin Desteği ile Distal Radius Kırıklarının Tanımlanması ve Konservatif Tedavi Kriterlerinin Değerlendirilmesi Van Yüzüncü Yıl Üniversitesi Tıp Fakültesi Ortopedi ve Travmatoloji Anabilim Dalı. Uzmanlık Tezi. Van.

Giriş ve Amaç: Günümüzde yapay zekâ (YZ) ve derin öğrenme teknolojilerinin sağlık alanındaki etkileri giderek artmaktadır. Özellikle ortopedi ve travmatoloji gibi klinik branşlarda, bu teknolojilerin tanı ve tedavi süreçlerini kolaylaştırma potansiyeli dikkat çekmektedir. Distal radius kırıkları, el bileği bölgesinde sık karşılaşılan travmatik yaralanmalar arasında yer almakta olup, doğru tanı ve uygun tedavi yöntemlerinin belirlenmesi büyük önem taşımaktadır. Bu çalışmada, distal radius kırıklarının Frykman sınıflamasına göre gruplandırılması ve kapalı redüksiyon ile açılama yapılan hastaların radyolojik görüntülerinin konservatif tedavi kriterlerine uygunluğunun derin öğrenme modelleri ile değerlendirilmesi amaçlanmıştır. Yapay zekâ ve derin öğrenme modellerinin, kırık tanısı ve tedavi takibinde klinisyenlere yardımcı olabileceği düşünülmektedir. Çalışma, distal radius kırıklarının tanı ve tedavi süreçlerinde yapay zekâ destekli modellerin potansiyelini ortaya koymayı hedeflemiştir.

Materyal ve Metod: Çalışma ortopedi ve travmatoloji polikliniğine başvuran, primer tanısı distal radius kırığı olan ve konservatif tedavi ile takip edilen 328 hastanın 1354 radyolojik görüntüsü üzerinde gerçekleştirilmiştir. Görüntüler Frykman sınıflamasına göre gruplandırılmış ve kırık tipleri ekstra-artiküler (EA), radiokarpal (RC), radio-ulnar (RU) ve her iki eklem uzanan kırıklar (BJ) olarak sınıflandırılmıştır. Ayrıca, radial inklinasyon, volar eğim, eklem basamaklanması ve dorsal korteks parçalanması gibi konservatif tedavi kriterleri değerlendirilmiştir. Elde ettiğimiz radyografilerin sınıflandırılması ve ölçüm gerektiren parametrelerin değerlendirilmesi 3 ortopedi uzmanı tarafından yapılmıştır. Görüntüler, Roboflow platformu kullanılarak işaretlenmiş ve derin öğrenme modelleri ile analiz edilmiştir. Model performansını değerlendirmek amacıyla doğruluk, duyarlılık ve ortalama doğruluk değeri (mAP50) gibi istatistiksel ölçütler kullanılmıştır.

Bulgular: Çalışmada, derin öğrenme modellerinin kırık sınıflandırma ve konservatif tedavi kriterlerini değerlendirme performansı incelenmiştir. Frykman sınıflamasına göre yapılan gruplandırmada, ekstra-artiküler kırıklar %70 oranında doğru tespit edilmiştir. Ancak, radiokarpal ve radio-ulnar kırıklar gibi daha az örneklem içeren gruplarda başarı oranı %30 seviyesinde kalmıştır. Eklem basamaklanmasının değerlendirilmesinde model %75 doğruluk oranı ile başarılı sonuçlar vermiştir. Radial inklinasyon ve volar eğim ölçümlerinde ise modelin doğruluk oranı sırasıyla %92 ve %72 olarak bulunmuştur.

Sonuç: Derin öğrenme modelleri, distal radius kırıklarının tanı ve tedavi süreçlerinde klinisyenlere yardımcı olabilecek potansiyele sahiptir. Özellikle kırık sınıflandırması ve konservatif tedavi kriterlerinin değerlendirilmesinde umut verici sonuçlar elde edilmiştir. Ancak, daha büyük veri setleri ve farklı modellemelerle yapılacak çalışmalar, bu teknolojinin klinik kullanıma entegrasyonunu daha da geliştirebilir. Çalışma, yapay zekâ destekli modellerin ortopedi ve travmatoloji alanında kullanımına yönelik literatüre katkı sağlamaktadır.

Anahtar Kelimeler: Distal radius kırıkları, Yapay zekâ, Derin öğrenme, Frykman sınıflaması,

ABSTRACT

SARACALIOGLU, M. (2025). Identification of Distal Radius Fractures and Evaluation of Conservative Treatment Criteria with the Support of Deep Learning Models. Van Yüzüncü Yıl University, Faculty of Medicine, Department of Orthopedics and Traumatology. Master thesis. Van.

Introduction and Objective: The impact of artificial intelligence (AI) and deep learning technologies in healthcare is increasing. These technologies have significant potential to facilitate diagnostic and therapeutic processes, particularly in clinical fields such as orthopedics and traumatology. Distal radius fractures are among the most common traumatic injuries in the wrist area, and determining an accurate diagnosis and appropriate treatment methods is crucial. This study aims to evaluate the radiological images of patients who underwent closed reduction and casting for distal radius fractures, according to the Frykman classification, using deep learning models, to assess their compliance with conservative treatment criteria. It is thought that AI and deep learning models can assist clinicians in diagnosing fractures and monitoring treatment. The study aims to reveal the potential of AI-assisted models in the diagnostic and therapeutic processes of distal radius fractures.

Materials and Methods: The study was conducted on 328 patients with a primary diagnosis of distal radius fracture, who were followed up with conservative treatment in the orthopedics and traumatology clinic. A total of 1354 radiological images were analyzed. The images were categorized according to the Frykman classification, and the fracture types were classified as extra-articular (EA), radiocarpal (RC), radio-ulnar (RU), and fractures involving both joints (BJ). Furthermore, conservative treatment criteria such as radial inclination, volar tilt, joint step-off, and dorsal cortex fragmentation were evaluated. The classification of the radiographs and the assessment of the parameters requiring measurement were performed by three orthopedic specialists. The images were labeled using the Roboflow platform and analyzed with deep learning models. Statistical measures such as accuracy, sensitivity, and mean average precision (mAP50) were used to assess model performance.

Results: The performance of the deep learning models in classifying fractures and evaluating conservative treatment criteria was investigated. In the classification based on the Frykman system, extra-articular fractures were correctly identified with an accuracy of 70%. However, in groups with fewer samples, such as radiocarpal and radio-ulnar fractures, the accuracy rate remained at around 30%. In evaluating joint step-off, the model achieved a success rate of 75%. The accuracy rates for measuring radial inclination and volar tilt were found to be 92% and 72%, respectively.

Conclusion: Deep learning models have the potential to assist clinicians in the diagnosis and treatment processes of distal radius fractures. Promising results were obtained, particularly in fracture classification and the evaluation of conservative treatment criteria. However, further studies with larger datasets and different modeling approaches could enhance the clinical integration of this technology. This study contributes to the literature on the use of AI-assisted models in the field of orthopedics and traumatology.

Keywords: Distal radius fractures, artificial intelligence, deep learning, Frykman

İÇİNDEKİLER

ÖN SÖZ.....	1
ÖZET	2
ABSTRACT	3
İÇİNDEKİLER.....	4
KISALTMALAR.....	5
ŞEKİLLER DİZİNİ.....	6
TABLolar DİZİNİ.....	7
1. GİRİŞ VE AMAÇ	8
2. GENEL BİLGİLER.....	11
2.1. Distal Radius Kırıklarına Klinik Bakış.....	11
2.1.1. Distal Radius Kırıkları Tanım ve Epidemiyolojisi.....	11
2.1.2. Distal Radius Anatomisi.....	13
2.1.3. Distal Radius Kırıklarının Klinik ve Tanısı.....	17
2.1.4. Distal Radius Kırıklarının sınıflandırılması.....	21
2.1.5. Distal Radius kırıklarının konservatif tedavisi.....	25
2.2. Derin Öğrenme Modelleri ve Yapay Zekâ	29
2.2.1. Yapay Zekâ ve Derin Öğrenme Modelleri.....	29
2.2.2. Yapay Zekânın Tıp Alanındaki Uygulamaları.....	33
3. GEREÇ VE YÖNTEM	35
3.1. Çalışmada Kullanılan Kriterler ve Çalışma Planı.....	35
3.2. Çalışmada Kullanılan Değerlendirme Parametreler	37
3.3. İstatistiksel Yöntem	38
4. BULGULAR	40
5. TARTIŞMA	48
6. SONUÇLAR	53
KAYNAKLAR.....	54

KISALTMALAR

- YZ:** Yapay zekâ
PACS: Picture Archiving and Communication Systems
EA: Extra-artiküler
RC: Radiokarpal
RU: Radioulnar
BJ: Both-joint
DRK: Distal Radius Kırıkları
CNN: Convolutional Neural Networks
PKT: Primer kemik tümörü
MRG: Manyetik Rezonans Görüntüleme
BT: Bilgisayarlı Tomografi
TFKK: Triangüler Fibrokartilaj Kompleksi
DRUE: Distal Radioulnar Eklem
EPL: Ekstensör Pollicis Longus
P: Doğruluk
R: Duyarlılık
mAP50: Ortalama Doğruluk Değeri
PA: Posterior-anterior
ABD: Amerika Birleşik Devletleri
FDA: Food and Drug Administration

ŞEKİLLER DİZİNİ

Şekil 2.1 : Distal Radiusun Anatomisi

Şekil 2.2 : Distal Radioulnar eklem anatomisi

Şekil 2.3 : Karpal Kemiklerin Anatomisi

Şekil 2.4 : El Bileği Kemikleri Radyolojik Görünümü

Şekil 2.5 : El bileği ekleminin fleksiyon ve ekstansiyonu

Şekil 2.6 : El bileği ekleminin radial ve ulnar deviasyonu

Şekil 2.7 : PA grafi çekimi

Şekil 2.8 : Lateral grafi çekimi

Şekil 2.9 : Radyolojik parametrelerin şematik gösterimi

Şekil 2.10 : Radyal kayma

Şekil 2.11 : Volar eğim ve radial inkliasyon açısının radyografik değerlendirilmesi

Şekil 2.12 : AO/OTA Sınıflandırma sistemi

Şekil 2.13 : Frykman sınıflamasının şematik görünümü

Şekil 2.14 : Redüksiyon manevrasının şematik çizimi

Şekil 2.15 : Traksiyon ve kırığın palpasyon ile kontrol edilmesi

Şekil 2.16 : Uygun sirküler alçı pozisyonu

Şekil 2.17 : Yapay sinir ağı katmanları

Şekil 2.18 : Özellik haritası

Şekil 2.19 : Evrimsel sinir ağları mimarisi

Şekil 2.20 : Roboflow internet sitesi

Şekil 3.1 : Roboflow sisteminden alınmış örnekler (eklem basamaklanması)

Şekil 3.2 : Roboflow sisteminden alınmış örnekler (radial inklinasyon)

TABLULAR DİZİNİ

- Tablo 2.1 :** DRK'nın cinsiyete göre dağılımı
- Tablo 2.2 :** Yaş gruplarına ve cinsiyete göre DRK
- Tablo 2.3 :** Kırık tiplerinin dağılımı
- Tablo 2.4 :** El Bileği Hareket Açıklıkları
- Tablo 2.5 :** Frykman sınıflamasının tablo olarak görünümü
- Tablo 4.1 :** Ulna styloid kırıklarında modelin performansının değerlendirilmesi
- Tablo 4.2 :** Ulna sthyloid fraktürlerinin değerlendirilmesi
- Tablo 4.3 :** Kırık sınıflandırılmasında modelin performansı
- Tablo 4.4 :** Kırık sınıflandırılmasının değerlendirilmesi
- Tablo 4.5 :** Eklem basamaklanmasında modelin performansı
- Tablo 4.6 :** Eklem basamaklanmasının değerlendirilmesi
- Tablo 4.7 :** Dorsal kortekste parçalanmanın değerlendirilmesinde modelin performansı
- Tablo 4.8 :** Dorsal kortekste parçalanmanın değerlendirilmesi
- Tablo 4.9 :** Radial inklinasyonun değerlendirilmesinde modelin performansı
- Tablo 4.10 :** Radyal inkliasyonun değerlendirilmesi
- Tablo 4.11 :** Volar eğimin değerlendirilmesinde modelin performansı
- Tablo 4.12:** Volar eğimin değerlendirilmesi

1. GİRİŞ VE AMAÇ

Günümüzde her alanda YZ (yapay zekâ) kullanımının etkilerini görüyoruz. Gelişen YZ teknolojilerinin modern tıbbi ne ölçüde etkileyeceği öngörülememektedir. YZ teknolojilerinin ortopedik hastalıkların tanı ve tedavilerini kolaylaştırması amaçlanmaktadır. Henüz ne kadar güvenilir olduğu konusunda literatürde net veriler olmamakla beraber bunun araştırmaya açık bir konu olduğu düşünülmektedir. Ayrıca bu konu tıp dünyası için yeni bir araştırma konusu olduğu gibi mühendislikler için de aynı şekilde yeni bir alandır.

Özellikle yapay zekâ ve derin öğrenme ile ilgili çalışmalara baktığımızda 2019 yılından sonra daha fazla çalışma olduğu görülmektedir. İlaç endüstrileri, sağlık yönetimleri ve klinik branşların çoğunda bu konuya olan artmış ilgi dikkat çekmektedir. Her alanda olduğu gibi tıp dünyası için de devrim niteliğinde gelişmeler olacağı düşünülmektedir.

Lea strom ve arkadaşları tarafından yapılan bir çalışmada klinik radyolojide yapay zekâ kullanımını incelenmiştir. Farklı hastanelerde çalışan ve farklı rollere sahip 24 kişi ile yapılan çalışmada yapay zekâ kullanımının kolaylıkları ve kullanımındaki engeller araştırılmıştır. Araştırmada yapay zekâ uygulamalarının maliyet üzerine olumlu faydaları olabileceği, iş yükünü azaltabileceği ve uygulamaların PACS (Picture Archiving and Communication Systems) sistemine entegre edilebilirliği açısından iyi sonuçlar vermiştir. Fakat güven eksikliği, yapay zekâ uygulamalarının tutarsız performans sergilemesi, uygulamayı kullanan kişilerin teknik bilgi yetersizlikleri ve kanıt eksikliği gibi faktörler yapay zekâ kullanımının önündeki engeller olarak yorumlanmıştır. (1).

Yaptığımız literatür taramalarında sağlık sisteminin tanı tedavi algoritmalarında, hasta rehabilitasyonunda ve hastayı bilgilendirme amacıyla yapay zekâ ve derin öğrenme modellerinin temel alındığı uygulamalar araştırılmıştır.

Abhiyan Bhandari yaptığı derlemede yapay zekâ teknolojilerinin radyoloji alanında getireceği yeniliklerin devrim niteliğinde olabileceğini belirtmiştir. Sadece hastalık özelinde bir çalışma olmamakla beraber YZ uygulamaları ile tanısal doğruluk, iş akışı verileri ve hasta rehabilitasyonu üzerinde de etkili sonuçları olabileceğini savunmuştur. Bu çalışmanın temelinde farklı radyoloji alt branşlarında olan çalışmalarda göz önüne alınmıştır ve bu da YZ uygulamalarının geniş bir alanda uygulanabileceğini göstermiştir. Ayrıca bazı çalışmalarında

radlyologlar ile kıyaslanabilir sonuçlar alındığını ama algoritmalara bağı olarak nicel sonuçların değıştğini belirtmiştir. Bunun yanında raporlama süresinde ve radyasyon dozunda azalma gibi verilerin olduğunu belirtse de spesifik sayısal veriler vermemektedir. Tabi ki çalışmada sınırlılıklara da yer verilmiştir. Öncelikle hasta ve veri gizliliğı, etik faktörler, radyolojiye entegrasyon öne çıkan eksiklikler olarak gösterilmiştir (2).

YZ uygulamaları ile ilgili ortopedi ve travmatoloji alanına baktığımızda kemik ve yumuşak doku tümörleri sınıflaması, kırık tanınması, hasta rehabilitasyonu ve bilgilendirilmesi gibi konularda çalışmalar yapılmıştır (3).

Qiang Ye ve arkadaşlarının yaptığı çok merkezli bir retrospektif çalışmada 749 hastanın manyetik rezonans görüntüleme (MRG) ile primer kemik tümörü (PKT) ve kemik enfeksiyonu tanısı ve sınıflandırılması amaçlanmıştır. MRG kesitleri alınarak oluşturulan derin öğrenme modelleri ile radyologların raporları karşılaştırılmıştır. Özellikle PKT sınıflandırmasında klinik tecrübesi düşük üç radyoloğun raporundan daha iyi sonuç vermiş ve kıdemli radyologların raporları ile karşılaştırılabilir sonuçlar elde edilmiştir. Fakat iyi huylu PKT tanısında özellikle yetersiz kaldıklarını vurgulamışlardır. Çalışmalar umut verici olsa da yeni çalışmalar yapılması gerektiğini belirtmişlerdir (3).

Jie Li ve arkadaşlarının yaptığı retrospektif çalışmada YOLO modeli 1085 kemik tümörü radyografisi ve 345 patolojik olmayan radyografi ile eğitilmiştir. Radyografiler iki radyolog tarafından işaretlenmiştir. Klinik sonuçlar ise cerrahi materyal histopatolojik incelemesi ile standartize edilmiştir. YOLO modelinde kitle tespiti ve iyi huylu veya kötü huylu olarak sınıflandırılması amaçlanmıştır. Lezyonun lokalizasyonunun tanı için önemli bir kriter olması ve bunu saptamada olan yetersizlik önemli sorunlardan biri olmuştur. Buna rağmen klinik kullanımda yardımcı olabileceğı düşünülmüştür. Özellikle küçük boyutta olan lezyonların tanısında dikkat çeken sonuçlar vadedmiştir (4).

Rachel YL Kuo ve arkadaşları ise kırık tespitinde YZ uygulamalarından faydalanan çalışmalar ile bir meta-analiz yapmıştır. Klinik uzmanlarının performansları ile YZ uygulamalarının kırık tespiti performansları karşılaştırmışlardır. Bu meta-analizde 42 çalışma verisi analiz edilmiştir. Bu çalışmalardan 37 tanesi direkt radyografileri 5 tanesi bilgisayarlı tomografi (BT) görüntülerini kullanmıştır. Çalışma sonucunda klinik uzmanları ve YZ uygulamalarının benzer duyarlılık ve özgüllük değerleri elde edilmiştir. Bunun ileride klinik

uygulamada tanı aşamasında yardımcı olabileceğini göstermiştir. YZ uygulamalarının entegrasyonu açısından daha fazla çalışma gerektiği belirtilmiştir (5). Bunların yanında ortopedi ve travmatolojide vertebra kırıklarının tanısı (6), kalça kırıklarının tanınması (7), BT kullanarak osteoporoz sınıflaması (8), skafoid kırıklarının tanınması (9) gibi tanı odaklı çalışmalar vardır. Elbette YZ uygulamaları sadece tanı odaklı çalışmalarda kullanılmamıştır. Yisak Kim ve arkadaşları derin öğrenme modellerini elde ettikleri BT görüntüleri ile eğiterek 5 yıllık kırık insidanslarını araştıran bir çalışma yapmışlardır (10). Bu konuda yapılan çalışmalar arttıkça YZ uygulamalarının tanıdan başlayarak koruyucu sağlık hizmetlerine kadar birçok farklı alanda katkı sağlayacağını düşünmekteyiz.

Bu çalışmada distal radius kırığı (DRK) olan hastaların tanısı ve konservatif tedavi kriterlerinde hekimlere yardımcı olabilecek bir derin öğrenme modeli geliştirmeyi amaçladık. Özellikle DRK'nı ele almak istememizin nedeni artan yaşam beklentisi nedeniyle insidansının giderek artmasıdır. Bunun yanında DRK'ları en sık görülen üst ekstremitte ortopedik yaralanmalarındandır ve acil servis başvurularında görülen tüm kırıkların 1/6'sından fazlasını oluşturur (11).

Hasta seçimlerimizde taraflı olmamak için 2014-2019 yılları arasında ortopedi ve travmatoloji polikliniğine başvuran primer tanısı DRK olan ve konservatif tedavi ile takip edilen hastaları belirledik. 328 hastanın dosya kayıtları tarandı. Primer tanı alan ve konservatif takip edilen hastaların 2551 adet grafisi ile çalıştık. Çalışmaya uygun olan 1354 radyografi derin öğrenme modellerine gösterildi. Bu çalışmada hasta grafileri en az 5 yıllık deneyimi olan 3 ortopedi doktoru tarafından değerlendirildi. Ölçüm gerektiren parametreler ve kırık sınıflandırılmaları da yine en az 5 yıllık deneyimi olan 3 ortopedi doktoru tarafından yapıldı. Derin öğrenme modelleri ile kırık tespiti, kırığın sınıflandırılması ve konservatif tedavi kriterlerini değerlendirildi.

2. GENEL BİLGİLER

2.1. Distal Radius Kırıklarına Klinik Bakış


2.1.1. Distal Radius Kırıkları Tanım ve Epidemiyolojisi

DRK genellikle el bileği ve dirsek eklemi ekstansiyonda iken düşme sonucu oluşan kırıklardır. El bileği ekleminin aldığı enerjiye göre farklı morfolojik paternlerde olabilirler. Bu farklı morfolojik paternler distal radiusun metafiz bölümünden izole oluşan kırıklardan eklemi ilgilendiren karmaşık kırıklara kadar uzanabilir. Ayrıca bu kırıklarla beraber inter-karpal bağ, triangüler fibrokartilaj kompleksi (TFKK) yırtıkları veya ulnanın styloid çıkıntısının ve karpal kemiklerin kırıkları görülebilir (12).


DRK'ları için doğru epidemiyolojik rakamlar vermek zordur. Günümüzde hala epidemiyolojisi popüler konular arasındadır. Güncel literatür tarandığında tüm kırıkların yaklaşık olarak yüzde 16'sını oluşturmaktadır. Yetişkin yaş grubunda en sık karşılaşılan kırıklardan biridir. Özellikle osteoporozun yaygın olduğu toplumlarda sıklığı daha fazladır (13).

Yaş dağılımı incelendiğinde bi-modal dağılım paterni görülmektedir. Genel olarak genç erkeklerde yüksek enerjili travma öyküsü (spor yaralanması, trafik kazası) görülmekteyken yaşlı kadınlarda düşük enerjili travma (basit düşme) öyküsü sıktır. Özellikle yaşlı kadınlarda osteoporoz ile ilişkisi anlamlıdır. Literatürde 64-94 yaş arası kadınlarda DRK insidansı altı kata kadar daha fazladır (13). Bunun haricinde mevsimlere göre dağılımları ve bölgelere göre dağılımları arasında anlamlı fark yoktur.

Tablo 2.1 : Distal radius kırıklarının cinsiyete göre dağılımı

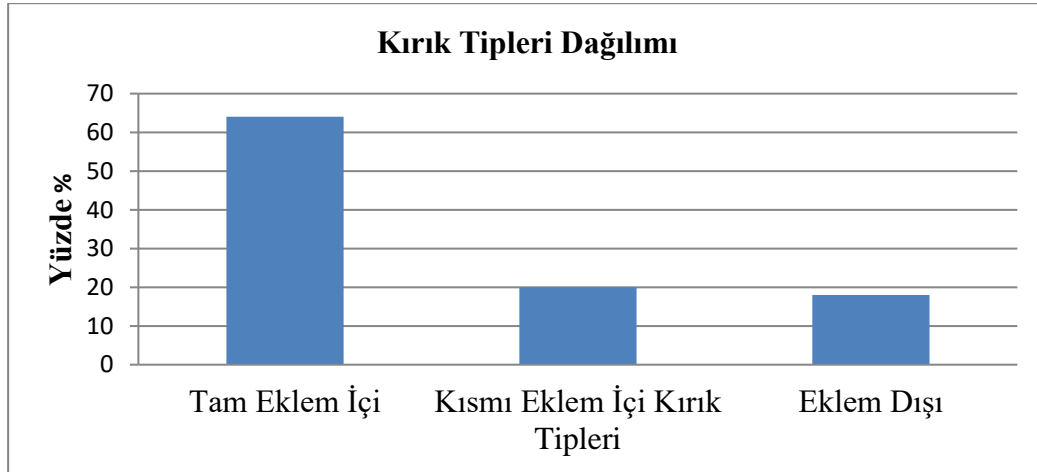


Tablo 2.2 : Distal radius kırıklarının yaş gruplarına ve cinsiyete göre dağılımı



Ayrıca kırık tipi cinsiyete göre farklı dağılım göstermektedir. DRK sınıflaması ile ilgili detaylı bilgi ilerleyen bölümde verilecektir. DRK'da kırık paterni genellikle yaralanma mekanizmasıyla ilişkilidir. Genç erkeklerde eklem ile ilişkili kompleks yaralanmalar daha sıktır. Bunun sebebi daha çok yüksek enerjili yaralanmalar ile oluşmasıdır.

Tablo 2.3 : Kırık tiplerinin dağılımı



Ortalama yaşam beklentisinin arttığı düşünülürse distal radius kırıklarının görülme sıklığı giderek artacaktır. Hem acil servislere hem de ortopedi ve travmatoloji polikliniklerine sık başvuru nedenleri olarak kalmaya devam edecektir. Bu durum sınıflandırılması, tedavi yöntemleri ve rehabilitasyon programları için her zaman geniş bir araştırma alanı sunmaktadır.

2.1.2. Distal Radius Anatomisi

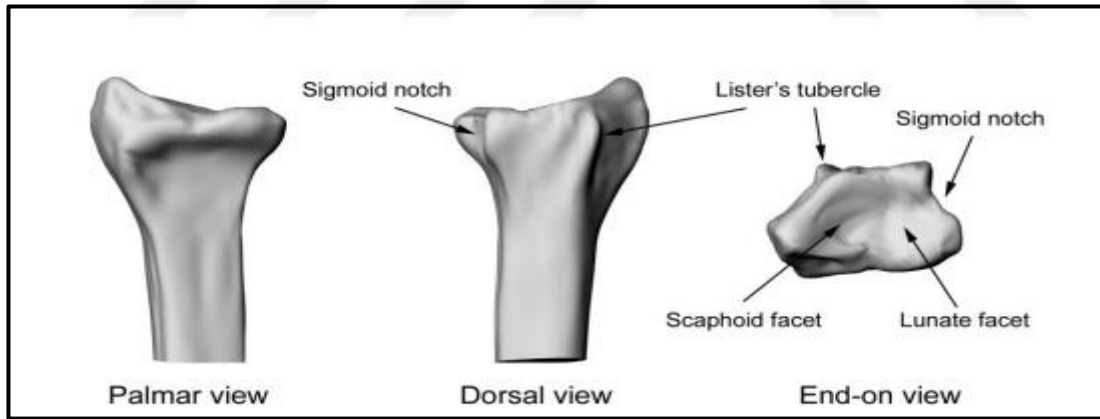
El bileği, proksimalde pronotor kuadratus kasından başlayıp karpometakarpal eklemlere kadar uzanan anatomik bölgedir. Vücudun mekanik açıdan en kompleks eklemine oluşturan pek çok kemikle birlikte birçok damar sinir yapısı ve tendon bu bölgede yer almaktadır (15).

El Bileği Anatomisi

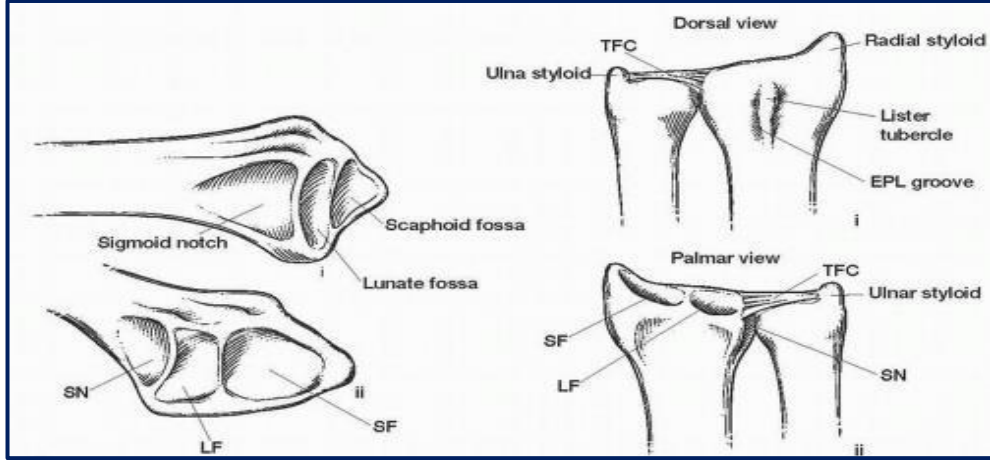
Radius ve Ulna

Radius ön kol lateralinde yer alır. Humerus ve karpal kemiklerden skafoideum ve lunatum arasında bulunur. El bileğini oluşturan distal radius dış tarafta skafoid fossa (çukur), iç tarafta lunat fossa (çukur) ve medialde ulna başı ile eklemlenen sigmoid çentik olmak üzere hyalin kıkırdak ile örtülü üç konkav eklem yüzeyinden oluşmuştur (16,17). (Şekil 2.1)

Ulna ön kol medialinde yer alır. Humerus ile karpal kemiklerden lunatum ve trikuetrum arasında bulunur. El bileğini oluşturan distal ulna, ulna başı (kaput ulna) olarak adlandırılır. İç-arka tarafında distale doğru ulna styloid çıkıntı uzanır. Karpal kemiklerden triangular fibrokartilaj kompleksi diye adlandırılan ve el bileğinden kola geçen doğrudan kuvvetlere karşı darbe emici olarak görev yapıp ulna ve dirsek eklemine koruyan bir eklem diski ile ayrılmıştır (16,17). (Şekil 2.2)




Şekil 2.1: Distal Radiusun Anatomisi (14)




Şekil 2.2: Distal Radioulnar Eklem Anatomisi (50)

Karpal Kemikler

İki sıra halinde gördüğümüz karpal kemiklerin proksimalinde skafoid, lunatum, trikuetrum ve pisiforme; distalinde trapezium, trapezoideum, kapitatum ve hamatum bulunur (18). (Şekil 2.3) (Şekil 2.4)



Şekil 2.3: Karpal Kemiklerin Anatomisi (51)



Şekil 2.4: El Bileği Kemikleri Radyolojik Görünümü (52)

El bileği, radius ve ulna kemiklerinin distalde oluşturdukları radioulnar eklem, radius kemiğinin karpal kemiklerle oluşturduğu radyokarpal eklem, midkarpal eklem ve ulnokarpal eklem olmak üzere dört eklemden oluşmaktadır. Bu el bileği eklemine mekanik olarak da çok kompleks bir eklem haline getirir (19).

El bileğininin dorsal ve volar yüzünde önemli kas yapıları, tendon yapıları, el bileği inervasyonunda görevli damar ve sinir yapıları bulunmaktadır. El bileği biyomekaniğinde kemik anatomi kadar bu yapılarda önemlidir.

El Bileği Biyomekaniği

El bileğinin karmaşık yapısını anlamak için biyomekanik olarak değerlendirilmelidir. El bileğinin farklı eksenlerde ve geniş bir hareket alanı vardır. Hareket eksenleri, ekstansiyon, fleksiyon, pronasyon, supinasyon, radial deviasyon ve ulnar deviasyon olmak üzere çok planlıdır. Bu hareketlerin toplamı olarak adlandırılan sirkümdiksiyon hareketine de sahiptir (20).


Normal bir el bileğinin hareketleri, nötral sıfır metodu kullanılarak Tablo (2.4)'de tanımlanmıştır (21).

Tablo 2.4 : El Bileği hareket açıklıkları

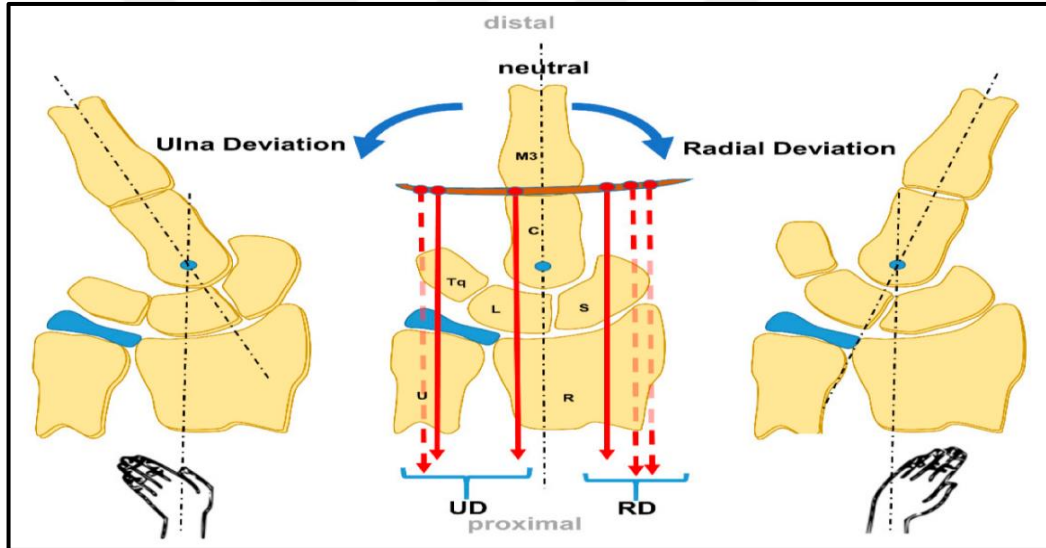
Hareket Türü	Hareket Açıklığı (Derece)
Dorsal Fleksiyon (Ekstansiyon)	50° - 80°
Palmar Fleksiyon (Fleksiyon)	60° - 85°
Ulnar Deviasyon (Adduksiyon)	30° - 45°
Radial Deviasyon (Abduksiyon)	15° - 30°
İç Rotasyon (Pronasyon)	80° - 90°
Dış Rotasyon (Supinasyon)	80° - 90°

Bu hareketlerin sınırları, el bileğinin anatomik yapısı ve biyomekanik özellikleri ile ilişkilidir. Örneğin, radial styloid çıkıntı, ulnar styloid çıkıntıya göre daha distalde yer alır. Bu durum, abduksiyon sırasında skafoid kemiğin radyal styloide dayanmasına neden olur ve bu nedenle abduksiyon (radial deviasyon), adduksiyona (ulnar deviasyon) göre daha kısıtlıdır (22). (Şekil 2.6)

Ayrıca, radyokarpal eklemin ön kenarının arka kenarı kadar distale uzanmaması nedeniyle, fleksiyon hareketi, ekstansiyon hareketine göre daha fazla gerçekleşir. Bu durum, el bileği ekleminin anatomik yapısının hareket açıklığı üzerindeki etkisini açıkça göstermektedir (23). (Şekil 2.5)



Şekil 2.5: El Bileği Eklemine Flexiyon ve Ekstansiyonu (52)



Şekil 2.6: El Bileği Eklemine Radial ve Ulnar Deviasyonu (52)

2.1.3. Distal Radius Kırıklarının Klinik ve Tanısı

Klinik ve Tanı

Distal radius kırığı olan hastaların kliniğinde travma öyküsü genellikle vardır. Travma mekanizmasına bağlı olarak plastik deformiteler görülebilir. El bileği bölgesinde şişlik, ekimoz, hassasiyet ve hareket ile olan ağrı görülür. Nörolojik ve vasküler muayeneler yapılmalıdır. Sekonder yaralanmaları gözden kaçırmamak için proksimalinde ve distalinde bulunan eklem muayeneleri mutlaka yapılmalıdır.

Radyolojik değerlendirme:

Radyografi

Klinik ön tanı olarak distal radius fraktürü düşündüğümüz hastalarda yapılması gereken ilk tetkik ön-arka ve yan planda çekilen direk radyografidir. Ucuz ve pratik olması büyük avantaj sağlamaktadır (24). Radyografiler tanı koymanın yanında sınıflandırma, tedavi planı ve tedavi takibi içinde oldukça önemlidir. Radyografi çekiminin ideal olması çok önemlidir. Uygun şartlarda ve uygun dozajda çekilmelidir. İdeal radyografi için posterior-anterior (PA) grafilerde omuz eklemi 90° abdüksiyonda, dirsek eklemi omuz eklemi ile aynı seviyede ve 90° fleksiyonda, ön kol ise pronasyona getirilip avuç içi röntgen kasetine bakacak şekilde görüntü alınmalıdır. Yan grafilerde ise yine dirsek eklemi omuz eklemi ile aynı seviyeye getirilmeli ve başparmak yukarıya doğru bakacak şekilde iken görüntü alınmalıdır. İdeal şartlarda alınmış radyografilerle kırık hastalarının yaklaşık olarak %95'inin tanısı konulabilir (25). (Şekil 2.7) (Şekil 2.8)



Şekil 2.7: PA Grafi Çekimi



Şekil 2.8: Lateral Grafi Çekimi

Çekilen ön-arka grafilerle radial uzunluk, ulnar varyans, ulna styloid fraktürünün yeri ve metafizyel ezilmenin miktarı değerlendirilebilir. Ekleme uzanan parçalı kırıklar için lunat fasette çökme, skafoid ve lunat faset arasındaki uzaklık ve proksimal karpal kemiklerin sırası değerlendirilebilir (24).

Lateral grafiler ile dorsal eğim, karpal kemiklerin dizilimi, volar ve dorsal korteksin deplasman miktarı ve distal radioulnar eklem (DRUE) eklemin pozisyonu değerlendirilebilir. Ekleme uzanan kırıklar için ön arka grafilerde olduğu gibi eklem yüzeyleri değerlendirilebilir.

Lateral grafilerde ideal çekim dorsal ve volar eğim değerlendirmesi için özellikle önem arz eder. Çekim yapılan el bileğinin supinasyonda olması palmar eğimin artmasına pronasyonda olması ise palmar eğimin azalmasına yol açar (24).

Bunların yanında hastalarda oblik grafiler ve eğim verilmiş yan grafiler de çekilebilir. Oblik grafiler ile radius styloidi ve lunat fasetin depresyonu değerlendirilirken eğim verilmiş yan grafiler ile özellikle cerrahi sırasında eklem içi değerlendirme yapılabilir (24). Eğim verilmiş yan grafi çekimi için el bileği altına yükselti konularak ve el bileği eklemine ışına doğru 20° eğim verilmesiyle çekilmesi önerilir (26).

Radial Açılanma (radial inklinasyon)

Ön-arka radyografide, radial styloidin uç kısmıyla distal radioulnar eklem radial kısmını birleştiren çizgiyle, radiusun uzun eksenine çizilen dik çizgi arasındaki açıdır. Normali 13°-30° (ortalama 22°-23°) arasındadır (27). (Şekil 2.9)

Radial Yükseklik (radial uzunluk)

Ön arka radyografide radial styloid uç kısmından ve distal ulnar başın eklem yüzünden geçen birbirine paralel iki çizgi arası mesafedir. Normalde 8-18 mm (ortalama 11-12 mm) arasındadır (27). (Şekil 2.9) (Şekil 2.11)

Palmar Eğim (volar eğim, dorsal açılanma)

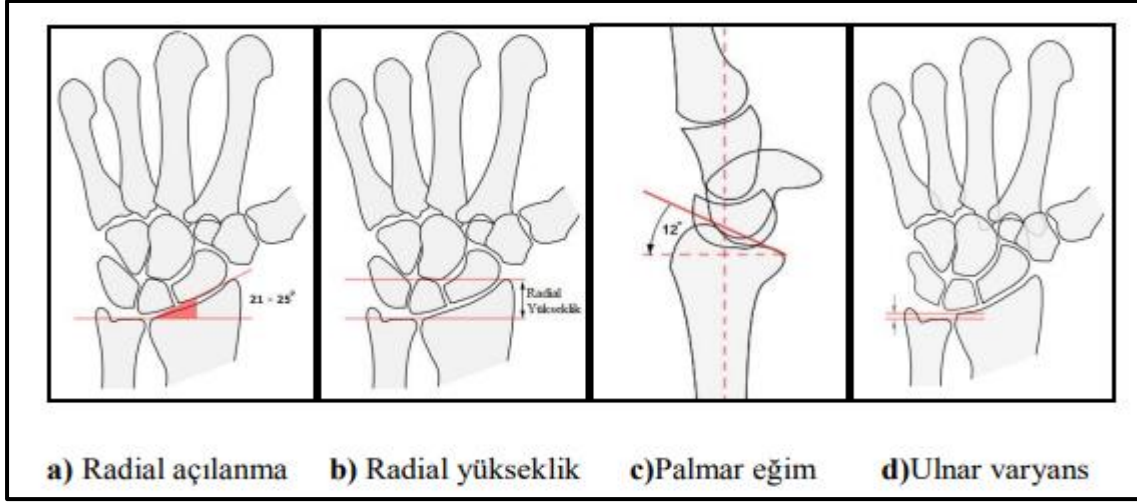
Yan grafide radiusun volar ve dorsal uçlarını birleştiren doğru ile radiusun uzun eksenine çizilen dik çizgi arasındaki açıdır. Normalde 0°-22° (ortalama 11°-12°) arasında ve volar yüze dönüktür (28). (Şekil 2.9) (Şekil 2.11)

Ulnar Varyans


Ulna başının eklem yüzeyi ile distal radiusun lunat faseti arasındaki vertikal mesafedir. Normalde sık olarak bu iki yapı aynı seviyede olup mesafe sıfırdır ve bu durum "nötral anatomik varyans" olarak bilinir. Normal bileklerin %10'unda ise ulna daha ileride olup "pozitif varyans" söz konusudur. Normal değeri 0±2 mm' dir (29). (Şekil 2.9)

Radial Kayma (radial şift)


Radius uzun ekseni ile radius styloidi arasındaki uzaklıktır. Sağlam tarafla fark 1 mm'den fazla olmamalıdır (27). (Şekil 2.10)



Şekil 2.9: Radyolojik Parametrelerin Şematik Gösterimi (53)



Şekil 2.10: Radyal Kayma (53)



Şekil 2.11: Volar Eğim ve Radial İnkliasyon Açısının Radyografik Değerlendirilmesi (54)

Bilgisayarlı Tomografi

Genellikle radyograflerin yetersiz olduđu durumlarda çekilir. BT üç boyutlu görüntü desteđi vermesi nedeniyle eklem uzanan kırıkların değerlendirilmesi, DRUE değerlendirilmesi ve karpal kemiklerin değerlendirilmesi amacıyla kullanılır. Özellikle eklem basamaklanmasının değerlendirilmesinde direk grafiye göre üstünlüğü vardır.

Manyetik Rezonans

DRK için rutin kullanımı yoktur. Daha çok DRK sonrası eşlik eden ek yaralanmaları (yumuşak doku yaralanması, tendon rüptürü, median sinir kompresyonu) değerlendirmek için kullanılır.

Sintigrafi

Rutin kullanımı yoktur. Daha çok radyografi ve BT'de saptanamayan kırıkların saptanması için kullanımının tariflendiđi çalışmalar vardır. Özellikle kırık sonrası oluşan kompleks bölgesel ağrı sendromu tanısında önemini belirten çalışmalar mevcuttur (30).

2.1.4. Distal Radius Kırıklarının Sınıflandırılması

DRK için birçok sınıflandırma yöntemi tarif edilmiştir. Günümüzde gelişen görüntüleme teknikleri ile sınıflandırma hala popüler konular arasındadır. Gelişen görüntüleme teknikleri kırığın morfolojisi ile ilgili olarak bize daha fazla bilgi vermesi nedeniyle tarif edilen farklı sınıflandırma yöntemleri oluşturulmuştur. Geliştirilen sınıflandırma yöntemlerinin hem güvenilir olması hem tedaviyi belirleyici olması hem kullanışlı olması amaçlanmaktadır. Fakat günümüzde kullanılan hiçbir sınıflama yöntemi bu şartların tamamını karşılamamaktadır (31).

Sınıflandırmanın tarihçesine bakılınca ilk sınıflandırmalar 1814 yıllarında Colles tarafından yapılmış günümüze kadar birçok sınıflandırma tanımlanmış ve en son 2013 yılında Joao Carlos Belloti ve arkadaşları tarafından IDEAL sınıflaması tanımlanmıştır. Sınıflandırmaların hepsinden çalışmamızda bahsetmek mümkün değildir. Sınıflandırmaların haricinde günlük pratiğimizde kullandığımız birçok tanımlanmış kırık da mevcuttur. Hiçbir sınıflandırma günümüzde ideal sınıflandırma olarak kabul edilmemektedir.

DRK insanlık tarihinde her zaman sık görülen kırıklar olmuştur ve haliyle her zaman tanısı ve tedavisi güncel konular olarak kalmıştır. Bu sayede birçok sınıflandırma yöntemi tarif edilmiştir. Kronolojik sırayla sınıflandırmalara bakacak olursak;

- 1814 yılında Colles sınıflandırması tanımlanmıştır ve bu distal radius kırıklarının ilk sınıflandırılmasıdır. Dorsale açılanmış metafizer kırıklar olarak tanımlanmışlardır. Bu sınıflandırma tedavi ve prognoz hakkında bilgi vermemektedir (32).

- 1838 yılında Barton sınıflandırılması tanımlanmış. İntraartiküler kırıkları tanımlamıştır. Bu kırıkların dorsal veya volar yüze yer değiştirmelerine odaklanılmış bir tanımlamadır (33).

- 1847 yılında Smith volar yer değiştirmeli kırıkları tanımlamıştır (34).

- 1967 yılında Frykman sınıflaması tanımlanmıştır. Aynı zamanda çalışmamızda kullandığımız sınıflandırmadır. İleride detaylı olarak anlatılacaktır.

- 1984 yılında Melone Sınıflandırması tanımlanmıştır. İntraartiküler kırıkları sınıflamıştır. kırıkları diafiz, styloid, palmar medial faset, dorsal medial faset olmak üzere 4 kısma ayırmıştır. Bu sınıflandırmada, distal radiusun medial(lunat) fasetini ayrı olarak değerlendirir (35).

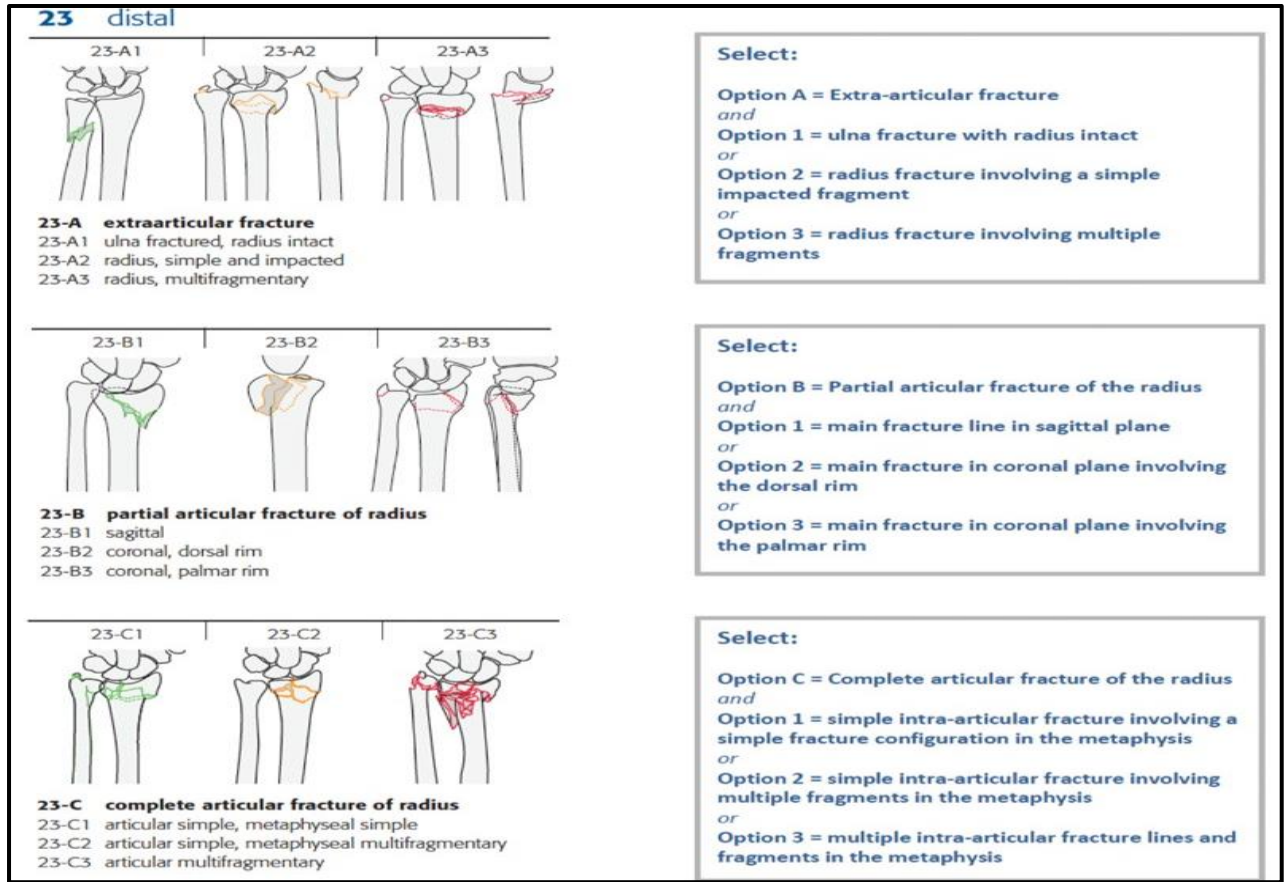
- 1986 yılında AO/ASIF sınıflama sistemi tanımlanmıştır. Sonrasında bu sistem ilk olarak 1990 yılında olmak üzere 2018 yılına kadar birkaç kez güncel ihtiyaçlar göz önüne alınarak revize edilmiştir. Tüm uzun kemiklere numaralar verilir. Her kemik 3 gruba ayrılır. Radius 2 rakamı ile temsil edilir. Proksimali 1, diafizi 2, distali için 3 rakamı kullanılır. Radius distal uç kırığı 2,3 ile isimlendirilir.

3 büyük gruba ayrılır:

Grup A: Ekleme uzanımı olmayan kırık

Grup B: Basit ekleme uzanan kırık

Grup C: Metafizer uzanımı olan kompleks eklem içi kırık. Üç grup da kendi içinde, kırığın dengesine, çökmesine, parçalı olup olmamasına, redükte edilebilirliğine ve anatomik yerine göre 27 farklı alt gruba ayrılır (36). (Şekil 2.12)



Şekil 2.12: AO/OTA Sınıflandırma Sistemi (55)

- 1991 yılında Fernandez Sınıflandırması tanımlanmıştır. Bu sınıflandırma kırıkları daha çok travma mekanizmasına göre ayırt etmiştir (37).
- 1993 yılında Cooney WP tarafından Universal Sınıflandırma geliştirilmiştir. Bu sınıflandırma, kırıkları basit bir şekilde tanımlamak ve tedavi planlamasına rehberlik etmek amacıyla oluşturulmuştur. Universal sınıflandırması, kırıkları ekstraartiküler ve intraartiküler olarak ayırır ve yer değiştirme durumuna göre alt gruplara böler (38).
- 2013 yılında IDEAL Sınıflandırmasını tanımlanmıştır. Modern bir sınıflandırma yöntemidir. Sınıflandırma sisteminin içinde bireysel faktörler, kırık parçalarının deplasmanı, travmanın enerji miktarının, eklemin durumunun ve kırık lokasyonunu içeren güncel sınıflama yöntemidir. Klinik pratik kullanımı yaygın değildir. Her sınıflama sistemi gibi sınırlılıkları vardır (39).

DRK için kullanılan sınıflandırma sistemlerini genel olarak deplasman miktarına göre, deplasman derecesi ve radyolojik kriterlere göre, kırık hattının eklem ilişkisine göre ve kırığın oluşma mekanizmalarına göre ayırmakta mümkündür. Bunların yanında özel isimlerle anılan distal radius kırıkları tanımlanmıştır. Biz çalışmamızda Frykman sınıflandırmasını kullandık.

Frykman sınıflaması

Frykman, radius alt uç kırıklarını, 1967 yılında kırığın intraartiküler ya da ekstraartiküler oluşuna, ulna styloidinin sağlam kalışı ve kırık oluşu ile distal radioulnar ve radyokarpal eklem tutulumuna göre 8 gruba ayırmıştır (40). (Şekil 2.13)

Tip I: Ekleme uzanım göstermeyen radius alt uç kırığı

Tip II: Ekleme uzanım göstermeyen radius alt uç kırığı ve ulna styloid kırığı

Tip III: Radyokarpal eklemi içeren radius alt uç kırığı

Tip IV: Radyokarpal eklemi içeren radius alt uç kırığı ve ulna styloid kırığı

Tip V: Radioulnar eklemi içeren radius alt uç kırığı

Tip VI: Radioulnar eklemi içeren radius alt uç kırığı ve ulna styloid kırığı

Tip VII: Radyokarpal ve radioulnar eklemi içeren radius alt uç kırığı


Tip VIII: Radyokarpal ve radioulnar eklemi içeren radius alt uç kırığı ve ulna styloid kırığı

Sınıflamada gruplandırmanın temsil ettiği rakam arttıkça kırıkların iyileşmesinde komplikasyon görülme oranının yüksek olduğu ve prognozunun daha kötü olduğu düşünülür. Sınıflandırmanın sınırlamaları; kırık fragmanlarının deplasman yönü, parçalanma derecesi ile ilgili fikir vermemesidir. Ayrıca prognoz hakkında da yönlendirme yapmamasıdır.

Tablo 2.5: Frykman sınıflamasının tablo olarak görünümü

Radius Kırık Şekli		Ulnar Stiloid Kırığı	
		Hayır	Evet
Ekstra-artiküler		I	II
İntra-artiküler	DRKE	III	IV
	DRUE	V	VI
	DRKE + DRUE	VII	VIII

(DRKE:Distal radio-carpal eklem, DRUE:Distal radio-ulnar eklem)



Şekil 2.13: Frykman Sınıflamasının Şematik Görünümü (56)

2.1.5. Distal Radius Kırıklarının Konservatif Tedavisi

DRK'nın tedavisi günümüzde halen tartışmaya açık konular arasında yer almaktadır. Bizim çalışmamızda konservatif tedavi üzerinde durulacaktır. Bunların yanında kapalı redüksiyon ve perkütan pinleme, eksternal fiksasyon, açık redüksiyon ve internal fiksasyon ve artroskopik tedavi yöntemleri mevcuttur. Tedavi yöntemini belirlemede hasta yaşı, ek yaralanma ve kırığa bağlı oluşan komplikasyonlarda önemlidir.

DRK'larının %80'i stabil olan eklem uzanımı göstermeyen kırıklardır ve bu kırıklarda konservatif tedavi yöntemleri sık tercih edilmektedir. Stabil olmayan kırıkların ise kapalı redüksiyon sonrası anatomik bütünlüğünün sağlanması zordur. Stabil olmayan kırıklarda daha çok cerrahi yöntemler tercih edilmektedir (45).

Literatüre baktığımızda;

- Tanı anında dorsal açılanmanın 20°'den fazla olması, dorsal kortikal parçalanma ya da defekt varlığı
- Tanı anında radial kısalığın 10 mm'den fazla olması
- Radyokarpal veya radioulnar ekleme uzanım gösteren kırık varlığı
- Kemikğin metafizer bölgesinde defekt olması

- Kapalı redüksiyon ve alçılama sonrası dorsal açılanmanın 5°'ten fazla olması
- Kapalı redüksiyon ve alçılama sonrası radial kısalığın 5 mm'den fazla olması

kırığın instabil olduğunu gösterir (42).

Konservatif Tedavi

Tedavi hedefi bütün yaş gruplarında meslek ve aktivitelere izin veren ağrısız, yeterli hareket ve stabilite sağlayabilecek bir el bileğidir. Özellikle genç hastalarda ilerleyen yaşlarda dejeneratif değişikliklerin olmaması amaçlanır. Tedavi planlanırken sadece kırığın görüntülenmesi ve klinik bulgular değil aynı zamanda hasta yaşı, mental durumu, fiziki yapısı, kemik kalitesi, kronik hastalıklarının olması, kırık bölgesindeki yumuşak dokuların durumu, travmanın oluş mekanizması ve şiddeti gözlenerek en uygun tedavi tercihi yapılmalıdır (41).


Son yıllarda gelişen cerrahi tedavi yöntemleri ve artan implant teknolojisine rağmen bazı kırık tipleri için kapalı redüksiyon ve alçılama iyi bir yöntemdir. Konservatif tedavi, kendine göre zorlukları olan zahmetli bir yöntemdir. Sık radyolojik ve klinik takip gerektirir.

Hangi hastalara konservatif tedavinin uygulanacağı kararını vermede göz önünde bulundurulması gereken esas ölçüt, kapalı redüksiyon sonrası kırığın redükte olabilmesi ve stabil kalabilmesidir. Bu tedavinin amacı, kırığın anatomik diziliminin sağlanması ve kemik iyileşmesinin olgunlaşacağı 4–6. hafta sonuna kadar bu dizilimin alçı içinde korunmasıdır.


Alçı içinde kırığın redüksiyonunu korunması ancak alçının temas etkisi, yumuşak dokuların gerginliği ve yumuşak doku kılıfının hidrolik basıncı sayesinde olabilir. Stabil kırıklar denildiğinde, kaymamış veya kaymış ama redüksiyon manevraları ile düzeltilip pozisyonu alçı içinde korunabilen kırıklar ile, 5°'den az dorsal açılanma ve 2 mm'den az kısalma gösteren eklem dışı kırıklar anlaşılır. Başlangıç grafisinde parçalanma ve aşırı açılanma gösteren veya eklem içine uzanan kırıklar, ulnada eşlik eden kırıklar veya ileri derece osteoporozu olan hastaların kırıkları, stabil olmayan kırıklardır ve bu, alçı içinde redüksiyon kaybı ihtimali yüksek kırıklar anlamına gelir (12).

Kapalı redüksiyon ile amaç anatomik dizilim sağlamak olsa da her hastada bunu sağlamak mümkün olmayabilir. Fakat anatomik olarak redükte olmayan kırıklarında hastalarda fonksiyonel olarak kısıtlılık yapmadığı ve ağrısız bir şekilde el bileklerini kullanabildiklerini gösteren çalışmalarda vardır. Bu yüzden kabul edilebilir radyolojik kriterlerde kalmak önemlidir.

DRK’da kapalı redüksiyon sırasında ağrı kontrolü sağlanması gerekir. Ağrıyı kontrolü ile hem hastanın stres seviyesini azaltılması hem de kasların gevşemesi ile redüksiyon manevrasının kolaylaştırılması amaçlanır. Redüksiyon yapılırken cerraha yardımcı olacak biri dirsekten tutarken cerrah ön kol distalinden tutarak radiusun ekseninde traksiyon yapar ve öncelikle deformite yönünde sonrasında asıl manevra olan kırık hattında açılanmanın tersi yönünde kırık parçası redükte edilir. Radial inklinasyonun sağlanması için yeterli ulnar deviasyon ile ön kol pronasyon pozisyonu verilebilir (41). Redüksiyon sonrası palpasyon ile kontrol sağlanır. Mümkünse bu aşamada radyografi alınabilir. Sonrasında ise alçılmaya geçilir. (Şekil 2.14) (Şekil 2.15)



Şekil 2.14: Redüksiyon Manevrasının Şematik Çizimi (57)



Şekil 2.15: Traksiyon ve Kırığın Palpasyonla Kontrol Edilmesi (57)

Alçı sonrası önerilen el bileği pozisyonu 15° palmar fleksiyon ve $10-15^{\circ}$ ulnar deviasyondur (42). Gereğinden fazla fleksiyon ve gereğinden fazla ulnar deviasyondan kaçınılmalıdır. Bu pozisyonun kompleks bölgesel ağrı sendromu riskini arttırdığı gösterilmiştir (43). Açık yaralanmalar el bileğinde aşırı şişlik olması ve dolaşım bozukluğu durumunda sirküler alçı uygulaması tavsiye edilmemektedir. (Şekil 2.16)



Şekil 2.16: Uygun Sirküler Alçı Pozisyonu

Alçı içerisindeki redüksiyon kayıpları genellikle ilk iki hafta içerisinde meydana geldiğinden sirküler alçının ilk haftalarında hasta sık takip edilmelidir. Özellikle yaşlı hasta popülasyonlarında daha geç dönemde redüksiyon kaybı görülebilmektedir. Redüksiyon kaybı yaşanan hastalarda tekrarlanan redüksiyon manevraları sonrasında da redüksiyon kaybı yaşanma ihtimali yüksek olduğundan bu durumlarda yeniden açılama ile tedavi yerine ek tespit yöntemlerine yönelmek önerilir (43).

Redüksiyon sonrası dördüncü haftada yeterli klinik iyileşme olur, fakat kallus dokusunun radyografilerde görülmesi altıncı haftayı bulacaktır. Bu nedenle minimal ayrışmış ve stabilitesi iyi olan kırıklarda immobilizasyon için 3-4 hafta yeterli iken instabil, parçalı kırıklarda ve yaşlı hastalarda tespit süresi 6 haftaya kadar uzatılmalıdır (42).

Tespit sonlandırıldıktan sonra koruma amaçlı 3-4 hafta daha statik el bilekliği kullanılabilir. Alçı çıkarıldıktan sonra el bilek hareketlerini geri kazanamayan hastalara mümkün olduğunca erken dönemde fizik tedavi uygulamaları başlanmalıdır (42).

Konservatif tedavi sonrasında yaşanan komplikasyon oranları çeşitli kaynaklarda farklılık göstermektedir (44). Konservatif tedavi sonrası görülebilecek komplikasyonların başlıcaları yanlış kaynama (malunion), karpal tünel sendromu, EPL (ekstensör pollicis longus) tendon yaralanması ve kompleks bölgesel ağrı sendromudur.

Yanlış kaynama ile ilgili fonksiyonel kayıplar özellikle radial uzunluğun geri kazanılamamasına bağlı görülür. Yanlış kaynama sonrasında DRUE'de ağrı, el bileğinde deviasyon ve dorsal açılma, ulna styloid çıkıntının belirginleşmesi, sinir sıkışmaları, osteoartrit ve kavrama gücünde azalma gibi kötü sonuçlarla ilişkili bulgularla karşılaşılabilir (43). Kırığın 10° den az radial inklinasyon, 20° den fazla dorsal ve volar eğim, 10 mm'den az radial yükseklik ve eklemde 2 mm'den fazla basamaklanma ile kaynaması malunion olarak tanımlanır.

2.2. Derin Öğrenme Modelleri ve Yapay Zekâ

2.2.1. Yapay Zekâ ve Derin Öğrenme Modelleri

Günümüzde gelişen teknoloji kendine yeni alanlar açmaktadır. Yapay zekâ insan zekâsını taklit ederek problem çözme ve karar vermek amacıyla geliştirilmiş bir teknoloji alanıdır. Finans, eğitim, ulaşım ve sağlık gibi birçok alanda yararlanılmaya başlanmıştır. Özellikle büyük verileri analiz edebilme yeteneği kullanıldığı her alan için avantaj sağlamaktadır.

Yapay zekâ, genel olarak iki ana kategoriye ayrılır:

Dar Yapay Zekâ (Narrow AI): Belirli bir görevi yerine getirmek için tasarlanmış sistemlerdir. Örnek olarak radyografilerde yapay zekâ aracılığıyla kırık tespiti yapmak, radyografik görüntülerin işlenmesiyle beyin dokusunda kitle saptamak sayılabilir.

Genel Yapay Zekâ (General AI): Birden fazla görevi yerine getirebilen karmaşık sistemlerdir. Henüz geliştirileme aşamasında olan bu kategoride insan gibi düşünme yeteneği sunabilmesi beklenmektedir.

Yapay zekâ uygulamalarının, sisteme yüklenen verilerden öğrenebilmesi ve öğrendiklerini uygulama yeteneği vardır. Bu öğrenme süreci, makine öğrenimi (Machine Learning) adı verilen bir alt alanını oluşturmuştur.

Geleneksel programlama yöntemlerinde, bir sistemin nasıl çalışacağı adım adım kodlanırken, makine öğreniminde sistem, verilerden öğrenerek kendi kurallarını oluşturur. Bu, özellikle büyük miktarda verinin olduğu durumlarda oldukça etkili bir yöntemdir (46). Bizim çalışmamızda da bu özellikten yararlanılmıştır.


Makine öğrenimine biraz daha detaylı bakacak olursak çalışmamızda kullandığımız ve makine öğrenme sistemlerinden biri olan derin öğrenme (Deep Learning), daha karmaşık ve büyük veri setleriyle çalışabilen bir yöntemdir. Derin öğrenme, insan beynindeki sinir ağlarından esinlenerek geliştirilmiş yapay sinir ağları (Artificial Neural Networks) üzerine kuruludur.

Derin Öğrenme ve Yapay Sinir Ağları

Derin öğrenme, çok katmanlı yapay sinir ağlarını kullanarak verilerden öğrenme sürecini daha güçlü hale getirir. Yapay sinir ağları, insan beynindeki nöronların çalışma prensibine benzer şekilde tasarlanmıştır. Bu ağlar, verileri katmanlar halinde işler ve her katmanda daha karmaşık özellikleri öğrenir. Derin öğrenmede bu çok katmanlı yapay sinir ağları sayesinde verilerden öğrenme sürecini daha güçlü hale getirir.


Yapay sinir ağlarının çalışma mekanizmasına temel olarak bakmak istersek 3 katman olarak özetleyebiliriz.

- Giriş katmanı: Verinin ilk değerlendirildiği katmandır. Sistem tarafından ilk alınan görüntünün bir sayısal form ile sisteme uygun şekilde işlendiği yer burasıdır.
- Gizli katmanlar: Giriş katmanında gelen farklı özelliklerin işleminden geçirildiği yerdir. Bu gizli katmanların sayısı ve yapısı modellemelerin öğrenme kapasitesini ve karmaşıklığını belirler.
- Çıkış katmanı: Gizli katmanlardan gelen verilerin son olarak karara bağlandığı yer gibi düşünülebilir. Yani sistem verilerden kendi elde ettiği öğrenimleri toplayarak bu aşamada uygulamaya koymasına gibi örnek verilebilir ya da kırık var veya yok gibi bir sonuca vardığı katmandır (47).



Şekil 2.17 : Yapay sinir ağı katmanları (58)

Bu katmanlı yapının kazandırdığı avantaj ile görüntü ve ses gibi karmaşık olabilen veriler derin öğrenme modelleri ile başarılı bir şekilde işlenebilmektedir. Tabii bu başarı buna uygun tasarlanmış özel sinir ağları sayesinde. Görüntü işleme konusunda Evrimsel Sinir Ağları (Convolutional Neural Networks-CNNs) kullanılmaktadır. CNN'ler ile görüntülerdeki önemli özellikler (mesela kenar, köşe gibi) analiz edilir. Bu özellikler görüntüleme alanında çok fayda sağlar. Bizim çalışmamızda örnek verecek olursak kırık konfigürasyonlarını bu şekilde modellendi. CNN'lerin temel farkı görüntülerdeki verileri analiz etmek için otomatik olarak tasarlanması yanında görüntülerin iki boyutlu yapısına uygun kodlama yapmasıdır (47).



Şekil 2.18 : Özellik haritası (58)

Evrimsel Sinir Ağları(CNN)

Evrimsim (Convolution) Katmanı: Doğrusal ve doğrusal olmayan işlemlerin kombinasyon yöntemini kullanarak girdi olarak verilen görüntülerden özellikler çıkarılmasını sağlar. Bu katman ile evrimsim filtreleri kullanılarak, görüntüden özelliklerin belirlendiği yeni görüntüler elde edilir.

Aktivasyon Fonksiyonları: Oluşturduğumuz modelin öğrenme kapasitesini artırır.

Havuzlama (Pooling) Katmanı : Görüntü boyutlarını azaltır ve veri maliyetini düşürür. Aynı zamanda konum değişikliklerine karşı modelin daha duyarlı olmasını sağlar.

Tam Bağlı (Fully Connected) Katman:Görüntüden çıkarılan özellikleri kullanarak sınıflandırma veya tahmin işleminin yapıldığı katmandır (47).


Litjens ve arkadaşları tarafından yapılan derlemede derin öğrenme modellerinin tıbbi görüntüleme analizini incelemişlerdir. Çalışmada derin öğrenme yöntemleri şu başlıklar halinde sınıflandırmıştır;

Görüntü Sınıflandırma (Image Classification): Görüntüde kırık olup olmadığının belirlenmesi

Segmentasyon (Segmentation): Görüntüdeki belirli bölümün otomatik olarak işaretlenmesi.

Kayıt ve Yeniden Yapılandırma (Registration and Reconstruction): Görüntülerin hizalanması ve yeniden oluşturulması (48).


Aynı çalışmada derin öğrenme modellerinin otomatik özellik çıkarımı yapabildiğini, büyük veri setleri ile çalışabilme yeteneğinden ve aynı zamanda hızlı çalışabilmesinden de bahsedilmiştir (48). Derin öğrenme modellemelerinin bu avantajları tıbbi görüntüleme ve analizi için kullanılabilir olduğunu göstermektedir. Tabi ki sınırlılıkları da mevcuttur. Bunların en önemlisi az veri ile yapılan modellemelerin düşük performans göstermesidir (48).



Şekil 2.19 : Evrimsel sinir ağları mimarisi (58)

Roboflow

2019 yılında Joseph Nelson ve Brad Dwyer tarafından kurulan bu platform, özellikle Bilgisayarla görme (computer vision) ve yapay zekâ modelleri geliştirme üzerinde çalışmaktadır. (59).



Şekil 2.20 : Roboflow internet sitesi (59)

2.2.2. Yapay Zekânın Tıp Alanındaki Uygulamaları

Geçmişte baktığımızda bilgisayar ve yapay zekâ kavramları 1950'LI yıllarda gelişmeye başlayınca tıp dünyası da kullanılabilirliğini fark etmiştir. 1959 yılında Keeve Brodman ve meslektaşları semptomları makinalar öğretmenin mümkün olabileceğini söylemişlerdir. 2000 yılında William B. Schwartz yazısında bilgisayarların doktorların işlerine yardımcı olacağını hatta bazı durumlarda yerini alabileceğini belirtmiştir (49).

Literatüre baktığımızda yapay zekâ yöntemleri tanı koyma, ayırıcı tanı, hasta takibi, tedavi planlaması gibi kliniğin birçok aşamasında denenmiş olmasına rağmen hala sınırlılıkları vardır.

Literatüre baktığımızda YZ klinik kullanımıyla ilgili;

- Meme kanseri taraması: mamografi görüntüleri üzerinden kitlenin sınıflandırılması (benign/malign ayrımı) ve hasta takibi
- Akciğer kitlelerinin tespiti: BT görüntüleri aracılığıyla sınıflandırılması (benign/malign ayrımı)
- İntrakraniyel kitle tanısı: MR görüntüleri ile yer kaplayan lezyonların anatomik lokalizasyon tespiti, Alzheimer gibi nörodejeneratif hastalıkların tanısı
- Kardiyak görüntüleme: Kardiyak BT ve MR görüntüleri ile fonksiyonel analiz
- Oftalmoloji: Retina görüntüleri ile diyabetik retinopati, glokom ve makula dejenerasyonu gibi göz hastalıklarının tanısı
- Patoloji: Mikroskop görüntüleri ile kanser tanısı ve sınıflandırılması
- Ortopedi: Kemik fraktürü ve dejeneratif eklem hastalıkları tanısı
- Dermatoloji: Cilt lezyonlarının tanısı ve ayırıcı tanısı

- Gastroenteroloji: Endoskopi ve kolonoskopi görüntüleri ile poliplerin ve diğer gastrointestinal lezyonların tespiti
- Onkoloji: Kanser tanısı ve tedavi planlaması

gibi çalışmalar vardır (48).



3. GEREÇ VE YÖNTEM

3.1. Çalışmada Kullanılan Kriterler ve Çalışma Planı

Çalışmamız T.C. Van Yüzüncü Yıl Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu'nun 20.09.2024 tarih ve 2024/10-20 karar numaralı etik kurul onayı alınarak ve Helsinki Deklarasyonu'na uygun yürütülmüştür.

Çalışmaya Dahil Edilme Kriterleri

- İzole DRK olması
- Hastanın 18-90 yaş aralığında olması
- Radyolojik görüntülemelerinin nizami çekilmiş olması
- Sirküler alçılamanın uygun şartlarda olması
- Hastanemizin radyoloji ünitesinde graflerinin çekilmiş olması

Çalışmadan Dışlanma Kriterleri

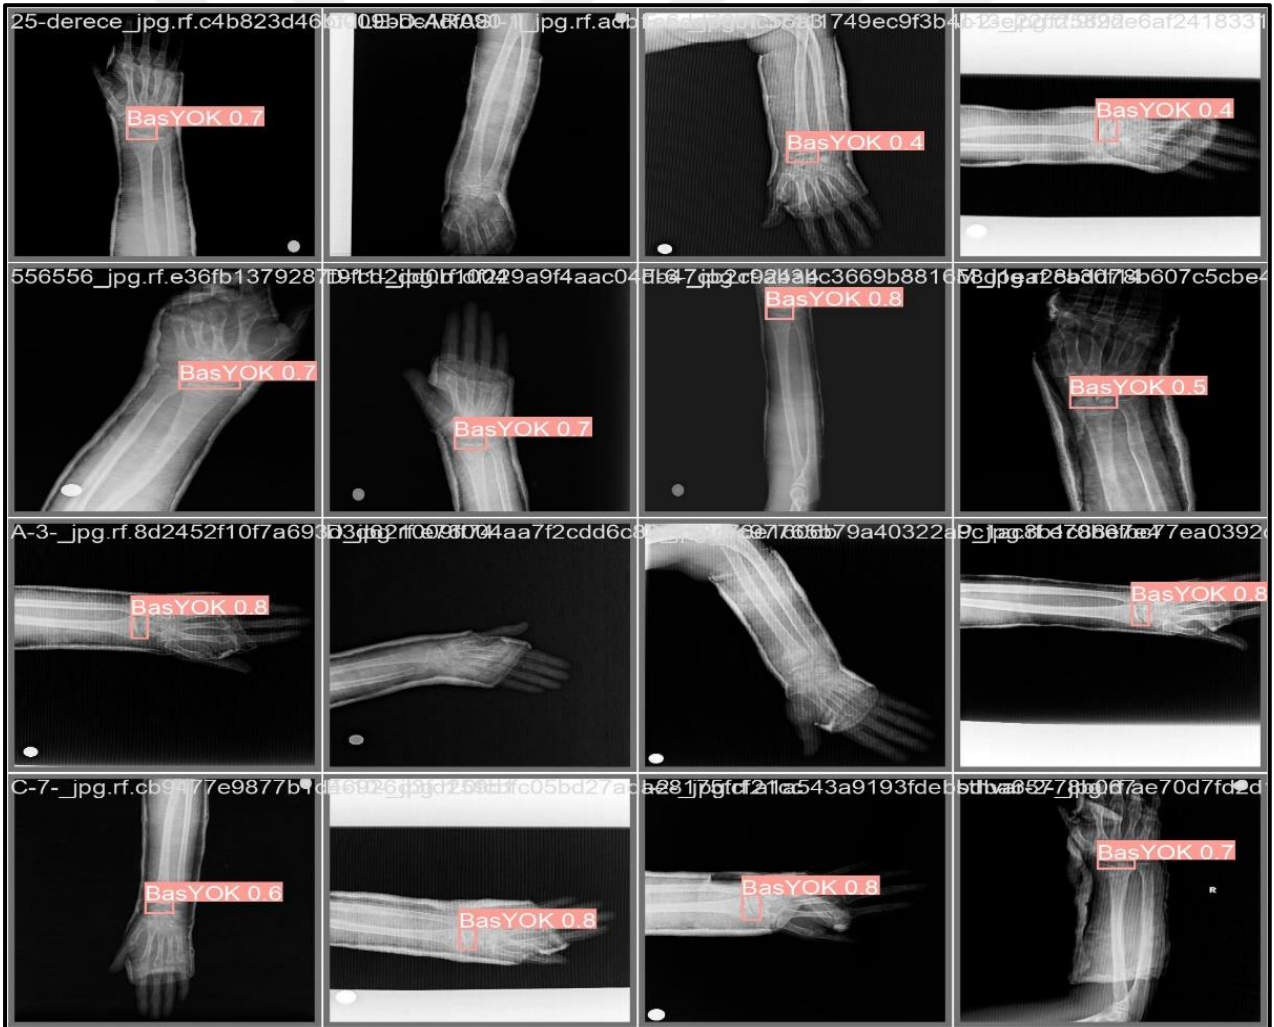
- Taşınabilir röntgen cihazları ile çekilen grafleri
- Eşlik eden karpal kemik ve metakarp fraktürleri olan hastalar
- Eşlik eden radius, ulna shaft ve radius, ulna proksimal uç kırığı olan hastalar
- Uygun olmayan dozda grafi çekimi yapılan hastalar
- Uygun olmayan açıda grafi çekimi yapılan hastalar

Çalışma Planı

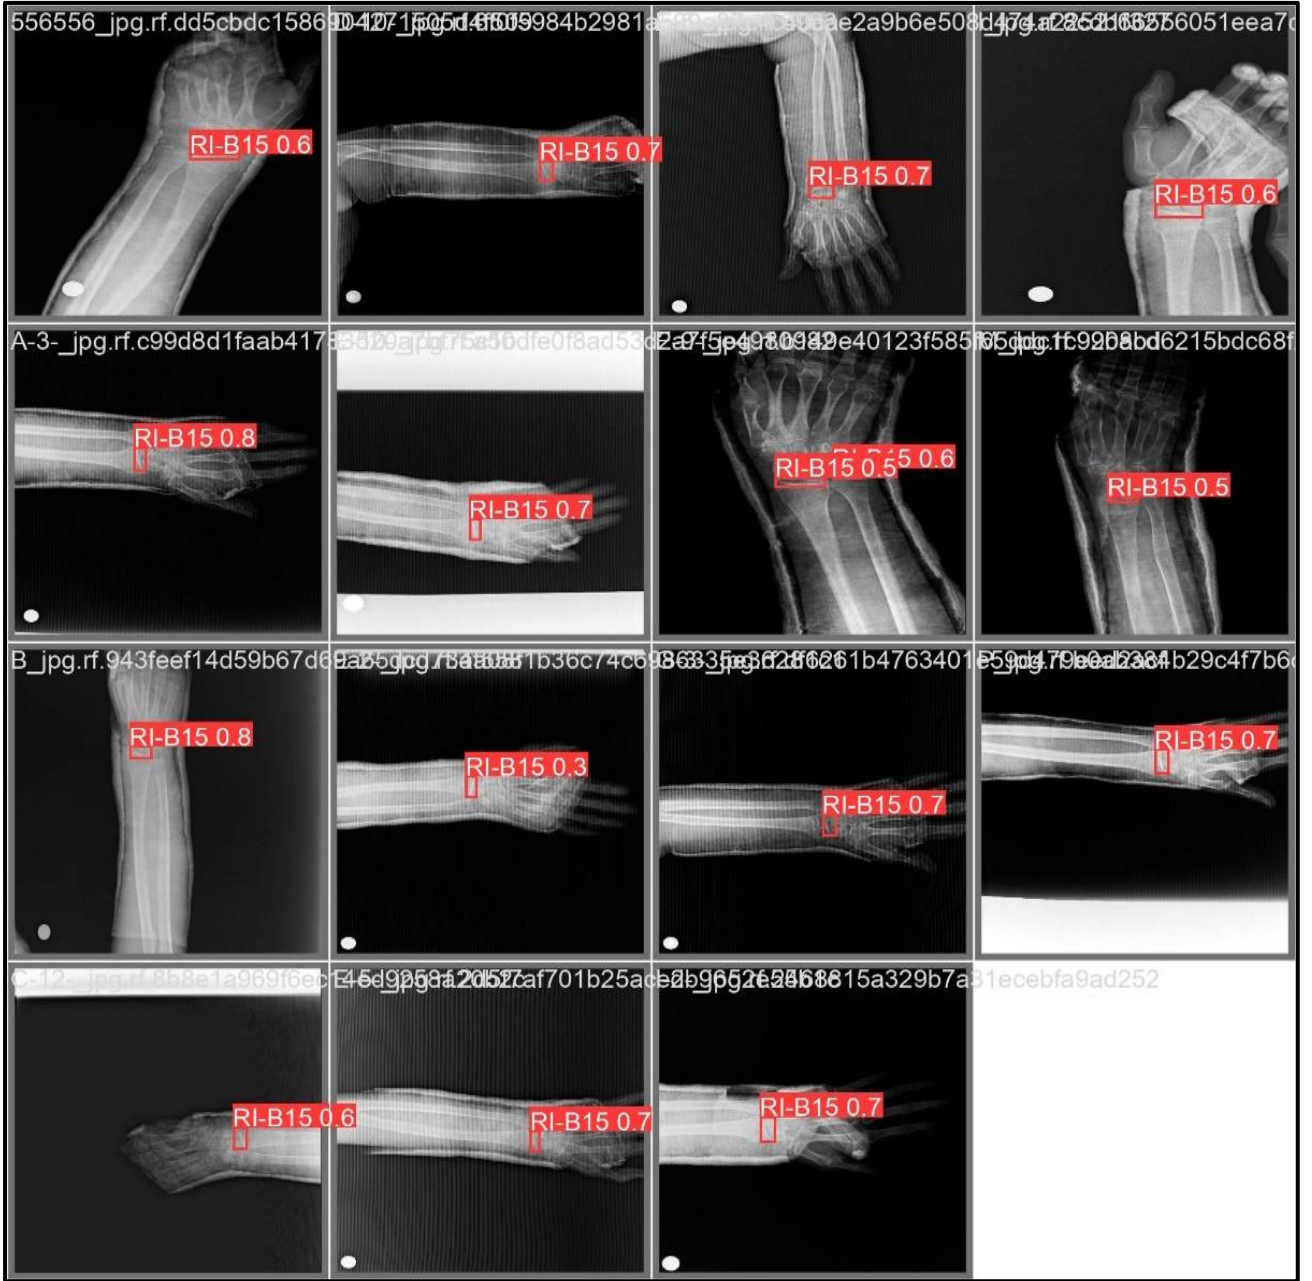
1) Çalışmamız için ortopedi ve travmatoloji polikliniğine başvuran 378 hastanın radyografleri incelendi. Bunlardan 328 hastanın grafleri çalışma için kullanıldı. Toplam 2551 grafiden 1354 tanesi çalışma için uygun olarak değerlendirildi. Çalışmadan çıkarılan grafler çekimi uygun yapılmayan graflerden oluşmaktaydı.

2) Oluşturulan grafler Frykman sınıflaması baz alınarak sınıflandırıldı. Sınıflandırılma yapılırken tip 1 kırıklar ekstra-artiküler kırıklar (EA), tip 3 kırıklar radyokarpal kırıklar (RC) tip 5 kırıklar radioulnar (RU) kırıklar, tip 7 kırıklar her iki ekleme uzanan kırıklar (BJ) olarak sınıflandırıldı. Styloid kırıklarının eşlik ettiği tip 2, tip 4 ve tip 6 kırıklar ayrı bir grup olarak sınıflandırılmadı. Burada amaç grup sayısını azaltarak daha fazla grafi ile modelleme yapabilmektir. Bu sayede sınıflamada olan 8 grubu 5 ayrı kategori olarak modellemeye tanıtıldı.

- 3) Kapalı redüksiyon sonrası çekilen grafilerde radial inklinasyon açısına, volar eğim açısına, eklem basamaklanması olup olmamasına ve dorsal kortekste parçalanma olup olmamasına göre gruplandırıldı. Burada amaç konservatif tedavi kriterlerini modellemede kullanabilmektir.
- 4) Radial inklinasyon açısı 15 dereceden büyük olanları ve volar eğimi 0-20 derece arasında olan kırıkları tek grup olarak, eklem basamaklanmasını var veya yok olarak ve en son olarak dorsal korteks parçalanmasını var veya yok olarak sınıflandırıldı..
- 5) Kullanılan grafiler 3 ortopedi uzmanı tarafından değerlendirildi.
- 6) Görüntüler üzerinde yapılan ölçümler 3 ortopedi hekimi tarafından ve tek bir program kullanılarak yapıldı. Burada amaç belirli bir standart yakalamaktır.
- 7) Sonrasında gruplar Roboflow sistemi üzerinde gruplarına uygun olarak işaretlendi.
- 8) Sonuçlar aynı sistem üzerinden alınarak değerlendirildi.



Şekil 3.1 : Roboflow sisteminden alınmış örnekler (eklem basamaklanması) (59)



Şekil 3.2 : Roboflow sisteminden alınmış örnekler (radial inklınasyon) (59)

3.2. Çalışmada Kullanılan Değerlendirme Parametreleri

Bu çalışmada, modelin performansını değerlendirmek amacıyla literatürde yaygın olarak kullanılan çeşitli metrikler tercih edilmiştir. Değerlendirme sürecinde dikkate alınan temel parametreler aşağıda açıklanmıştır:

- Hassasiyet (Precision): Modelin doğru pozitif tahminlerinin, toplam pozitif tahminlere oranını ifade eden bu metrik, modelin yanlış pozitif tahmin yapma eğilimini

değerlendirmek için kullanılmıştır. Yüksek hassasiyet, modelin tahminlerinin doğruluğunu göstermektedir.

- **Hatırlama Oranı (Recall):** Modelin doğru pozitif tahminlerinin, toplam gerçek pozitiflere oranını ifade eden bu metrik, modelin gerçek pozitifleri ne ölçüde doğru bir şekilde tespit edebildiğini değerlendirmektedir. Hatırlama oranı, modelin duyarlılığını ortaya koymaktadır.
- **Ortalama Doğruluk (Mean Average Precision-mAP):** Modelin genel doğruluk performansını ölçmek için kullanılan bu metrik, hem hassasiyet hem de hatırlama oranını dikkate alarak hesaplanmaktadır. Çalışmada özellikle mAP 0.5 (eşik değeri 0.5 olan mAP) metriği temel alınmıştır. Bu metrik, modelin farklı sınıflar üzerindeki genel başarısını değerlendirmek için kritik bir gösterge olarak kullanılmıştır.
- **Kutu Kayıpları (Box Loss):** Modelin nesne kutularını tanımlarken yaşadığı kayıpları ifade eden bu metrik, eğitim sürecindeki iyileşme durumunu değerlendirmek amacıyla kullanılmıştır. Kayıp değerlerinin azalması, modelin eğitim sürecinde daha iyi bir performans sergilediğini göstermektedir.

Bu parametreler, modelin farklı sınıflar ve gruplar üzerindeki performansını detaylı bir şekilde analiz etmek ve değerlendirmek amacıyla kullanılmıştır. Her bir sınıf için ayrı ayrı hesaplanan bu metrikler, çalışmanın bulgular kısmında tablolar ve grafikler ile sunulmuştur.

3.3. İstatistiksel Yöntem

Çalışmada elde edilen verilerin analizi ve değerlendirilmesi için çeşitli istatistiksel yöntemler uygulanmıştır. Bu yöntemler, modelin performansını kapsamlı bir şekilde değerlendirmek ve farklı gruplar arasındaki farkları ortaya koymak amacıyla kullanılmıştır. Çalışmada kullanılan istatistiksel yöntemler şu şekilde özetlenebilir:

- **Veri Gruplandırma:** Görüntüler, belirli sınıflar ve gruplar altında kategorize edilmiştir. Örneğin, ulna styloid fraktürleri, kırıkların sınıflandırılması, basamaklanma, dorsal kortekste parçalanma, radial inklinasyon ve volar eğim gibi farklı gruplar oluşturulmuş ve bu gruplar üzerinden analizler gerçekleştirilmiştir.
- **Metrik Analizi:** Her bir grup için hassasiyet (precision), hatırlama oranı (recall) ve ortalama doğruluk (mAP) gibi metrikler hesaplanmış ve bu metriklerin eğitim

sürecindeki deęişimleri grafikler ve tablolar aracılıęıyla deęerlendirilmiřtir. Bu analizler, modelin performansındaki deęişimlerin görselleřtirilmesini saęlamıřtır.

- **Karřılařtırılmalđ Analiz:** Farklı gruplar arasında modelin performansı karřılařtırılmıřtır. Örneęin, ulna styloid fraktürü olan ve olmayan gruplar arasındaki performans farkları detaylı bir řekilde incelenmiřtir.
- **Örneklem Sayısının Etkisi:** Modelin performansının örneklem sayısına baęlı olarak deęişimi analiz edilmiřtir. Özellikle düşük örneklem sayısına sahip gruplarda hassasiyet ve mAP deęerlerinin daha düşük olduęu gözlemlenmiřtir. Bu durum, örneklem büyüklüęünün model performansı üzerindeki etkisini ortaya koymaktadır.
- **Eřik Deęerleri:** Çalışmada, modelin genel doęruluk performansını deęerlendirmek için **mAP0.5** metrięi temel alınmıřtır.

Bu yöntemler, modelin genel performansını deęerlendirmek, farklı gruplar arasındaki farkları ortaya koymak ve modelin eęitim sürecindeki iyileřme durumunu analiz etmek için kullanılmıřtır. Analiz sonuçları, çalışmanın bulgular kısmında detaylı bir řekilde sunulmuř ve yorumlanmıřtır.

4. BULGULAR

Çalışmamızda sistemden aldığımız sonuçları başlıklar halinde incelenecektir.

Ulna Sthyloid Fraktürleri İçin Sonuçlar

Grafilerde kullanılan metrikler şu şekildedir.


Metrics/precision: Bu grafik, modelin hassasiyetini (precision) göstermektedir. Eğitim ilerledikçe hassasiyetin genel olarak arttığı gözlemleniyor, ancak bazı dalgalanmalar da mevcut. Hassasiyetin zamanla iyileştiğini fakat eğitim boyunca değişiklik gösterebildiğini görüyoruz.

Metrics/recall: Bu grafik, modelin hatırlama oranını (recall) göstermektedir. Eğitim ilerledikçe hatırlama oranı da artıyor, bu da modelin doğru şekilde tanımlama yapma yeteneğinin geliştiğini göstermektedir.

Metrics/mAP_0.5: Modelin 0.5 eşik değerindeki ortalama doğruluk değerini (mean Average Precision) gösterir. Bu metrik zamanla artıyor ve modelin performansının iyileştiğini göstermektedir. Bu değer aynı zamanda bizim çalışmada temel aldığımız değerdir. Bu metrik, modelin hem hassasiyetini (precision) hem de hatırlama oranını (recall) dikkate alarak, tahminlerinin doğruluğunu ölçer.

Train/box_loss: Eğitim sırasında modelin nesne kutularını tanımlarken yaşadığı kayıplar gösterilmektedir. Kaybın eğitimin başında yüksek olduğu, ancak adım adım azaldığı görülmektedir. Bu, modelin zamanla daha iyi bir şekilde kutu tanımlamayı öğrendiğini göstermektedir.

Tablo 4.1 : Ulna styloid kırıklarında modelin performansının değerlendirilmesi



Analizlerimize tablo olarak baktığımızda ulna styloid fraktürlerinden toplam 56 adet görüntü sisteme tanıtılmıştır. Tüm görüntülere baktığımızda modelin genel hassasiyeti %54.9'dur. Bu, modelin yaptığı tahminlerin yaklaşık %55'inin doğru olduğunu göstermektedir. Modelin genel hatırlama oranı %69.2'dir. Bu, modelin veri setindeki gerçek örneklerin yaklaşık %69'unu doğru bir şekilde tespit ettiğini göstermektedir. Ortalama doğruluk (mean Average Precision) metriği, 0.5 eşik değerinde %59.6'dır. Bu, modelin genel doğruluk performansının orta seviyede olduğunu göstermektedir.

Ulna sthloid fraktürü olmayan gruba baktığımızda bu sınıfta toplam 40 örnek üzerinden ilerlemiştir. Hassasiyet %71.6'dır. Bu, modelin *sthyok* sınıfı için yaptığı tahminlerin %71'inin doğru olduğunu göstermektedir. Bu oldukça iyi bir değerdir. Hatırlama oranı %80'dir. Bu, modelin *sthyok* sınıfındaki gerçek örneklerin %80'ini doğru bir şekilde tespit ettiğini göstermektedir. Bu oldukça yüksek bir performanstır. Ortalama doğruluk metriği %79.1'dir. Bu, modelin *sthyok* sınıfındaki genel doğruluk performansının oldukça iyi olduğunu göstermektedir.

Tablo(4.2)'ye bakıldığında ulna sthyloid fraktürü olan hasta grubunda verilerin az olmasına bağlı olarak değerlerin düşük olduğunu görmekteyiz. bu bize ulna styloid fraktürü olan veya olmayan grubun karşılaştırılmasının yanı sıra örnek sayısı arttıkça modellemenin daha iyi çalıştığını ispatlamaktadır.

Tablo 4.2: Ulna sthyloid fraktürlerinin değerlendirilmesi

Sınıf	Görseller	Örnekler	P	R	mAP50
Tümü	56	52	0,549	0,692	0,596
Sth var	56	12	0,381	0,583	0,402
Sth yok	56	40	0,716	0,8	0,791


(Sth var: sthyloid fraktürü var, Sth yok:sthyloid fraktürü yok, P:Doğruluk, R:Duyarlılık, mAP50: ortalama doğruluk değeri)

Kırıkların Sınıflandırılması

Çalışmamızda Radius distal uç kırıkları için Frykman sınıflamasını kullandık. Bu çerçevede ulna styloid kırıklarını ayrı sınıflama olarak yaptık. Kalan grupları EA, RC, RU ve BJ olarak gruplandıracağız.

Metriklere baktığımızda bir önceki grup ile benzer grafikler görüyoruz. Precision ve recall değerleri eğitim boyunca düzenli olarak artmıştır. mAP50 değerinin de artma eğiliminde olduğunu ve eğitimde olan kayıpların azaldığını görmekteyiz.

Tablo 4.3 : Kırık sınıflandırılmasında modelin performansı



Analizlerimize Tablo (4.3)'e baktığımızda 52 adet görüntü ile gruplandırma yapılmıştır. Bütün gruplar için baktığımızda Precision(hassasiyet): 0.455, Recall(hatırlama oranı): 0.593, mAP0.5: 0.468 olarak analiz edilmiştir. Modellemeye tüm gruplar için baktığımızda performansını orta seviyede gibi düşünebiliriz. Precision değeri düşük, yani model yanlış pozitif tahminler yapma eğiliminde; recall ise daha yüksek, model gerçek pozitiflerin yüksek oranda yakaladığını göstermektedir.

BJ grubuna baktığımızda Precision: 0.55, Recall: 0.556, mAP0.5: 0.589 olarak analiz edilmiştir. Precision (0.55) ve Recall (0.556) değerleri birbirine oldukça yakın, bu da modelin tahminlerinde dengeli bir performans sergilediğini göstermektedir. Tabi ki mAP50 değerinin yeteri kadar iyi olduğunu söyleyemeyiz. Bunun en büyük sebeplerinden birinin Instances(örneklem) sayısının düşük olmasıdır.

EA grubuna baktığımızda Precision: 0.647, Recall: 0.689, mAP0.5: 0.71 olarak analiz edilmiştir. Precision ve Recall değerleri yüksek, mAP değeri de diğer sınıflara göre çok daha

yüksek çıkmıştır. Model bu sınıfta daha başarılıdır. Bunda örneklem sayısının fazla olması etkendir.

RC ve RU gruplarına baktığımızda ise genel performansın düşük olduğunu ve özellikle Precision değerinin oldukça düşük olduğunu görüyoruz. Bu durum modelin bu sınıfta çok fazla yanlış pozitif tahmin yaptığını göstermektedir.

Tablo 4.4 : Kırık sınıflandırılmasının değerlendirilmesi

Sınıf	Görseller	Örnekler	P	R	mAP50
Tümü	52	52	0,455	0,593	0,468
BJ	52	9	0,55	0,556	0,509
EA	52	23	0,647	0,609	0,71
RC	52	12	0,297	0,583	0,356
RU	52	8	0,326	0,625	0,297

(BJ:her iki eklemi ilgilendiren kırıklar, EA: extraartiküler kırıklar, RC:radiokarpal ekleme uzanım gösteren kırıklar, RU:radioulnar ekleme uzanım gösteren kırıklar, P:Doğruluk, R:Duyarlılık mAP50: ortalama doğruluk değeri)


Basamaklanmanın Değerlendirilmesi

Hastalarımızın grafilerini basamaklanma var veya basamaklanma yok olarak gruplandırdık. Bunun sebebi ise grafiler çekilirken standart bir çekim yapılmadığı için ölçüm değerlerinin gerçeği yansıtmayacak olmasıdır.

İki gruba bakacak olursak bu grupta modellemenin daha iyi performans gösterdiği görünmektedir.

Metriklerin grafiklerine baktığımızda eğitim boyunca modelin eğitilebilirliğinin arttığını ve daha doğru tahminler yapabildiği görünmektedir.

Tablo 4.5: Eklem basamaklanmasında modelin performansı



Tablo (4.6)'ya bakacak olursak modelin doğruluk (Precision, P), duyarlılık (Recall, R) ve ortalama doğruluk (mAP0.5) değerlerini genel olarak yüksek olduğunu görmekteyiz. mAp50 değerini göz önüne alırsak modellemenin bu grupta neredeyse %75 oranında başarı sağladığını söylenebilir. Ayrıca modelleme precision ve recall değerlerine baktığımızda oldukça dengeli performans sağladığı da görülmektedir.

Tablo 4.6: Eklem basamaklanmasının değerlendirilmesi

Sınıf	Görseller	Örnekler	P	R	mAP50
Tümü	24	24	0,784	0,815	0,748
BasVAR	24	9	0,873	0,764	0,776
BasYOK	24	15	0,696	0,867	0,719


(BasVAR: eklem basamaklanması olan kırıklar, BasYOK:eklem basamaklanması olmayan kırıklar P:Doğruluk, R:Duyarlılık, mAP50: ortalama doğruluk değeri)

Dorsal Kortekste Parçalanmanın Değerlendirilmesi

Radius dorsal kortekste parçalanma da yine iki gruba ayrılarak dorsal kortekste parçalanma var veya parçalanma yok olarak gruplandırılmıştır.

Metrik graflerine baktığımızda benzer sonuçların burada da olduğu görülmektedir.

Tablo 4.7: Dorsal kortekste parçalanmanın değerlendirilmesinde modelin performansı



Tablo (4.8)'e bakacak olursak ise modellemenin genel performansının kabul edilebilir olduğunu görüyoruz. Tablo (4.8)'de ölçümler detaylı olarak verilmiştir.

Tablo 4.8 : Dorsal kortekste parçalanmanın değerlendirilmesi

Sınıf	Görseller	Örnekler	P	R	mAP50
Tümü	23	23	0,573	0,711	0,628
pvar	23	17	0,549	0,588	0,515
pyok	23	6	0,596	0,833	0,741


(pvar:Dorsal kortekste parçalanması olan kırıklar, pyok: Dorsal kortekste parçalanması olmayan kırıklar, P:Doğruluk, R:Duyarlılık mAP50: ortalama doğruluk değeri)

Radial İnklinasyonun Değerlendirilmesi

Çalışmamızda radial inklinasyon açısını 15 derece olarak baz aldık. İnklinasyon açısının 15 derece ve üstü olmasını uygun olarak kabul ettik. Gruplandırılmamızı ölçeklendirme belirtmeden radial inklinasyon açısı uygun ve uygun değil olarak ayrıldı.

Metrik graflerine bakacak olursak; her grupta olduğu gibi görüntü sayısı artıkcı modellemenin yeteneğinin arttığı görünmektedir.

Tablo 4.9: Radial inklasyonun deęerlendirilmesinde modelin performansı



Tablo (4.10)'a bakacak olursak modellemenin bu konuda mAp50 deęerlerinin çok yüksek olduęunu görüyoruz. Ama bu deęerlendirme ve volar eęimde olduęu gibi görsel olarak açığı algılayabilme arařtırmaya çok açık olduęu düşünölmektedir. Burada özellikle Recall deęerinin yüksek olması ve eęitilebilir olması önemlidir.

Tablo 4.10: Radyal inklasyonun deęerlendirilmesi


Sınıf	Görseller	Örnekler	P	R	mAP50	mAP50-95
Tümü	15	15	0,81	0,867	0,903	0,446

(P:Doęruluk, R:Duyarlılık, mAP50: ortalama doęruluk deęeri)

Volar Eęimin Deęerlendirilmesi

Çalıřmamızda volar eęimi 0-20 derece açılanmayı uygun olarak gruplandırıldı. Metrik grafilere baktığımızda aynı řekillenmenin farklı oranlarda da olsa olduęunu görmekteyiz.

Tablo 4.11: Volar eęimin deęerlendirilmesinde modelin performansı



Tablo(4.12)'ye bakacak olursak modellemenin performansının kabul edilebilir olduđu grlmektedir. zellikle precision deęeri nemli bir gstergedir.

Tablo 4.12: Volar eęimin deęerlendirilmesi

Sınıf	Grseller	rnekler	P	R	mAP50
Tm	13	16	0,928	0,688	0,727

(P:Doęruluk, R:Duyarlılık, mAP50: ortalama doęruluk deęeri)

5. TARTIŞMA

Bu çalışma ile distal radius kırıklarının Frykman sınıflamasına göre gruplandırılması, kapalı redüksiyon ve alçılama yapılan hastaların grafilerinin, konservatif tedavinin radyolojik kriterleri içinde olup olmadığının derin öğrenme modelleri ile tanınmasını amaçlamaktadır. Ortopedi ve travmatolojide yapay zekânın kullanımına baktığımızda kırık tanınması, kas-tendon yaralanmaları, kitlelerin yorumlanması ve rehabilitasyon programları gibi tanı ve tedavi protokollerinin çeşitli aşamalarında kullanımı ile ilgili çalışmalar vardır. Bizim çalışmamızın en belirgin farkı tek bir anatomik bölge özelinde derin öğrenme modellerinin kullanılması, kırık tanısının ve aynı zamanda tedavi edilen hastanın grafisinin konservatif tedaviye uygun olup olmadığının araştırılmasıdır. Ayrıca dorsal kortekte parçalanma gibi kırık sınıflamasından ziyade tedavinin prognozu hakkında bilgi verebilecek verilerimizin bulunması tedavini seçimi için ortopedi ve travmatoloji uzmanlarına yardımcı olabileceği ile ilgili bize fikir vermesidir. Bununla beraber ölçümlerimiz içinde volar eğim ve radyal inklinasyon ölçümleri gibi klinik pratikte kullandığımız ölçümler derin öğrenme modellerinin yardımıyla kullanımı araştırılmıştır. Literatüre baktığımızda volar eğim ve radial inklinasyon açılarının ölçümüyle ilgili yeteri kadar çalışma olmadığı için elde ettiğimiz verilerin yol gösterici olabileceğini düşünmekteyiz.

Çalışmamızın bulgularına bakacak olursak Frykman sınıflamasını simüle etmek amacıyla ulna styloid kırıklarını ayrı bir grup olarak tanımladık. Kırık sınıflandırmasında ise ekstraartiküler kırıklar (tip 1), radiokarpal kırıklar (tip 3), radioulnar kırıklar (tip 5) ve her iki eklem uzanan kırıklar (tip 7) olarak simüle edildi. Ulna styloid kırık varlığı kırık sınıflandırma numarasını bir puan arttıracaktır. Yapay zekâ destekli derin öğrenme modelinin ulna kırığını tespit etme oranı tüm sınıflarda yaklaşık %60 olarak bulunmuştur. Sınıflandırmalara ayrı ayrı bakacak olursak özellikle ekstraartiküler kırıkları %70 oranında tespit etmiştir. Tabii ki bazı gruplarda örnek görüntü sayısı düşük olduğu için derin öğrenme modelinin eğitim oranları düşük olarak gelmiştir. Örneğin radiokarpal ve radioulnar kırıklar için başarı oranı %30 olarak belirlenmiştir ki bu düşük bir orandır. Derin öğrenme modellerinin çalışma prensiplerinde açıklanan sebeple görüntü sayısının az olması ve gruplandırılma sayısının fazla olması bu modellerinin başarı oranını düşürmektedir. Bu konuda daha büyük verilerle çalışmalar yapılması gerekmektedir.

Eklem basamaklanmasının model tarafından değerlendirilmesinde; yaklaşık olarak %75 oranında doğru tanımlanmıştır. Çalışmamızda görüntü üzerinde gerçek ölçüm yapılması

mümkün olmadığı için eklem basamaklanması var ya da yok olarak kabul edildi. Yine aynı sebepten dolayı radial kısalık ölçümü kriterlerden biri olarak belirlenmedi.

Dorsal korteks parçalanmasını değerlendirme oranına baktığımızda ise yaklaşık %62 oranında bir başarı oranı görülmektedir. Dorsal kortekste parçalanma olması instabilite kriteri olarak kabul edildiği için konservatif tedaviye karar verme aşamasında yapay zekâ klinisyenlere yardımcı olabilir. Ama tabii ki büyük veri setleriyle daha kapsamlı çalışmalar yapılmasına ihtiyaç duyulacağını düşünülmektedir.

Volar eğim ve radial inklinasyon ölçümünün değerlendirilmesinde, verilerimiz özellikle radial inklinasyon açısından %92 gibi yüksek bir uyum oranı gösterse de, bu ölçüm gerektiren bir değerlendirme olduğundan literatürde daha sınırlı bilgi bulunmaktadır. Çalışmamızda radial inklinasyon açısı 15 dereceden büyük ve volar eğim açısı 0-20 derece arasında olan grafipler konservatif tedaviye uygun olarak sınıflandırılmıştır. Literatürde derin öğrenme modellerinin açı ölçebilme veya tahmin edebilme yeteneği ile ilgili ortopedi ve travmatoloji alanında kullanımına dair çalışmaya rastlanılmadı. Bu konu ilerleyen zamanlarda literatürde daha kapsamlı olarak yer alacaktır.

Ama bütün sonuçların ortak noktasına baktığımızda ise derin öğrenme modellerinin daha çok veri ile daha iyi sonuçlar verebileceğini göstermektedir. Çalışmamız ile daha büyük veri setleriyle daha verimli öğrenme modellerinin yapılabileceği gösterilmiştir. Bu aynı zamanda literatür tarafından desteklenen bir bulgudur (60).

Hang Min ve arkadaşlarının yaptığı çalışmada derin öğrenme modellerinin yardımıyla distal radius kırıklarının ekstra artiküler ve intraartiküler kırıklar olarak sınıflandırılması amaçlanmıştır. Bu çalışmada 400 adet radyolojik görüntü kullanılmıştır. Sadece PA grafiplerle yapılan çalışmada %81 doğruluk, %83 duyarlılık elde edilmiştir. Araştırmacılar yazılarında sınırlı veri setleriyle yapıldığını ve daha büyük veri setleriyle daha iyi sonuçlar alınabileceğini belirtmişlerdir (60). Bu bizim çalışmamızın sonuçlarını destekleyen bir bulgudur. Bizim çalışmamızda kırık sınıflandırılmasının değerlendirmesine baktığımızda daha düşük duyarlılık ve daha düşük doğruluk değerlerinin olmasının sebebi, bizim daha detaylı bir sınıflandırma yapmak istememiz ama buna karşın daha az görüntü kullanmamız olduğunu düşünmekteyiz. Buna karşın bizim çalışmamızda daha fazla veri seti, daha fazla gruplandırma, hem PA hem de lateral grafiplerden oluşan değerlendirmeler eklenmiştir. Ayrıca derin öğrenme modellerinin desteği ile distal radius kırıklarının konservatif tedavisinde kullanılan radyolojik

parametrelerin gruplandırılması amaçlanmıştır. Burada klinik pratikte ölçümlerin subjektif olarak değerlendirilmesi ve hekimlerin tanı koymasını hızlandırmak amaçlanmıştır. Günümüzde olmasa da ilerleyen teknoloji ve yapay zekânın modern tıbbı entegrasyonu ile daha fazla çalışma yapılarak daha yüksek oranlar elde edilebilir. Çalışmamızın sonuçlarıyla güncel literatüre yol gösterebileceğini düşünmekteyiz. Tabii ki bunların yanında bizim çalışmamızda daha güncel bir derin öğrenme modellemesinin kullanılması da diğer çalışmaların sonuçlarıyla karşılaştırılmasını zor hale getirmektedir.

Axehus M. ve arkadaşları metakarp ve falanks kırıklarının CNN modelleri ile tanıma ve sınıflandırmayı amaçladığı çalışmasına bakıldığında transvers metakarpal kırıklar: AUC = 0.91 (Area Under the Curve-Eğri altında kalan alan), %100 duyarlılık, %87 özgüllük ile distal falanks kırıklarının AUC = 0.97, %100 duyarlılık, %96 özgüllük ile tahmin edilmiştir. Bu çalışmada en iyi performans gösteren kırık türleri olarak öne çıkmıştır. Oblik ve intraartiküler kırıklar gibi daha kompleks kırıklarda ise AUC = 0.76, %71 duyarlılık, %79 özgüllük elde edilmiştir (61). Bu sonuçlar, radiokarpal ve radioulnar eklemlere uzanan kırıkların tanınmasında aldığımız düşük oranları desteklemektedir.

YZ'nın kırık tanınması ile ilgili yapılan geniş serili bir çalışmada (62) yapay zekâ destekli derin öğrenme modellerinin hem radius distal kırıklarının tanınması hem de hekimlere tanıda destek olması açısından değerlendirilmesi amaçlanmıştır. Bu çalışmada 26.121 adet grafi ile sadece kırık olup olmadığını gruplayan bir modelleme kullanılmıştır. Modelleme bağımsız olarak değerlendirildiğinde %96 duyarlılık, %91 özgüllüğe sahiptir ve bizim çalışmamızda bahsedildiği gibi veri setlerinin artması ile derin öğrenme modellerinin tahmin oranlarının arttığını göstermektedir. Aynı çalışmada ulaşılan önemli bir sonuç ise distal radius kırıklarının tanı sürecinde hekimlere olan faydalarıdır. Yapay zekâ destekli bir CNN modelinin hekimlerin tanısal doğruluğu arttırdığını ve hata oranlarını düşürdüğü saptanmıştır. Özellikle ortopedi ve travmatoloji asistanlarının yapay zekâ destekli derin öğrenme modellerinden daha fazla yarar gördüğü anlamlı olarak tespit edilmiştir (62). Bizde ilerleyen yıllarda yapay zekâ destekli derin öğrenme modellerinin tıp eğitiminde önemli bir yer tutabileceğini öngörmekteyiz.

Zhang ve arkadaşlarının büyük veri setleriyle yapmış olduğu araştırmaya baktığımızda kırığın evrendirilmesinden ziyade kırığın tanınması düzeyinde çalışmışlardır (63). Bu çalışmanın öne çıkan bir başka özelliği ise aynı kırığın tanınmasında farklı modellemelerin de karşılaştırılması olmuştur. Örnek vermek gerekirse distal radius kırıkları, çalışmada kullanılan bir modellemede %99.3 doğruluk, %98.7 duyarlılık ve %100 özgüllük ile başka bir

modellemede ise %97.03 doğruluk, %95.7 duyarlılık ve %98.37 özgüllük ile tanınmıştır. Çalışmada farklı algoritmalar kullanımı ile modellemelerin performanslarının artabileceğini ve tanı değerlerinin yükseleceğini belirtmişlerdir (63). Biz de aynı şekilde sınıflandırılmalar için yapılacak olan farklı modellemeler ile hata oranının azalacağını düşünmekteyiz.

Çalışmamızda klinik verileri eklemeyen sadece radyografiler üzerinden veriler elde edilmiş olsa da makine öğrenimi ile distal radius kırıklarının komplikasyon riskini tahmin etmek için etkili bir araç olduğunu düşündüren çalışmalar da vardır (64). Alexander L ve arkadaşları distal radius kırığı nedeniyle operasyon geçiren, ameliyat sonrası yedi gün içinde komplikasyon yaşayan, tekrar hastaneye yatışı yapılan veya ameliyat sonrası bir günden daha fazla hastane yatışı olan hastalardan elde ettiği verileri kullanmışlardır. Bu verilerle makine öğrenimi modellerinin, DRF ameliyatı sonrası komplikasyon riskini tahmin etmede etkili olduğunu göstermişlerdir (64). Gelecekte yapılacak çalışmalarda görüntülerin yanında hasta verilerinin dahil edilmesiyle klinik kullanıma daha uygun modellemeler geliştirilebilir.

Yapay zekânın gelişmesi tıp dünyasında devrim olacağı öngörülmekte ama klinik kullanımının önündeki sorunları da beraberinde getirmektedir. Pai ve arkadaşları, Amerika Birleşik Devletleri'nde FDA (Gıda ve İlaç Dairesi) gibi düzenleyici kurumlar, YZ tabanlı tıbbi cihazların güvenilirliğini ve etkinliğini denetlerken, Avrupa Birliği "AI Liability Directive" gibi düzenlemelerle bu alandaki hukuki boşlukları doldurduğunu, Hindistan'da ise YZ'nin sağlık hizmetlerindeki kullanımıyla ilgili net bir yasal çerçeve bulunmadığını belirtmişlerdir. Bu nedenle ortopedik cerrahların YZ'yi bir araç olarak görmeleri ve tamamen güvenmemeleri gerektiği belirtilmiştir (65). YZ'nin sağlık hizmetlerindeki rolünü düzenleyen spesifik yasaların oluşturulması, hem hasta güvenliğini artıracak hem de sağlık profesyonellerinin üzerindeki hukuki yükü hafifletecektir.

Yapay zekânın çeşitli alt dallarının klinik pratikte kullanımı arttıkça etik kurallar da gündeme gelmektedir. Bunu yapay zekânın sağlık alanına entegrasyonunun sunduğu kolaylıkların yanında getirdiği zorluklardan biri olarak görülmektedir. Yapılan bir çalışmada veri güvenliği, yapay zekânın karar alma aşamaları ve karar alma sürecindeki rolleri net olmadığı için şeffaflık ve güven ile ilgili sorunlarla beraber tanı ve tedavi sürecinde oluşabilecek sorumluluk gibi problemlerin de olduğu düşünülmektedir. Aynı çalışmada bu problemlerin çözümü için yeterli veri setleriyle daha fazla çalışma yapılarak hata oranlarının düşürülmesi, özellikle ilgili alanlarla daha fazla iş birliği yapılmasıyla oluşabilecek problemlerin önüne geçilebileceği belirtilmektedir (66).

Çalışmamızın güçlü yönlerine değinirsek incelemeye alınan görüntülemelerin tek bir merkezde çekilmiş olması, yapılan değerlendirmelerin standardizasyonu açısından 3 hekim tarafından ve aynı açı ölçme programı kullanılarak yapılması ve sınıflandırmaların 3 ortopedi ve travmatoloji hekimi tarafından yapılmış olmasıdır.

Çalışmamızın kısıtlılıklarına bakacak olursak; kırığın tanınmasının değerlendirilmesi açısından farklı sınıflar için aynı sayıda görüntü elde edilmemiş olması, daha küçük bir veri seti ile değerlendirilme yapılması, çalışmada sadece radyoloji görüntülerin kullanılması ve hastaların klinik detayına yer verilmemiş olması ve çalışmanın retrospektif olarak tasarlanması sayılabilir.

Yapay zekâ destekli derin öğrenme modellerinin incelendiği çalışmamızda ortopedi ve travmatoloji polikliniklerinde ve acil servislerde kırık tanınmasının yanısıra tedavi yönteminin seçiminde yardımcı olabileceğini düşünmekteyiz. Tanı ve tedavi seçiminde hekimlerin iş gücünü azaltmasının ilerleyen zamanlarda mümkün olabileceğini de düşünmekteyiz. Genel olarak literatüre baktığımızda daha az gruplandırma kullanılması özellikle bizim çalışmamızı öne çıkarmaktadır. Ayrıca ölçüm gerektiren parametrelerin değerlendirilmesi ile ilgili henüz bir modelleme olmaması yeni yapılacak çalışmalara ihtiyaç olduğunu göstermektedir.

6. SONUÇLAR

Bu çalışma derin öğrenme modelleri yardımıyla DRK'larının sınıflandırılması ve konservatif tedavi edilen hastaların radyografileri üzerinden radyolojik parametrelerinin değerlendirilmesiyle yapay zekâ uygulamaları alanında yapılan araştırmalara katkı sağlamaktadır. Bizim çalışmamızda da görüldüğü üzere daha büyük veri setleri ile daha verimli modeller oluşturulabilir ve klinik kullanıma entegre edilebilir.

Yapay zekâ ve derin öğrenme modellerini tıp eğitimi içinde özellikle acil tıp birimi asistan hekimlerinin ile ortopedi ve travmatoloji birimi asistan hekimlerinin eğitimine katkı sağlayabileceğine inanmaktayız. Bunun için tıp hekimlerinin güncel gelişmeleri takip etmesi ve yapay zekâ uygulamalarına hakim olması da gerekmektedir. Aynı zamanda mühendisliğin de ilgi alanına girdiği için ortak çalışma programları oluşturulabilir. Sadece uzmanlık eğitimi alan hekimler için değil aynı zamanda tıp fakültesi öğrencileri için temel müfredat programlarına eklenilmesi gündeme gelebileceğini düşünmekteyiz.

Güncel literatür ve bizim sonuçlarımız derin öğrenme modellerinin önümüzdeki süreçte tıbbın her alanında fayda sağlayabileceğini göstermektedir. Tabi ki bu büyük bir entegrasyon programı gerektirmektedir. Bu süreçte ilerleyen yapay zekâ teknolojisi bu süreci hızlandıracaktır. YZ teknolojisinin klinik kullanıma ne kadar etki edebileceği veya tanı ve tedavi sürecinin hangi aşamalarında olması gerektiğini öngörememekle beraber bu konuda daha fazla çalışmaya ihtiyaç olduğunu görmekteyiz.

Çalışmamız sınırlamalar içermesine rağmen elde edilen veriler ışığında yeni yapılacak çalışmalara yol gösterecektir.

Sonuç olarak yapay zekâ ve derin öğrenme modellerinin verimli kullanımı ile ortopedi ve travmatoloji hekimlerine tanı ve tedavide yardımcı olabilir ve iş gücünü azaltabileceğini öngörmekteyiz.

KAYNAKLAR

1. Strohm L, Hehakaya C, Ranschaert ER, Boon WPC, Moors EHM. Implementation of artificial intelligence (AI) applications in radiology: hindering and facilitating factors. *Eur Radiol.* 2020 Oct;30(10):5525-5532. doi: 10.1007/s00330-020-06946-y. Epub 2020 May 26. PMID: 32458173; PMCID: PMC7476917.
2. Bhandari A. Revolutionizing Radiology With Artificial Intelligence. *Cureus.* 2024 Oct 29;16(10):e72646. doi: 10.7759/cureus.72646. PMID: 39474591; PMCID: PMC11521355.
3. Ye Q, Yang H, Lin B, Wang M, Song L, Xie Z, Lu Z, Feng Q, Zhao Y. Automatic detection, segmentation, and classification of primary bone tumors and bone infections using an ensemble multi-task deep learning framework on multi-parametric MRIs: a multi-center study. *Eur Radiol.* 2024 Jul;34(7):4287-4299. doi: 10.1007/s00330-023-10506-5. Epub 2023 Dec 21. PMID: 38127073.
4. Li J, Li S, Li X, Miao S, Dong C, Gao C, Liu X, Hao D, Xu W, Huang M, Cui J. Primary bone tumor detection and classification in full-field bone radiographs via YOLO deep learning model. *Eur Radiol.* 2023 Jun;33(6):4237-4248. doi: 10.1007/s00330-022-09289-y. Epub 2022 Nov 30. PMID: 36449060.
5. Kuo RYL, Harrison C, Curran TA, Jones B, Freethy A, Cussons D, Stewart M, Collins GS, Furniss D. Artificial Intelligence in Fracture Detection: A Systematic Review and Meta-Analysis. *Radiology.* 2022 Jul;304(1):50-62. doi: 10.1148/radiol.211785. Epub 2022 Mar 29. PMID: 35348381; PMCID: PMC9270679.
6. Shen L, Gao C, Hu S, Kang D, Zhang Z, Xia D, Xu Y, Xiang S, Zhu Q, Xu G, Tang F, Yue H, Yu W, Zhang Z. Using Artificial Intelligence to Diagnose Osteoporotic Vertebral Fractures on Plain Radiographs. *J Bone Miner Res.* 2023 Sep;38(9):1278-1287. doi: 10.1002/jbmr.4879. Epub 2023 Aug 2. PMID: 37449775.

7. Twinprai N, Boonrod A, Boonrod A, Chindaprasirt J, Sirithanaphol W, Chindaprasirt P, Twinprai P. Artificial intelligence (AI) vs. human in hip fracture detection. *Heliyon*. 2022 Oct 27;8(11):e11266. doi: 10.1016/j.heliyon.2022.e11266. PMID: 36339768; PMCID: PMC9634369.
8. Ong W, Liu RW, Makmur A, Low XZ, Sng WJ, Tan JH, Kumar N, Hallinan JTPD. Artificial Intelligence Applications for Osteoporosis Classification Using Computed Tomography. *Bioengineering (Basel)*. 2023 Nov 27;10(12):1364. doi: 10.3390/bioengineering10121364. PMID: 38135954; PMCID: PMC10741220.
9. Orji C, Reghefaoui M, Saavedra Palacios MS, Thota P, Peresuodei TS, Gill A, Hamid P. Application of Artificial Intelligence and Machine Learning in Diagnosing Scaphoid Fractures: A Systematic Review. *Cureus*. 2023 Oct 26;15(10):e47732. doi: 10.7759/cureus.47732. PMID: 38021992; PMCID: PMC10676208.
10. Kim Y, Kim YG, Park JW, Kim BW, Shin Y, Kong SH, Kim JH, Lee YK, Kim SW, Shin CS. A CT-based Deep Learning Model for Predicting Subsequent Fracture Risk in Patients with Hip Fracture. *Radiology*. 2024 Jan;310(1):e230614. doi: 10.1148/radiol.230614. PMID: 38289213.
11. Lim JA, Loh BL, Sylvester G, Khan W. Perioperative management of distal radius fractures. *J Perioper Pract*. 2021 Oct;31(10):1750458920949463. doi: 10.1177/1750458920949463. Epub 2020 Sep 8. PMID: 32894999; PMCID: PMC8474299.
12. Güdemez, Eftal, Serkan Uludağ, and Yaprak Ataker. "Distal radius kırıklarına genel bakış ve konservatif tedavisi." *TOTBİD Dergisi* 12 (2014): 177-93.
13. Schroeder JD, Varacallo M. Smith Fracture Review. [Güncellendi 2024 Ocak 11]. İçinde: StatPearls . Treasure Island (FL): StatPearls Publishing; 2024 Ocak-. Buradan edinilebilir: <https://www.ncbi.nlm.nih.gov/sites/books/NBK547714/>
14. Madanat, Rami. (2011). The Use of Radiostereometric Analysis in Fractures of the Distal Radius: From Phantom Models to Clinical Application.

15. Mesut R, Yıldırım M. Üst taraf; Bilek bölgeleri. Topoğrafik Anatomi, (1. baskı) Beta yayınları, İstanbul, 1995, pp.85-90.
16. Çimen A. Systema Locomotorium; Osteologia, Arthrologia. Uludağ Üniversitesi güçlendirme vakfı yayınları, Bursa, 1991, pp.60-73.
17. Yıldırım M.(Snell RS' den çeviri), Klinik anatomi, Nobel Tıp Kitabevleri, İstanbul,1997,pp.427-37.
18. Gökmen FG. Sistematik anatomi. Güven Kitabevi, İzmir, 2003, pp.67-73, 114-7.
19. Adams CR. Outline of Fractures. 6th ed. Edinburgh: Churchill Livingstone, 1972;pp 158-68.
20. Zanotti RM, Louis DSJTJohs. Intra-articular fractures of the distal end of the radius treated with an adjustable fixator system. 1997;22:428-40.
21. Ç. AYHAN And İ. TEKDEMİR, "El ve El Bileği: Anatomi ve Biyomekanik," In Üst Ekstremitte Yaralanmalarında Rehabilitasyon , Ankara: Hipokrat, 2021, pp.66-108.
22. Wolfe, Scott W. "Distal radius fractures." *Green's operative hand surgery* 2 (2017).
23. Çırpar, M., & Pehlivan, O. (2022). KRONİK EL BİLEK AĞRISININ DEĞERLENDİRİLMESİ. The Journal of Kırıkkale University Faculty of Medicine, 24(2), 417-427. <https://doi.org/10.24938/kutfd.1137183>
24. Capo JT, Accousti K, Jakob G, et al. The effect rotational malalignment on X-rays of the wrist. J hand surg Eur 2009;34:166-172
25. Ronald LL. William PC. James HH. Fractures dislocation in the hand. Rockwood and Green's fractures in adults, 4th edition, Volume 1. PP: Lippincott- Raven JbB. 1996;745-849.
26. Lundy D, Quisling S, Lourie G, et al. Tilted lateral radiographs in the evaluation of intraarticular distal Radius fractures. J Hand Surg Am 1999;24:249-256

27. Warwick D, Prothero D. Radiological management of the radial shortening in Colles' fractures. *J Hand Surg Br* 1993;18(1):50-52
28. Schuind FA, Linscheid RL, Kai-Nan EYS. Current concepts review a normal data base of posteroanterior roentgenographic measurements of the wrist. *J Bone Joint Surg Am* 1992;74(9):1418-
29. Melone CP. Articular fractures of the distal radius. *Orthop Clin North Am* 1984;15(2):217-236.
30. Harhaus L, Neubrech F, Hirche C, Schilling T, Kohler H, Mayr A, Riesmeier A, Bickert B, Kneser U. Komplexes regionales Schmerzsyndrom nach distaler Radiusfraktur : Aktuelle Epidemiologie, pathophysiologische Modelle, Diagnostik und Therapie [Complex regional pain syndrome following distal fractures of the radius : Epidemiology, pathophysiological models, diagnostics and therapy]. *Unfallchirurg*. 2016 Sep;119(9):732-41. German. doi: 10.1007/s00113-016-0217-x. PMID: 27488541.
31. Imrie M, Yao J. Distal radius fractures: A Historical perspective. In: Slutsky DJ, Osterman AL, editors. *Fractures and Injuries of the Distal Radius and Carpus*. Philadelphia: Saunders Elsevier, 2009. p.3–10.
32. Jupiter JB, Fernandez DL. *Complications following distal radial fractures*. *Journal of Bone and Joint Surgery*, 2001.
33. Wolfe SW, Hotchkiss RN, Pederson WC, Kozin SH. *Green's Operative Hand Surgery*. 7th Edition, Elsevier, 2017.
34. Rhee PC, Medoff RJ, Shin AY. *Complex distal radius fractures: an anatomic algorithm for surgical management*. *Journal of the American Academy of Orthopaedic Surgeons*, 2017.
35. Melone CP. *Distal radius fractures: patterns of articular fragmentation*. *Orthopedic Clinics of North America*, 1993.

36. Meinberg, EG MD ; Agel, J MA, ATC ; Roberts, CS MD, MBA ; Karam, MD MD ; Kellam, JF MD .Kırık ve Çıkık Sınıflandırma Özeti—2018. *Ortopedik Travma Dergisi* 32():p S1-S10, Ocak 2018. | DOI: 10.1097/BOT.0000000000001063
37. Fernandez DL, Jupiter JB. *Fractures of the Distal Radius: A Practical Approach to Management*. Springer, 2002
38. Cooney WP. *Management of Colles' fractures*. *Journal of Hand Surgery*, 1993.
39. Belloti JC, Santos JBGD, Erazo JP, Iani LJ, Tamaoki MJS, Moraes VY, Faloppa F. A new method for classifying distal radius fracture: the IDEAL classification. *Rev Bras Ortop*. 2013 Jun 11;48(1):36-40. doi: 10.1016/j.rboe.2012.06.002. PMID: 31304108; PMCID: PMC6565848.
40. Frykman, Gösta. "Fracture of the distal radius including sequelae-shoulder-handfinger syndrome, disturbance in the distal radio-ulnar joint and impairment of nerve function: a clinical and experimental study." *Acta Orthopaedica Scandinavica* 38.sup108 (1967): 1-61.
41. Shum L, Coleman CM, Hatakeyama Y, Tuan RS. Morphogenesis and dysmorphogenesis of the appendicular skeleton. *Birth Defects Research (Part C)* 2003;69:102-122.
42. Fernandez DL. Closed manipulation and casting of distal radius fractures. *Hand Clin*. 2005;21(3):307-316.
43. Gofton W, Liew A. Distal radius fractures: nonoperative and percutaneous pinning treatment options. *Orthop Clin North Am*. 2007;38(2):175-185, v-vi.
44. Mathews AL, Chung KC. Management of complications of distal radius fractures. *Hand Clin*. 2015;31(2):205-215.
45. Wahlstrom O. Treatment of Colles fracture. A prospective comparison of three different positions of immobilization. *Acta Orthop Scand* 1982;53:225-8.

46. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015 May 28;521(7553):436-44. doi: 10.1038/nature14539. PMID: 26017442.

47. Akın, E., & Şahin, M. E. (2024). Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme. *EMO Bilimsel Dergi*, 14(1), 27-38.

48. Litjens, G., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.

49. Haug CJ, Drazen JM. Artificial Intelligence and Machine Learning in Clinical Medicine, 2023. *N Engl J Med*. 2023 Mar 30;388(13):1201-1208. doi: 10.1056/NEJMra2302038. PMID: 36988595.

50. Orthobullets. Distal radius fractures. Orthobullets website. Accessed February 13, 2025. <https://www.orthobullets.com/trauma/1027/distal-radius-fractures>

51. Scientific Animations. Wiki images. Scientific Animations website. Published under CC BY-SA 4.0. Accessed February 13, 2025. <https://commons.wikimedia.org/w/index.php?curid=92031630>.

52. Eschweiler J, Li J, Quack V, Rath B, Baroncini A, Hildebrand F, Migliorini F. Anatomy, biomechanics, and loading of the wrist joint. *Life*. 2022;12(2):188. doi:10.3390/life12020188.

53. Argün AS. Radius alt uç kırıklarında klinik ve işlevsel sonuçlar üzerine etkili parametreler [Tıpta uzmanlık tezi]. Erciyes Üniversitesi Tıp Fakültesi; 2015.

54. Bilgin Y, Ekinçi M, Özmen Z, Birisik F. Radiological measurement parameters of distal radius and wrist measured on X-rays in the Turkish population. *North Clin Istanbul*. 2023;10(4):484-489. doi:10.14744/nci.2022.56514.

55. Jayakumar P, Teunis T, Giménez BB, Verstreken F, Di Mascio L, Jupiter JB. AO distal radius fracture classification: global perspective on observer agreement. *J Wrist Surg.* 2017;6(1):46-53. doi:10.1055/s-0036-1587316.
56. Faculty of Medicine, University of Washington. Frykman classification of distal radial fractures. Trauma radiology reference resource. Accessed February 13, 2025. <https://faculty.washington.edu/jeff8rob/trauma-radiology-reference-resource/9-upper-extremity/frykman-classification-of-distal-radial-fractures/>.
57. Tarlacık AO. Konservatif takip edilen radius alt uç kırıklı hastalarda redüksiyon kaybında etkili faktörler [Tıpta uzmanlık tezi]. Eskişehir Osmangazi Üniversitesi Tıp Fakültesi; 2020.
58. Ertunç Z. Akciğer Bilgisayarlı Tomografisinde İnsidental Saptanan Meme Nodüllerinin Evrişimli Sinir Ağları ile Benign-Malign Olarak Sınıflandırılması. [Yüksek Lisans Tezi]. Muğla: Muğla Sıtkı Koçman Üniversitesi; 2023.
59. <https://roboflow.com>
60. Min, Hang, et al. "Automatic classification of distal radius fracture using a two-stage ensemble deep learning framework." *Physical and engineering sciences in medicine* 46.2 (2023): 877-886.
61. Axenus M, Wallin A, Havela J, Severin S, Karahan A, Gordon M, Magnéli M. Automated diagnosis and classification of metacarpal and phalangeal fractures using a convolutional neural network: a retrospective data analysis study. *Acta Orthop.* 2025 Jan 9;96:13-18. doi: 10.2340/17453674.2024.42702. PMID: 39786203; PMCID: PMC11714779.
62. Breu R, Avelar C, Bertalan Z, et al. Artificial intelligence in traumatology. *Bone Joint Res.* 2024;13(10):588-595. doi:10.1302/2046-3758.1310.BJR-2023-0275.R3
63. Zhang JY, Yang JM, Wang XM, Wang HL, Zhou H, Yan ZN, Xie Y, Liu PR, Hao ZW, Ye ZW. Application and Prospects of Deep Learning Technology in Fracture Diagnosis. *Curr Med Sci.* 2024 Dec;44(6):1132-1140. doi: 10.1007/s11596-024-2928-5. Epub 2024 Nov 18. PMID: 39551854.

64. Hornung AL, Rudisill SS, Smith S, Streepy JT, Simcock XC. Can Machine Learning Identify Patients Who are Appropriate for Outpatient Open Reduction and Internal Fixation of Distal Radius Fractures? *J Hand Surg Glob Online*. 2024 Aug 13;6(6):808-813. doi: 10.1016/j.jhsg.2024.06.002. PMID: 39703590; PMCID: PMC11652289.
65. Pai SN, Jeyaraman M, Shyam A. The AI Orthopedician will see you now - But who is Liable if it's Wrong? *J Orthop Case Rep*. 2024 Dec;14(12):1-3. doi: 10.13107/jocr.2024.v14.i12.4994. PMID: 39669024; PMCID: PMC11632473.
66. Jeyaraman M, Balaji S, Jeyaraman N, Yadav S. Unraveling the Ethical Enigma: Artificial Intelligence in Healthcare. *Cureus*. 2023 Aug 10;15(8):e43262. doi: 10.7759/cureus.43262. PMID: 37692617; PMCID: PMC10492220.